



DISERTASI - MO186604

# **STUDI PENINGKATAN KUALITAS KLASIFIKASI SEDIMENT DASAR LAUT DENGAN MENGGUNAKAN SELISIH BATIMETRI ANTAR FREKUENSI DAN MULTISPEKTRAL BACKSCATTER MULTIBEAM ECHOSOUNDER (MBES)**

KHOMSIN  
NRP. 04111960010007

DOSEN PEMBIMBING  
Prof. Ir. Mukhtasor, M.Eng., Ph.D  
Prof. Suntoyo, ST., M.Eng., Ph.D.  
Danar Guruh Pratomo, ST., MT., Ph.D.

PROGRAM DOKTOR  
BIDANG KEAHLIAN TEKNIK DAN MANAJEMEN PANTAI  
DEPARTEMEN TEKNIK KELAUTAN  
FAKULTAS TEKNOLOGI KELAUTAN  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA



# LEMBAR PENGESAHAN DISERTASI

Disertasi disusun untuk memenuhi salah satu syarat memperoleh gelar

**Doktor (Dr.)**

di

**Institut Teknologi Sepuluh Nopember**

Oleh:

**KHOMSIN**

**NRP. 04111960010007**

dengan Judul Disertasi

## **STUDI PENINGKATAN KUALITAS KLASIFIKASI SEDIMENT DASAR LAUT DENGAN MENGGUNAKAN SELISIH BATIMETRI ANTAR FREKUENSI DAN MULTISPEKTRAL BACKSCATTER MULTIBEAM ECHOSOUNDER (MBES)**

Tanggal Ujian: 16 Juli 2024

Periode Wisuda: September, 2024

Disetujui oleh:

**Pembimbing:**

1. Prof. Ir. Mukhtasor, M.Eng., Ph.D  
NIP. 1969 0420 1994 03 1 003



2. Prof. Suntoyo, ST., M.Eng., Ph.D  
NIP. 1971 0723 1995 12 1 001
3. Danar Guruh Pratomo, ST., MT., Ph.D  
NIP. 1980 0507 2003 12 1 001

**Penguji:**

1. Dr. Eng. Muhammad Zikra ST., M.Sc  
NIP. 1977 0225 2002 12 1 002
2. Dr. Dwa Desa Warnana, S.Si., M.Si  
NIP. 1976 0123 2000 03 1 001
3. Kolonel Laut (P) Dr. Dian Adrianto, S.Si, MSI  
NRP. 13436/P





**STUDI PENINGKATAN KUALITAS KLASIFIKASI SEDIMENT DASAR  
LAUT DENGAN MENGGUNAKAN SELISIH BATIMETRI ANTAR  
FREKUENSI DAN MULTISPEKTRAL BACKSCATTER  
MULTIBEAM ECHOSOUNDER (MBES)**

Nama Mahasiswa : Khomsin  
NRP Mahasiswa : 04111960010007  
Pembimbing : Prof. Ir. Mukhtasor, M.Eng., Ph.D  
Co-Supervisor : 1. Prof. Suntoyo, ST., M.Eng., Ph.D  
                  2. Danar Guruh Pratomo, ST., MT., Ph.D

**ABSTRAK**

Klasifikasi sedimen dasar laut mempunyai peran yang sangat penting dalam perencanaan dan pengembangan wilayah laut dan pesisir seperti keselamatan kapal pada saat sandar, konstruksi bangunan laut (pipa, kabel, rig, pelabuhan), dan lingkungan (habitat bentik, sedimen transport, pengeringan, pembuangan limbah). Klasifikasi sedimen dasar laut dapat dipetakan dengan data *in-situ* yang diambil dengan metode mekanik (*grab sampler* dan *gravity core*), optik (kamera dan video), dan metode akustik (*side scan sonar* (SSS), *singlebeam echosounder* (SBES) dan *multibeam echosounder* (MBES)). Penelitian ini menggunakan teknologi MBES MBES multifrekuensi yang dapat mengakuisisi data dengan frekuensi yang berbeda berbasis *ping by ping*. Masing-masing frekuensi memiliki karakteristik data kedalaman dan hamburan balik yang unik.

Penelitian ini bertujuan untuk mengklasifikasi sedimen dasar laut dengan menggunakan data batimetri dan *backscatter* dari MBES multifrekuensi. Klasifikasi sedimen dasar dilakukan dengan metode *Deep Neural Network* (DNN) dengan variasi input data seperti batimetri, selisih batimetri, fitur batimetri multifrekuensi, *backscatter*, dan fitur *backscatter* multispektral. Output data DNN ini adalah 74 titik sampel sedimen in situ yang diklasifikasikan sebagai *clayey sand*, *silty sand*, *sandy silt* dan *silt*.

Hasil dari penelitian ini menunjukkan bahwa klasifikasi sedimen dasar laut dengan metode DNN dan input kombinasi data batimetri, selisih batimetri dan fitur batimetri menghasilkan *overall accuracy* sebesar 71,9% dan koefisien kappa sebesar 0,59. Nilai ini naik 20,9% dan 0,22 dari *baseline* yang digunakan yaitu klasifikasi *Angular Range Analysis* (ARA) dengan akurasi 51% dan koefisien kappa 0,37. Peningkatan akurasi kedua tertinggi adalah input data kombinasi batimetri, selisih batimetri, fitur batimetri multifrekuensi, *backscatter* dan fitur backscatter multispektral dengan akurasi 62,2% dan koefsien kappa 0,28. Penurunan akurasi terjadi pada input batimetri dan selisih batimetri yaitu 41,9% dan koefisien kappa 0,21. Hasil penelitian ini akan memberi dampak yang besar bagi para pemangku kepentingan khususnya para praktisi dalam pemetaan klasifikasi sedimen dasar laut. Berdasarkan hasil penelitian ini, pemetaan sedimen dasar laut hanya membutuhkan data batimetri multifrekuensi (batimetri, selisih batimetri dan fitur batimetri) dan tidak membutuhkan data *backscatter*.

**Kata Kunci:** *klasifikasi, multibeam echosounder, multifrekuensi, sedimen dasar laut, selisih bathimetri, akurasi, kappa*

**STUDY OF IMPROVING THE QUALITY OF SEABED SEDIMENT  
CLASSIFICATION USING BATHYMETRIC DIFFERENCE  
INTER FREQUENCY AND MULTISPECTRAL BACKSCATTER  
MULTIBEAM ECHOSOUNDER (MBES)**

Student Name : Khomsin  
Student Identity Number : 04111960010007  
Supervisor : Prof. Ir. Mukhtasor, M.Eng., Ph.D  
Co-Supervisor : 1. Prof. Suntoyo, ST., M.Eng., Ph.D  
                  2. Danar Guruh Pratomo, ST., MT., Ph.D

**ABSTRACT**

The classification of seabed sediments has a very important role in the planning and development of marine and coastal areas such as the safety of ships at the time of berthing, the construction of marine buildings (pipes, cables, rigs, ports), and the environment (benthic habitats, transport sediments, dredging, waste disposal). The classification of seafloor sediments can be mapped with in-situ data taken by mechanical methods (grab sampler and gravity core), optical (camera and video), and acoustic methods (side scan sonar (SSS), singlebeam echosounder (SBES) and multibeam echosounder (MBES)). This research uses multi-frequency MBES technology that can acquire data with different frequencies based on ping by ping. Each frequency has unique data depth and backscatter characteristics.

This study aims to classify seafloor sediments using bathymetric and backscatter data from multifrequency MBES. Seabed sediment classification is carried out by the Deep Neural Network (DNN) method with data input variations such as bathymetry, bathymetric difference, multifrequency bathymetric feature, backscatter, and multispectral backscatter feature . The output of this DNN data is 74 in situ sediment sample points classified as clayey sand, silty sand, sandy silt and silt.

The results of this study show that the classification of seafloor sediments by the DNN method and the input of a combination of bathymetric data, bathymetric differences and bathymetric features produce an overall accuracy of 71.9% and a kappa coefficient of 0.59. This value increased by 20.9% and 0.22 from the baseline used, namely the Angular Range Analysis (ARA) classification with an accuracy of 51% and a kappa coefficient of 0.37. The second highest improvement in accuracy was the data input of bathymetric combination, bathymetric difference, multifrequency bathymetric feature, backscatter and multispectral backscatter feature with an accuracy of 62.2% and a kappa coefficient of 0.28. The decrease in accuracy occurred in the bathymetric input and the bathymetric difference was 41.9% and the kappa coefficient was 0.21. The results of this study will have a great impact on stakeholders, especially practitioners in mapping the classification of seabed sediments. Based on the results of this study, seafloor sediment mapping only requires multifrequency bathymetric data (bathymetry, bathymetric difference and bathymetric features) and does not require backscatter data.

**Keywords:** *classification, multibeam echosounder, multifrequency, seafloor sediments, bathymetric differences, accuracy, kappa*

## KATA PENGANTAR

Puji syukur Alhamdulillaah, kami panjatkan kepada Allah yang Maha Kuasa atas segala sesuati, karena dengan rahmat dan karunia-Nya, kami dapat menyelesaikan laporan Disertasi yang berjudul “Studi Peningkatan Kualitas Klasifikasi Sedimen Dasar Laut dengan Menggunakan Selisih Batimetri Antar Frekuensi Dan Multispektral *Backscatter* Multibeam Echosounder (MBES)” dengan baik. Kami mengucapkan terima kasih sebesar-besarnya kepada berbagai pihak yang telah memberikan bantuan baik secara moral maupun material sehingga penulis dapat menyelesaikan laporan disertasi ini.

1. Orang tua kami (Alm. Bp. As'ad; Alm. Ibu Hj. Suntirah, Alm. Bp. Tarji dan Ibu Suryani) serta istri (Ani Lestari) dan anak-anak kami (Hilmi, Lutfi dan Fahmi) atas support dan doanya sehingga laporan ini bisa diselesaikan dengan baik
2. Prof. Mukhtasor sebagai Promotor, Prof. Suntoyo sebagai Co-Promotor 1 dan Danar Guruh Pratomo, PhD sebagai Co-Promotor 2 atas bimbingan dan masukan ide-ide terkait dengan disertasi ini
3. Dr. Muhammad Zikra, Dr. Dwa Desa Warnana, dan Kolonel Laut (P) Dr. Dian Adrianto sebagai penguji yang memebri pertanyaan, kritik, ide dan saran yang sangat bermanfaat untuk perbaikan disertasi ini.
4. Keluarga besar Alm. Bp. As'ad dan Alm. Bp. Tarji atas doa dan dorongannya untuk segera menyelesaikan disertasi ini.
5. Semua dosen dan Tendik Pasca Sarjana S3 Teknik Kelautan, ITS Surabaya atas kerjasama dan bantuan yang telah diberikan selama kami mengambil studi di sini.
6. Keluarga besar Departemen Teknik Geomatika (Dosen dan Tendik) yang memberi semangat dan dorongan serta doa untuk segera menyelesaikan studi ini.
7. Semua pihak yang tidak bisa disebutkan satu per satu, yang telah membantu dan memberi dukungan kepada kami dalam pengambilan data, pengolahan data dan pemodelan yang digunakan utnuk analisa disertasi ini.

Penulis menyadari, laporan disertasi ini masih banyak kekurangannya. Oleh karena itu, kritik dan saran yang membangun akan diterima dengan senang hati untuk perbaikan dan penelitian kedepan. Kami berharap keberadaan laporan ini dapat bermanfaat dan barokah bagi kita semua di dunia dan akhirat. Amin yra.

Surabaya, Juli 2024

Penulis

## DAFTAR ISI

<b>LEMBAR PENGESAHAN</b>	i
<b>ABSTRAK</b>	iii
<b>ABSTRACT</b>	v
<b>KATA PENGANTAR</b>	vii
<b>DAFTAR ISI</b>	ix
<b>DAFTAR GAMBAR</b>	xv
<b>DAFTAR TABEL</b>	xxi
<b>DAFTAR SINGKATAN</b>	xxiii
<b>DAFTAR ISTILAH</b>	xxv
<b>BAB 1 PENDAHULUAN</b>	1
1.1 Latar Belakang	1
1.2 Permasalahan	7
1.3 Tujuan	7
1.4 Manfaat	8
1.5 Orisinalitas Penelitian	8
1.6 Hipotesis	11
<b>BAB 2 KAJIAN PUSTAKA DAN DASAR TEORI</b>	13
2.1 Sedimen Dasar Laut	13
2.2 Metode Pengambilan Sedimen Dasar Laut dengan Metode Non-Akustik	15
2.2.1 <i>Van Veen Grab Sampler</i>	15
2.2.2 Gravity Core	17

2.3 Metode Pemetaan Sedimen Dasar Laut Dengan Metode Akustik	18
2.3.1 Persamaan Dasar Akustik Bawah Air	18
2.3.2 Backscatter	24
2.3.2.1 Kebergantungan Sudut Datang	26
2.3.2.2 Kebergantungan Frekuensi	27
2.3.2.3 Koefisien <i>Backscatter</i> Permukaan Dasar Laut	28
2.3.2.4 <i>Backscatter</i> Dasar Permukaan	28
2.3.2.5 <i>Backscatter</i> Volume Sedimen	29
2.3.3 Model Deteksi Bawah Permukaan Dasar Laut	32
2.4 <i>Side Scan Sonar</i>	37
2.5 <i>Single Beam Echo Sounder</i>	40
2.6 <i>Multi Beam Echo Sounder</i>	43
2.6.1 Prinsip Multi Beam Echo Sounder	43
2.6.2 <i>Backscatter</i> MBES	45
2.6.3 MBES Multi Frekuensi	47
2.7 Review Pemetaan Klasifikasi Sedimen Dasar Laut dengan MBES Multispektral	48
2.8 Deep Neural Network	58
2.9 Evaluasi Akurasi (Kualitas) Klasifikasi	61
2.9.1 Metrik Konfusi Diskriminator	61
2.9.2 Indikator Akurasi	62
2.10 Variabel Penelitian	64

<b>BAB 3 METODOLOGI PENELITIAN</b>	67
3.1 Lokasi Penelitian	67
3.2 Data Penelitian	67
3.3 Peralatan	68
3.4 Metodologi Penelitian	68
3.4.1 Tahap Persiapan	68
3.4.2 Tahap Survei Lapangan	70
3.4.2 Tahap Pengolahan Data dan Analisa	70
3.4.3 Tahap Pelaporan dan Publikasi	77
<b>BAB 4 HASIL PENELITIAN DAN PEMBAHASAN</b>	79
4.1 Analisa Batimetri Multifrekuensi	79
4.1.1 Analisa Uji Tempel (Patch Test)	79
4.1.2 Analisa Kerapatan Data MBES Multifrekuensi	80
4.1.3 Model Batimetri Digital MBES Multi Frekuensi	81
4.1.4 Selisih Batimetri Antar Frekuensi	83
4.1.5 Analisis Volume Selisih Batimetri	85
4.1.6 Analisa Fitur Batimetri	88
4.1.6.1 Kemiringan	88
4.1.6.2 Aspek	89
4.1.6.3 Kelengkungan ( <i>Curvature</i> )	90
4.1.6.4 Indeks Posisi Batimetri ( <i>Bathymetric Position Index</i> )	91
4.1.6.5 Kekasaran ( <i>Roughness</i> )	92
4.1.6.6 Kekerasan ( <i>Ruggedness</i> )	92

4.2 Sampel in Situ Sedimen Dasar Laut	93
4.2.1 Distribusi Sampel Sedimen Dasar Laut in Situ	93
4.2.2 Analisis Ukuran Butir Sedimen	94
4.2.3 Analisis Jenis Sampel Sedimen Dasar Laut	95
4.3 <i>Backscatter</i>	97
4.3.1 Mosaik <i>Backscatter</i>	97
4.3.2 Fitur <i>Backscatter</i>	102
4.3.2.1 <i>Angular Second Moment</i>	102
4.3.2.2 <i>Contrast</i>	103
4.3.2.3 <i>Correlation</i>	103
4.3.2.4 <i>Energi</i>	104
4.4 Klasifikasi Sedimen Dasar Laut	105
4.4.1 <i>Angular Response Analysis</i>	105
4.4.2 <i>Deep Neural Network</i>	107
4.4.2.1 Klasifikasi Sedimen Dasar Laut dengan Input Batimetri dan Selisih Batimetri	107
4.4.2.2 Klasifikasi Sedimen Dasar Laut dengan input Batimetri dan Fitur Batimetri Multifrekuensi	110
4.4.2.3 Klasifikasi Sedimen Dasar Laut dengan input Batimetri, Selisih Batimetri dan Fitur Batimetri Multifrekuensi	111
4.4.2.4 Klasifikasi Sedimen Dasar Laut dengan input Batimetri, <i>Backscatter</i> Monospektral dan <i>Backscatter</i> Multispektral	114
4.4.2.5 Klasifikasi Sedimen Dasar Laut dengan input Batimetri, <i>Backscatter</i> , dan Fitur <i>Backscatter</i> Multispektral	119

4.4.2.6 Klasifikasi Sedimen Dasar Laut dengan input Batimetri, Selisih Batimetri, Fitur Batimetri, <i>Backscatter</i> Multispectral, Fitur <i>Backscatter</i>	120
4.5 Analisa Peningkatan Akurasi Klasifikasi Sedimen Dasar Laut	122
4.6 Analisa Peningkatan Akurasi dengan Peneliti Sebelumnya	125
<b>BAB 5 KESIMPULAN DAN SARAN</b>	129
5.1 Kesimpulan	129
5.2 Saran	129
<b>DAFTAR PUSTAKA</b>	131
<b>LAMPIRAN</b>	143
LAMPIRAN A Contoh Grain Size Distribution Curve	145
LAMPIRAN B Klasifikasi Sedimen in Situ	151
LAMPIRAN C Data Klasifikasi Sedimen dan Kedalaman	155
LAMPIRAN D Data Klasifikasi Sedimen dan Backscatter	159
LAMPIRAN E Data Klasifikasi Sedimen dan Selisih Kedalaman	163
LAMPIRAN F Coding DNN	171
<b>BIOGRAFI PENULIS</b>	225

*“Halaman ini sengaja dikosongkan”*

## DAFTAR GAMBAR

Gambar 2.1	Distribusi sumber sedimen di seluruh dunia	14
Gambar 2.2	Van Veen <i>grab sampler</i>	15
Gambar 2.3	Peta sebaran Sedimen dari data <i>grab sampler</i>	17
Gambar 2.4	<i>Gravity core</i>	17
Gambar 2.5	Respon kekasaran (kiri) dan kekerasan (kanan) sedimen dasar laut terhadap sinyal SBES	25
Gambar 2.6	Contoh hamburan balik yang bergantung pada sudut datang untuk berbagai jenis substrat pada 100 kHz, berdasarkan model hasil menggunakan	26
Gambar 2.7	Contoh hamburan balik yang bergantung pada sudut untuk pasir pada frekuensi yang berbeda	27
Gambar 2.8	Prinsip hamburan balik permukaan dasar	29
Gambar 2.9	Skema model BS berlapis dan model deteksi bawah. a) jejak MBES di dasar laut b) tampilan profil melintang media berlapis (dua lapis)	37
Gambar 2.10	Peta sedimen dasar Outer Thames Estuary dengan SSS	38
Gambar 2.11	<i>Tow-fish SSS</i>	39
Gambar 2.12	Prinsip SBES	40
Gambar 2.13	Lajur perum dan peta batimetri dari SBES	41
Gambar 2.14	Peta sedimen dasar laut dengan <i>backscatter</i> SBES	41
Gambar 2.15	Peta sebaran sedimen dasar dengan SBES	42
Gambar 2.16	Resolusi spasial <i>SBES</i> (Kearns, and Breaman, 2010)	43

Gambar 2.17	Prinsip MBES (Penrose, dkk., 2005)	44
Gambar 2.18	<i>Swath Multi Beam Echo Sounder</i> ( SeaBeam, 2000)	44
Gambar 2.19	Aplikasi MBES: (a) batimetri, (b) <i>backscatter</i> (c) <i>water column</i> (Colbo, 2014)	45
Gambar 2.20	Peta Sedimen Dasar Laut dengan MBES (Boulay, 2012)	46
Gambar 2.21	MBES multifrekuensi berbasis <i>ping by ping</i> (Brown, dkk., 2017 dan Brown, dkk., 2019)	47
Gambar 2.22	<i>Backscatter</i> MBES (a) multispektral dan (b) gabungan warna (Brown, dkk., 2017 dan Brown, dkk., 2019)	48
Gambar 2.23	Perbandingan perbedaan intensitas hamburan balik dalam satu lokasi survei antara mosaik multispektral (Brown, dkk., 2017 dan Brown, dkk., 2019)	48
Gambar 2.24	Skema struktur <i>Neural Network</i>	60
Gambar 2.25	Hubungan antara variabel penelitian ( <i>conceptual framework</i> )	66
Gambar 3.1	Lokasi penelitian	67
Gambar 3.2	Diagram alir metodologi penelitian	69
Gambar 3.3	Proses pengolahan data klasifikasi sedimen dasar laut	71
Gambar 3.4	Ukuran sedimen (kiri) dan segitiga <i>Sheppard</i> (kanan)	72
Gambar 3.5	Titik-titik kedalaman berdasarkan frekuensi (biru = 200 kHz, hijau = 250 kHz, orange = 300 kHz, merah = 350 kHz dan kuning = 400 kHz)	72
Gambar 3.6	<i>Patch test</i> untuk menghitung sudut roll, pitch dan yaw	73
Gambar 3.7	Editing data MBES (Deunf, et al, 2019)	73
Gambar 3.8	Kontur kedalaman frekuensi 400 kHz (kiri) dan 250 kHz (kanan)	74
Gambar 3.9	Selisih kedalaman frekuensi 250 kHz dengan 400 kHz	74

Gambar 3.10	Regresi linear x (jenis sedimen) dan y (selisih kedalaman)	75
Gambar 3.11	Intensitas <i>backscatter</i> 200 kHz (kiri), 300 kHz (tengah) dan 400 kHz (kanan)	75
Gambar 3.12	Korelasi antara ukuran sedimen (x) dengan kekuatan <i>backscatter</i> (y)	76
Gambar 4.1	Grafik nilai uji tempel (a) <i>pitch</i> , (b) <i>roll</i> , dan (c) <i>heading</i>	80
Gambar 4.2	Kepadatan data MBES multifrekuensi dan setiap frekuensi	81
Gambar 4.3	Model Batimetri Digital untuk masing-masing frekuensi	82
Gambar 4.4	Kontur kedalaman 2D masing-masing frekuensi	83
Gambar 4.5	Selisih batimetri antar frekuensi MBES multi frekuensi	85
Gambar 4.6	Kelebihan volume pengerukan jika $mc_0$ menggunakan $f_1$ dan $mc_{100}$ menggunakan $f_2$	87
Gambar 4.7	Kelebihan volume pengerukan jika $mc_0$ menggunakan $f_2$ dan $mc_{100}$ menggunakan $f_1$	87
Gambar 4.8	Kemiringan dasar laut area survei (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 350 kHz (e) 400 kHz	89
Gambar 4.9	Aspek fitur batimetri (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 350 kHz (e) 400 kHz	89
Gambar 4.10	Kelengkungan fitur batimetri (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 350 kHz (e) 400 kHz	90
Gambar 4.11	BPI fitur batimetri (a) 200 kHz (b) 250 kHz	91
Gambar 4.12	Kekasaran fitur batimetri (a) 200 kHz (b) 250 kHz	92
Gambar 4.13	Kekerasan fitur batimetri (a) 200 kHz (b) 250 kHz	93

Gambar 4.14	Distribusi sampel sedimen dasar laut di area survei	94
Gambar 4.15	Contoh hasil analisis sieveing dengan kurva distribusi ukuran butir	94
Gambar 4.16	Diagram segitiga <i>Sheppard</i> yang menunjukkan klasifikasi sedimen menurut tekstur butirannya	95
Gambar 4.17	Distribusi tipe sedimen dasar laut di area survei	96
Gambar 4.18	Klasifikasi sedimen dasar hasil interpolasi linear jenis sampel sedimen sampel <i>in situ</i>	96
Gambar 4.19	Data (a) batimetri dan mosaik <i>backscatter</i> (b) 200 kHz (c) 300 kHz dan (d) 400 kHz	98
Gambar 4.20	Overlai distribusi jenis sedimen dasar laut <i>in situ</i> dengan <i>backscatter</i>	98
Gambar 4.21	Mosaik <i>backscatter</i> multispektral (a) RGB234 (b) RGB243	100
Gambar 4.22	Intensitas hamburan balik dari tiga mosaik multispektral di sepanjang transek (a) RGB234 (b) Barat ke Timur (c) Utara ke Selatan	101
Gambar 4.23	<i>Angular Second Moment</i> (ASM) MBES untuk setiap frekuensi: (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 400 kHz (e) 450 kHz	102
Gambar 4.24	Kontras MBES untuk setiap frekuensi: (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 400 kHz (e) 450 kHz	103
Gambar 4.15	Korelasi untuk setiap frekuensi: (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 400 kHz (e) 450 kHz	104
Gambar 4.26	<i>Energy</i> (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 400 kHz (e) 450 kHz	104
Gambar 4.27	Klasifikasi sedimen dasar dengan metode ARA (a) 200 kHz (b) 300 kHz (c) 400 kHz	105
Gambar 4.28	Overlai 74 titik sampel sedimen di klasifikasi ARA	106

Gambar 4.29	Model pengklasifikasi <i>Deep Neural Network</i>	108
Gambar 4.30	Hasil klasifikasi sedimen dasar laut dengan input batimetri dan selisih batimetri multifrekuensi	109
Gambar 4.31	Hasil prediksi sebaran sedimen dasar dengan input batimetri dan fitur batimetri	111
Gambar 4.32	Deep Neural Network Model Classifier dengan 45 neuron	112
Gambar 4.33	Prediksi sedimen dasar laut dengan DNN di area survai	113
Gambar 4.34	Klasifikasi sedimen dasar laut menggunakan DNN untuk setiap frekuensi (a-e) dan multifrekuensi dengan input batimetri dan <i>backscatter</i>	115
Gambar 4.35	Klasifikasi sedimen dengan input batimetri, <i>backscatter</i> , dan fitur <i>backscatter</i> multispektral	119
Gambar 4.36	Klasifikasi sedimen dengan input batimetri, selisih batimetri, fitur batimetri multifrekuensi, backscatter, dan fitur backscatter multispektral	121

*“Halaman ini sengaja dikosongkan”*

## **DAFTAR TABEL**

Tabel 1.1	Daftar metode dan input data penelitian yang telah dilakukan oleh peneliti sebelumnya	10
Tabel 2.1	Ukuran Butir Sedimen (Wentworth, 1922)	14
Tabel 2.2	Review hasil penelitian dari peneliti sebelumnya terkait dengan penggunaan MBES multifrekuensi dalam klasifikasi sedimen dasar laut	52
Tabel 2.3	Matriks konfusi diskriminasi	61
Tabel 2.4	Klasifikasi nilai <i>chohen's kappa</i> (Cohen, 1960)	64
Tabel 4.1	Volume keruk ( <i>cut and fill</i> ) selisih kedalaman antar frekuensi	86
Tabel 4.2	Pengaruh penggunaan frekuensi yang berbeda terhadap volume pengeringan dalam 1 ha	88
Tabel 4.3	Matriks konfusi antara data in situ dan DNN dengan input batimetri dan selisih batimetri	110
Tabel 4.4	Matriks konfusi prediksi sedimen dasar laut dengan metode DNN dan input batimetri dan fitur batimetri	112
Tabel 4.5	Matriks konfusi klasifikasi sedimen dasar laut dengan DNN input batimetri, selisih batimetri dan fitur batimetri	114
Tabel 4.6	Matriks Konfusi Klasifikasi Sedimen Dasar Laut dengan DNN input batimetri dan backscatter 200 kHz	116
Tabel 4.7	Matriks Konfusi Klasifikasi Sedimen Dasar Laut dengan DNN input batimetri dan backscatter 250 kHz	116
Tabel 4.8	Matriks Konfusi Klasifikasi Sedimen Dasar Laut dengan DNN input batimetri dan backscatter 300 kHz	117
Tabel 4.9	Matriks Konfusi Klasifikasi Sedimen Dasar Laut dengan DNN input batimetri dan backscatter 350 kHz	117
Tabel 4.10	Matriks Konfusi Klasifikasi Sedimen Dasar Laut dengan DNN input batimetri dan backscatter 400 kHz	118

Tabel 4.11	Matriks Konfusi Klasifikasi Sedimen Dasar Laut dengan DNN input batimetri dan backscatter multispektral (semua frekuensi)	118
Tabel 4.12	Ringkasan akurasi dan koefisien Kappa klasifikasi sedimen dengan input batimetri dan backscatter monospektral dan multispektral	119
Tabel 4.13	Ringkasan akurasi dan koefisien Kappa klasifikasi sedimen dengan input batimetri dan backscatter monospektral dan multispektral	120
Tabel 4.14	Matriks Konfusi Klasifikasi Sedimen dengan input batimetri, selisih batimetri, fitur batimetri multifrekensi, backscatter, dan fitur backscatter multispektral	121
Tabel 4.15	Peningkatan akurasi dan koefisien Kappa dengan input data yang berbeda	124
Tabel 4.16	Ringkasan perbedaan penelitian ini dengan peneliti sebelumnya	127

## DAFTAR SINGKATAN

ARA	: <i>Angular Range Analysis</i>
ARC	: <i>Angular Response Curve</i>
ASM	: <i>Angular Second Moment</i>
BPI	: <i>Bathymetric Position Indeks</i>
BTM	: <i>Benthic Terrain Model</i>
CRF	: <i>Conditional Random Field</i>
DNN	: <i>Deep Neural Network</i>
GJT	: Gresik Jasa Tama
GLCM	: <i>Gray Level Co-Occurance Matrix</i>
GMM	: <i>Gaussian Mixture Model</i>
GNSS	: <i>Global Navigation Satellite System</i>
IL	: <i>Intensity Level</i>
IMU	: <i>Inertial Motion Unit</i>
LAR	: <i>Local Angular Response</i>
LBM	: <i>Layer Backscatter Model</i>
LWS	: <i>Low Water Spring</i>
MBES	: <i>Multibeam Echosounder</i>
ML	: <i>Machine Learning</i>
MLP	: <i>Multi Layer Perceptron</i>
NN	: <i>Neural Network</i>
OA	: <i>Overall Accuracy</i>
OBIA	: <i>Object Base Image Analysis</i>

PA	<i>: Producer's Accuracy</i>
PCA	<i>: Principal Component Analysis</i>
RF	<i>: Random Forest</i>
RFDT	<i>: Random Forest Decision Tree</i>
RMS	<i>: Root Mean Square</i>
RTK	<i>: Real Time Kinematic</i>
SBES	<i>: Singlebeam Echosounder</i>
SL	<i>: Source Level</i>
SNR	<i>: Signal Noise to Ratio</i>
Sonar	<i>: Sound Navigation and Ranging</i>
SSS	<i>: Side Scan Sonar</i>
SVM	<i>: Support Vector Machine</i>
TL	<i>: Transmission Lose</i>
TRI	<i>: Terrain Ruggedness Indeks</i>
TVU	<i>: Total Vertical Uncertainty</i>
THU	<i>: Total Horizontal Uncertainty</i>
UA	<i>: User's Accurcay</i>

## DAFTAR ISTILAH

<i>angular response curve</i>	kurva yang menggambarkan kekuatan hamburan balik (sebagai fungsi dari sudut datang di dasar laut)
<i>angular range analysis</i>	Penggunaan informasi intensitas hamburan balik sudut untuk memperkirakan jenis sedimen serta sifat sedimen lainnya, seperti ukuran butir sedimen, indeks impedansi, dan heterogenitas volume.
<i>angle second moment</i>	pola fitur yang digunakan untuk mengukur keseragaman gambar, yaitu ketika piksel memiliki nilai yang sangat mirip, ASM akan menjadi signifikan
<i>aspect</i>	menggambarkan arah azimut dari kemiringan paling curam melalui titik-titik di jendela analisis hamburan balik (pantulan) gelombang, partikel, atau sinyal kembali ke arah asalnya
<i>backscatter</i>	
<i>backscatter multispektral</i>	Backscatter yang merupakan gabungan ( <i>composite</i> ) dari beberapa frekuensi
<i>batimetri</i>	dikenal juga dengan topografi dasar air yaitu kontur kedalaman air (laut, sungai, waduk) relatif terhadap permukaan laut (referensi) yang digunakan.
<i>bathimetric position indeks</i>	membandingkan ketinggian setiap sel dalam model ketinggian digital dengan ketinggian rata-rata lingkungan tertentu di sekitar sel tersebut
<i>correlation</i>	fitur korelasi menunjukkan ketergantungan linier dari nilai tingkat abu-abu dalam matriks kejadian bersama

<i>contrast</i>	mengukur intensitas atau variasi tingkat abu-abu antara piksel referensi dan tetangganya
<i>curvature</i>	Menjelaskan kurva paling curam dari konveksitas permukaan atau profil melalui lingkungan sel yang ditentukan
<i>deep neural network</i>	kelas jaringan saraf yang terdiri dari beberapa lapisan neuron buatan yang saling berhubungan, terinspirasi oleh struktur dan fungsi otak manusia
<i>energy</i>	energi juga berarti keseragaman. Semakin homogen gambarnya, semakin besar nilainya
<i>GNSS</i>	Global Navigation Satellite System adalah suatu sistem satelit yang terdiri dari konstelasi satelit yang dapat menyediakan informasi terkait waktu dan lokasi, melalui singal dalam beberapa frekuensi secara terus menerus yang terus mengelilingi bumi
<i>grain size</i>	diameter butiran sedimen tunggal atau partikel yang mengalami litifikasi pada batuan klastik.
koefisien kappa	digunakan untuk mengevaluasi seberapa baik kinerja klasifikasi dibandingkan dengan hanya menetapkan nilai secara acak, yaitu apakah klasifikasi tersebut menghasilkan kinerja yang lebih baik daripada acak.
<i>machine learning</i>	pembelajaran mesin (ML) adalah bidang studi kecerdasan buatan yang berkaitan dengan pengembangan dan studi algoritma statistik yang dapat belajar dari data dan menggeneralisasi data yang tidak terlihat sehingga melakukan tugas tanpa instruksi eksplisit.

MBES multifrekuensi	MBES yang mampu mengukur dengan lebih satu mode frekuensi baik secara ping by ping maupun tidak.
<i>mosaic backscatter</i>	istilah umum untuk a gambar georeferensi skala abu-abu dari reflektivitas dasar laut yang warna dan teksturnya mewakili mengenai sifat dan geomorfologi dasar laut;
<i>multibeam echosounder</i>	salah satu jenis sonar yang digunakan untuk memetakan dasar laut yang memancarkan gelombang akustik dalam bentuk kipas di bawah transceivernya (transducer).
<i>neural network</i>	jaringan saraf adalah sekelompok unit yang saling berhubungan yang disebut neuron yang mengirimkan sinyal satu sama lain.
<i>sound navigation and ranging</i>	teknik yang menggunakan perambatan suara (biasanya di bawah air, seperti pada navigasi kapal selam) untuk bernavigasi, mengukur jarak (ranging), berkomunikasi dengan atau mendekripsi objek di atas atau di bawah permukaan. perairan, seperti kapal lainnya
<i>overall accuracy</i>	probabilitas bahwa sesuatu akan diklasifikasikan dengan benar melalui suatu tes; yaitu, jumlah positif sebenarnya ditambah negatif sebenarnya dibagi dengan jumlah total individu yang dites.
<i>patch test</i>	pendekatan sistematis yang digunakan mengkalibrasi berbagai sensor yang digunakan dalam akuisisi data multibeam
<i>producer's accuracy</i>	dihitung dengan membagi jumlah total titik klasifikasi yang cocok dengan data referensi dengan jumlah total titik referensi untuk kelas

	tersebut. Nilai-nilai ini merupakan nilai negatif palsu dalam hasil klasifikasi.
<i>roughness</i>	ukuran kompleksitas struktural yang diwakili oleh rasio luas permukaan terhadap luas bidang
<i>ruggedness</i>	Menggambarkan perbedaan kedalaman antar sel yang saling berdekatan
<i>side scan sonar</i>	salah satu jenis sonar yang digunakan untuk secara efisien membuat gambar ( <i>side imaging</i> ) area dasar laut yang luas.
<i>slope</i>	turunan pertama dari batimetri yang menunjukkan arah dan kecuraman dari permukaan dasar laut
<i>singlebeam echosounder</i>	salah satu jenis sonar yang digunakan untuk mengukur kedalaman air yang menggunakan pancaran tunggal sebagai pengirim dan penerima sinyal gelombang suara ( <i>transducer</i> ).
<i>sheppard triangle</i>	diagram segitiga yang digunakan untuk menentukan kelas sedimen lunak
<i>signal noise to ratio</i>	rasio sinyal terhadap kebisingan adalah ukuran yang digunakan dalam sains dan teknik yang membandingkan tingkat sinyal yang diinginkan dengan tingkat kebisingan latar belakang.
<i>sound intensity</i>	Intensitas bunyi, disebut juga intensitas akustik, didefinisikan sebagai daya yang dibawa gelombang bunyi per satuan luas dengan arah tegak lurus terhadap luas tersebut.
<i>sound level</i>	tingkat suara mengacu pada berbagai pengukuran logaritmik dari getaran yang terdengar
<i>sound intensity level</i>	Tingkat intensitas suara (SIL) atau tingkat intensitas akustik adalah tingkat (kuantitas

	logaritmik) intensitas suara relatif terhadap nilai referensi.
<i>sound pressure level</i>	Tingkat tekanan suara (SPL) atau tingkat tekanan akustik (APL) adalah ukuran logaritmik dari tekanan efektif suatu suara relatif terhadap nilai referensi.
<i>target strength</i>	Kekuatan target adalah ukuran luas target sonar, yang biasanya diukur sebagai jumlah desibel.
<i>transmission loss</i>	Kerugian transmisi (TL) secara umum menggambarkan akumulasi penurunan intensitas energi bentuk gelombang ketika gelombang merambat keluar dari sumber, atau ketika merambat melalui area tertentu atau melalui jenis struktur tertentu.
<i>user's accuracy</i>	keakuratan dari sudut pandang pengguna, yang memberi tahu penggunaan seberapa sering kelas di peta akan benar-benar hadir di lapangan dan dihitung dengan mengambil jumlah klasifikasi yang benar untuk kelas tertentu dan membaginya dengan total baris

*“Halaman ini sengaja dikosongkan”*

# **BAB 1**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Wilayah pesisir merupakan wilayah yang unik, dimana wilayah pesisir merupakan tempat bertemu daratan dan lautan (Kay dan Alder, 2005) yang bersifat dinamis, bervariasi terhadap ruang dan waktu. Di wilayah pesisir ada interaksi yang sangat kuat antara daratan dan lautan, seperti area pantai, rawa-rawa, hutan mangrove, terumbu karang, tambak, estuari, sungai dan area lainnya. Peralihan antara darat dan laut akan menghasilkan ekosistem yang beragam dan produktif, yang secara historis berkontribusi pada kesejahteraan manusia. Wilayah pesisir juga mempunyai nilai ekonomi yang sangat tinggi. Selain kaya akan aneka ragam hayati, penggunaan wilayah pesisir (pantai) sebagai wilayah perdagangan antar negara, antar pulau dan antar daerah.

Wilayah pesisir telah dikenal sebagai daya tarik manusia selama ribuan tahun dan terus berlanjut hingga saat ini. Banyak aktivitas manusia terkonsentrasi di kawasan pesisir ini. Hal ini dibuktikan dengan banyak kota besar di dunia dengan penduduk yang padat berkembang di kawasan ini. Aktivitas di wilayah pesisir membutuhkan peta laut untuk mendukung kegiatan perekonomian dan lingkungan di pesisir. Peta laut memainkan peran penting terkait dengan data dan informasi kelautan, yang menggambarkan konfigurasi dasar laut dan garis pantai (NOAA, 1997). Peta laut berisi informasi grafis dari laut dan daerah pesisir yang meliputi kedalaman laut (batimetri) dan fitur laut baik alami maupun buatan. Fitur laut alami meliputi garis pantai, navigasi alam, pasang surut dan arus laut. Sedangkan fitur buatan meliputi alat bantu navigasi buatan, struktur buatan manusia seperti pelabuhan, bangunan, jetty, dan jembatan (IHO, 2005). Selain itu, informasi yang tidak kalah pentingnya yang harus ada dalam peta laut adalah karakteristik sedimen dasar laut (Garlan, dkk., 2018).

Sedimen adalah bahan utama pembentuk morfologi (topografi dan batimetri) pesisir. Sedimen berasal dari fragmentasi (pemecahan) batuan. Pemecahan tersebut terjadi karena pelapukan (*weathering*) yang dapat berlangsung

secara fisik, kimiawi, atau biologis (Hutabarat dan Evans, 2000). Berubahnya morfologi pesisir/estuari terjadi sebagai akibat berpindahnya sedimen yang berlangsung melalui mekanisme erosi, pengangkutan (transpor) dan pengendapan (deposisi). Sedimen yang dipindahkan adalah sedimen yang terletak pada permukaan dasar perairan. Sedimentasi di lingkungan pantai berasal dari kehadiran sedimen yang berasal dari daratan dan pada dasarnya merupakan faktor utama dalam membentuk pantai. Sedimentasi berkaitan erat dengan agen geomorfik yang bekerja didalamnya. Agen geomorfik utama yang menyebabkan atau mempengaruhi proses dan dinamika perairan pantai adalah gelombang, arus dan angin (Lanuru dan Suwarni, 2011; Earle, 2015).

Meningkatnya aktivitas manusia di lingkungan pesisir dan laut, sedimen dasar laut mempunyai peran yang sangat penting untuk pengembangan dan pengelolaan wilayah pesisir dan laut secara berkelanjutan. Untuk mengetahui sedimen yang dominan suatu perairan, dilakukan pengumpulan sampel sedimen yang mengendap di dasar perairan. Peralatan yang sering digunakan adalah grab sampler dan corer (IAEA, 2003). Kelebihan metode ini adalah mendapatkan informasi klasifikasi sedimen dasar yang akurat sampai dengan persentase ukuran butiran sedimen yang diambil. Metode ini mempunyai beberapa kelemahan (Berthold, dkk, 2017) yaitu pertama, membutuhkan waktu yang lama dan biaya yang sangat mahal untuk mendapatkan data dengan resolusi spasial yang tinggi. Yang kedua, keterbatasan dalam pengambilan sampel untuk lokasi yang dalam dan sangat dalam. Yang terakhir, hasil peta klasifikasi sedimen dasarnya mempunyai resolusi spasial yang rendah.

Metode lain yang digunakan untuk pemetaan sedimen dasar laut adalah dengan menggunakan gelombang akustik seperti *single beam echosounder* (SBES), *side scan sonar* (SSS) dan *multi beam echosounder* (MBES). Metode akustik jauh lebih efisien dan efektif untuk pemetaan sedimen dengan area luas dan resolusi spasial yang tinggi. SBES merupakan teknologi yang memanfaatkan gelombang akustik untuk menentukan kedalaman laut dan pertama kali digunakan di pertengahan tahun 1900-an (IHO, 2005). Prinsip SBES ini adalah *transmitter* memancarkan gelombang suara ke dasar laut dan dipantulkan kembali ke *receiver*. Kedalaman diturunkan dari waktu yang ditempuh gelombang akustik saat

dipancarkan dari transmitter dan diterima kembali oleh receiver. Interaksi gelombang akustik yang dipancarkan ke dasar laut akan mengalami pantulan (*reflection*), pancaran (*transmission*) dan hamburan (*scattering*) (IHO, 2005). Gelombang suara yang dipantulkan tersebut dapat diferensialkan menjadi fitur sedimen dasar yang berupa informasi spektral yang dapat digunakan untuk klasifikasi sedimen dasar laut. Informasi ini paling tidak memberi informasi fitur sedimen dasar yaitu kekerasan (*hardness*) dan kekasaran (*roughness*) (Burns, dkk., 1989; Lied, dkk., 2004). Ada beberapa faktor yang mempengaruhi kekuatan intensitas gelombang akustik yaitu jarak, sudut, dan target. Semakin jauh jarak tranduser ke target maka semakin lemah intensitasnya. Semakin ke tepi sudut datangnya sinyal ke target maka semakin kecil intensitasnya. Permukaan yang keras akan memantulkan hampir semua energi sehingga akan menghasilkan tanda yang jelas. Permukaan yang lunak akan menyebabkan energi suara yang dipancarkan akan ditembuskan dan selanjutnya energi balik akan tersebar dari waktu ke waktu karena dikembalikan dari lapisan yang berbeda dalam sedimen.

Metode akustik lain yang dapat digunakan untuk pemetaan sedimen dasar laut adalah *Side Scan Sonar* (SSS). SSS merupakan instrumen pencitraan dasar laut (*seabed imaging*) (Atallah, dkk, 2002) yang mudah diinterpretasi dengan cakupan area yang luas. Umumnya alat ini ditarik dari belakang kapal (*tow fish*) dengan transduser mengarahkan energi dari sudut kanan jalur kapal, dan miring ke dasar laut. Pace dan Gao (1988) dan Tamsett (1993) menggunakan spektrum daya yang terkait dengan sifat hamburan balik (*backscatter*) sedimen untuk menentukan dasar klasifikasi sedimen. SSS memancarkan gelombang akustik tidak seperti SBES yang hanya satu pancaran satu titik, akan tetapi SSS memancarkan gelombang akustik dalam bentuk bidang (*swath*). Dengan demikian hasil survei SSS jauh lebih cepat dibandingkan dengan SBES. Akan tetapi SSS mempunyai kelemahan yaitu pengukuran yang dilakukan tidak mempunyai geometri insonifikasi yang sama satu sama lain (Clarke, 1994). Artinya SSS tidak memiliki kapasitas untuk memasukkan informasi tentang topografi dasar, sehingga membutuhkan data batimetri tambahan untuk koreksi.

Perkembangan teknologi terkini dalam pemetaan batimetri dan klasifikasi sedimen dasar laut adalah *Multi Beam Echo Sounder* (MBES). Tidak seperti SBES

yang hanya mampu mengambil data per titik, MBES mampu melakukan survei batimetri dengan cakupan penuh (*full coverage*) (IHO, 2005; IHO, 2008). Seperti metode akustik yang lain, SBES dan SSS, dengan memanfaatkan *backscatter*, MBES dapat digunakan untuk pemetaan klasifikasi sedimen dasar laut. Menurut Brisette dan Clarke (1999), kelebihan MBES adalah kemampuannya untuk menghasilkan data batimetri secara kuantitatif yang jauh lebih dapat diterima untuk klasifikasi dan pemrosesan citra (*image processing*). Beberapa peneliti telah menggunakan *backscatter MBES* untuk klasifikasi sedimen dasar (Medialdea, 2007; Fonseca, dkk, 2008; Simkoeei, dkk., 2009; Tang, dkk 2015; Leitao, dkk., 2016; Esposito dan Kulpa, 2018; Zakariya, dkk., 2018). Ada beberapa metode yang digunakan untuk mengklasifikasi sedimen dasar dengan *backscatter MBES* yaitu *Bayesian* (Gaida, dkk., 2018; Gaida, dkk., 2019; Koop, dkk., 2019). Metode lain yaitu *neural network* (Zhou dan Chen, 2005; Marsh dan Brown, 2009; Tegowskia, dkk., 2011), metode terselia (*supervised*) dan tidak terselia (*unsupervised*) (Galparsoro, dkk., 2015; Diesing, dkk., 2016). Peneliti lainnya mencoba untuk menggabungkan data *backscatter* dengan data batimetri (Kagesten, 2008), penggalian data visual (*visual data mining*) (Ahmed dan Demsar, 2010) dan mengkombinasikan dengan fitur morfologi (de Falco, dkk., 2010). Metode *Local Angular Response (LRA)* (Haniotis, dkk., 2012), *Angular Range Analysis (ARA)* (Samsudin dan Hasan, 2017; Ridha, dkk., 2019) dan *Object Based Image Analysis (OBIA)* (Jenowski, dkk., 2018) diusulkan oleh beberapa peneliti untuk klasifikasi sedimen dasar laut. Kombinasi *Pixel Based (PB)* dan *Object Based (OB)* (Ierodiaconou, dkk., 2018), *least squares cubic spline approximation (LS-CSA)* (Simkoeei, dkk., 2019) juga telah diusulkan oleh beberapa peneliti lain.

Metode *backscatter MBES* untuk memperbaiki kualitas hasil klasifikasi adalah *backscatter MBES multi swath* (Nguyen, 2018), *backscatter MBES multi-scale* (Misiuk, dkk., 2018) dan *backscatter MBES multi spectral* (Clarke, 2015; Brown, dkk., 2017; Feldens, dkk, 2018; Gaida, dkk., 2018; Brown, dkk., 2019). MBES multi frekuensi merupakan alat yang dapat digunakan untuk melakukan survei *ping to ping basis* yaitu memancarkan sinyal gelombang akustik secara bergantian dari frekuensi yang satu dengan frekuensi yang lain. Gaida, dkk (2018) menggunakan *backscatter MBES* multi frekuensi (*MBES R2Sonic 2026*) dengan

tujuan untuk membedakan respon akustik sedimen dasar laut yang lebih baik daripada menggunakan data frekuensi tunggal. Penelitiannya di Bedford Basin dan Patricia Bay, Kanada dengan metode *Bayesian* menunjukkan perbandingan kualitatif dan interpretasi geologis menggunakan hamburan balik multi-frekuensi.

Feldens, dkk (2018) menggunakan *backscatter MBES Norbit iWBMS* multi frekuensi dengan frekuensi 200 kHz, 400 kHz dan 600 kHz untuk memperbaiki interpretasi sedimen dasar laut di *North Sea*. Hasil penelitiannya menunjukkan bahwa penggunaan frekuensi yang paling rendah (200 kHz) akan terjadi peningkatan sensitifitas terhadap perubahan komposisi dasar laut dalam pengaturan landas kontinen sedimen. Mosaik *backscatter* multi frekuensi ini dapat memperbaiki interpretasi fitur sedimen dasar yang halus. Namun, untuk aplikasi praktis data multi-frekuensi untuk pemetaan habitat, masih ada kekurangan informasi untuk menginterpretasikan banyak fitur hambur balik dari dasar laut. Costa (2018) mengklaim bahwa *backscatter* multispektral merupakan alat yang sangat efektif untuk aplikasi yang fokus pada sedimen dasar yang halus. Hasil penelitiannya menunjukkan bahwa hamburan balik multispektral dapat meningkatkan diskriminasi bawah permukaan dasar.

Brown, dkk (2017) dan Brown, dkk., (2019) dengan menggunakan *MBES R2Sonic 2026* yang mampu menghasilkan *backscatter* 3 (tiga) frekuensi sekaligus yaitu 100 kHz, 200 kHz dan 400 kHz dalam sekali survei. Hasil penelitiannya menunjukkan bahwa mosaik *backscatter* *MBES* antar frekuensi mampu mempertegas klasifikasi sedimen dasar laut di Bedford Basin, Nova Scotia, Kanada. Inovasi ini menawarkan potensi yang luar biasa untuk aplikasi survei geologi dasar laut dan pemetaan habitat.

Gaida, dkk (2020) meneliti perbedaan sedimen dasar yang halus dengan menggunakan *MBES* multispektral (90 – 450 kHz). Hasil penelitiannya menunjukkan bahwa di sedimen halus yang berupa lumpur terdapat perbedaan kedalaman sampai 60 cm antara frekuensi yang terendah (90 kHz) dan frekuensi yang tertinggi (450 kHz). Sedangkan variasi *backscatter* di sedimen lumpur untuk frekuensi rendah (90 kHz) mencapai 15dB, akan tetapi untuk frekuensi tinggi mempunyai variasi yang kecil. Simulasi *MBES* untuk deteksi dasar laut menunjukkan bahwa batimetri yang diukur pada frekuensi tertinggi dan terendah

dapat digunakan untuk menentukan ketebalan lapisan tipis (~20 cm). Namun, dengan lapisan yang semakin meningkat ketebalannya, deteksi bawah menjadi lebih sensitif terhadap sudut datang dan sifat sedimen. Gaida, dkk (2020) menyarankan untuk menganalisis *backscatter* multi frekuensi yang dikombinasikan dengan perbedaan batimetri antar frekuensi untuk memastikan interpretasi dan klasifikasi yang benar atas data *backscatter* multi-frekuensi.

Kontradiktif dengan hasil penelitian sebelumnya, Vondervoort dan Lekkerkekk (2021) menyimpulkan bahwa penggunaan *backscatter* MBES multispektral tidak mampu memperbaiki karakteristik sedimen dasar laut dibandingkan dengan data monospektral dan sedimen lunak. Penelitian ini menggunakan R2Sonic 2024 dengan frekuensi 200 kHz, 400 kHz dan 700 kHz. Metode yang digunakan untuk klasifikasi sedimen adalah *Angle Range Analysis (ARA)*. Selain itu, penggunaan frekuensi 700 kHz tidak cocok karena saturasi gambar (citra) yang dihasilkan berlebihan.

Karakteristik sedimen dasar laut sangat penting untuk keselamatan kapal, terutama saat kapal ingin berhenti (sandar) di tengah laut dengan cara membuang jangkar. Karakteristik sedimen dasar laut juga penting untuk konstruksi (pipa gas dan minyak, kabel listrik, struktur anjungan, optik dan telekomunikasi,) dan lingkungan (habitat bentik, pengangkutan sedimen, material penggerukan, dan pembuangan limbah). Lebih jauh lagi, eksplorasi lautan oleh manusia yang semakin intensif telah menyebabkan meningkatnya permintaan akan peta informasi dasar laut yang akurat. Masalahnya adalah belum tersedianya peta laut yang memuat informasi sedimen dasar laut yang diperlukan dan lengkap, atau peta sedimen dasar laut yang lengkap dan akurat. Secara umum penelitian yang terkait dengan klasifikasi sedimen dasar laut dengan menggunakan MBES multifrekuensi terfokus pada metode klasifikasi. Metode yang paling sederhana yaitu mosaik dan *Angular Range Analysis (ARA)* yang telah disediakan oleh *software-software* komersial yang beredar saat ini. Akhir-akhir ini digunakan metode klasifikasi yang berbasiskan pada data statistik dan *machine learning* seperti *bayesian*, *random forest*, *gaussian mixture model* dan lainnya.

Gaida, dkk (2020), menyarankan penelitian lebih lanjut terkait dengan penambahan parameter selisih kedalaman antar frekuensi dan *backscatter* multi

frekuensi untuk memastikan interpretasi dan klasifikasi yang benar atas data *backscatter* multi-frekuensi. Oleh karena itu, penelitian ini akan mengusulkan peningkatan kualitas klasifikasi sedimen dasar laut di perairan pesisir dengan menggunakan selisih batimetri dan *backscatter MBES* multi frekuensi. Harapannya ada korelasi positif antara selisih batimetri (ketebalan sedimen) dengan intensitas hamburan balik sedimen dasar laut. Dengan demikian klasifikasi sedimen dasar laut yang dihasilkan dari MBES multispektral kualitasnya (kedekatan sedimen dasar dan ketelitian hasil klasifikasinya) akan meningkat secara signifikan.

## 1.2 Permasalahan

Dalam sub bab sebelumnya telah dijelaskan bahwa diperlukan peta sedimen dasar laut di perairan pesisir dengan cepat dan akurat untuk keperluan rekayasa maupun lingkungan. Oleh karena itu untuk memenuhi hal-hal tersebut disusunlah perumusan masalah dalam penelitian ini sebagai berikut:

1. Bagaimana perbedaan kedalaman yang dihasilkan oleh satu frekuensi dengan frekuensi lainnya dalam survei yang bersamaan dengan menggunakan MBES multifrekuensi berbasis *ping by ping*?
2. Sejauh mana perbedaan antara hasil klasifikasi sedimen dengan menggunakan *backscatter* monospektral dan multispektral MBES?
3. Seberapa besar peningkatan akurasi klasifikasi sedimen dasar laut dengan penggunaan selisih data batimetri dan *backscatter* multispektral terhadap akurasi klasifikasi sedimen dasar yang hanya menggunakan data batimetri dan *backscatter* monospektral?

## 1.3 Tujuan

Target dari penelitian ini adalah untuk menyediakan peta klasifikasi dan distribusi sedimen dasar laut di perairan dangkal (*shallow water*). Oleh karena itu, untuk memperoleh target tersebut, maka penelitian ini mempunyai beberapa tujuan sebagai berikut:

1. Menganalisa perbedaan kedalaman yang dihasilkan oleh survei batimetri dengan menggunakan MBES multi frekuensi dari satu frekuensi dengan frekuensi yang lain.

2. Menganalisa data *backscatter* MBES monospektral dan multi spektral untuk mengklasifikasi sedimen dasar laut di perairan dangkal yang didukung dengan data sedimen dasar laut secara *in situ*.
3. Menganalisa peningkatan akurasi klasifikasi sedimen dasar laut dengan menggunakan data selisih batimetri dan *backscatter* multispektral terhadap akurasi klasifikasi sedimen dengan data batimetri dan *backscatter* monospektral.

#### **1.4 Manfaat**

Hasil penelitian dalam disertasi ini nantinya diharapkan dapat menambah khasanah baru dalam ilmu pengetahuan di bidang pemetaan batimetri dan pemetaan sedimen dasar laut yang cepat dan akurat. Selain itu, hasil penelitian ini juga dapat digunakan sebagai referensi dalam melaksanakan riset aplikasi yang terkait dengan penggunaan data batimetri dan *backscatter* MBES multi frekuensi untuk klasifikasi sedimen dasar laut di perairan dangkal (pesisir). Sehingga kontribusi penelitian ini nantinya dapat digunakan sebagai salah satu alternatif metode yang digunakan oleh *software* pengolahan data untuk meningkatkan kualitas klasifikasi sedimen dasar laut dengan menggunakan data MBES multifrekuensi. Selain itu hasil penelitian ini juga bisa digunakan sebagai acuan bagi pemangku kepentingan dalam bidang klasifikasi sedimen dasar laut.

#### **1.5 Orisinalitas dan Kontribusi Penelitian**

Hasil dari penelitian ini merupakan peta klasifikasi dan sebaran sedimen dasar laut di perairan pesisir dengan menggunakan data *backscatter* dan selisih batimetri MBES multi frekuensi. Selama ini, beberapa peneliti (Tabel 1.1) menggunakan parameter yang digunakan untuk menentukan klasifikasi sedimen dasar laut dengan data MBES yaitu:

- batimetri *single* frekuensi (Koop dkk., 2021),
- *backscatter* monospektral (Ahmed dan Demsar, 2013; Gavazzi dkk., 2017; Solikin dkk., 2018; Nguyen dkk., 2018; Ji dkk., 2020; Trzcinska dkk., 2021; Zhao dkk., 2021),
- batimetri *single* frekuensi dan *backscatter* monospektral (Wan dkk., 2022; Zhang dkk. 2022; Zhu dkk., 2021),

- *backscatter* multispektral (Clarke, 2015; Brown dkk., 2017; Feldens dkk., 2018; Gaida dkk., 2018; Buscombe and Grams, 2018; Brown dkk., 2019; Tegowsky, 2019; Vondervoort dan Lekkerker, 2021; Runya, dkk, 2021; Menandro dkk., 2022),
- batimetri single frekuensi dan *backscatter* multispektral (Brown dan Varma, 2018; Mertikas & Karanzalos, 2020, Janowsky, 2018; Zakariya dkk, 2018).

Orisinalitas dalam penelitian ini adalah peningkatan kualitas klasifikasi sedimen dasar laut secara kuantitatif dengan menggunakan data MBES multifrekuensi. Data MBES multifrekuensi yang terdiri dari data batimetri dan *backscatter* dikombinasikan satu sama lain. Data batimetri, selisih batimetri antar frekuensi, fitur batimetri multifrekuensi, *backscatter*, dan fitur *backscatter* multispektral digunakan sebagai input mode yang digunakan yaitu *deep neural network*. *Baseline* atau referensi yang digunakan sebagai nilai awal akurasi adalah nilai *overall accuracy* yang diperoleh dari data *backscatter* dengan metode *angular response curve* yang digunakan oleh software komersial yang ada saat ini.

Hasil dari penelitian ini menunjukkan bahwa klasifikasi sedimen dasar laut dengan metode *deep neural network* (DNN) dan input data batimetri, selisih batimetri dan fitur batimetri multifrekuensi mempunyai nilai *overall accuracy* yang paling tinggi (71,9%) dibandingkan dengan input data yang lain. Input data *backscatter* multispektral hanya menghasilkan akurasi 51,4%. Input semua data yaitu batimetri, selisih batimetri, fitur batimetri multifrekuensi, *backscatter* dan fitur *backscatter* multispektral hanya menghasilkan *overall accuracy* sebesar 62,2%.

Kontribusi penelitian ini adalah penggunaan data batimetri, selisih batimetri dan fitur batimetri multifrekuensi MBES menghasilkan klasifikasi sedimen dasar laut dengan akurasi yang lebih tinggi dibandingkan dengan penggunaan data batimetri, *backscatter* dan fitur *backscatter* multispektral. Hasil ini akan memberi dampak yang besar bagi para pemangku kepentingan khususnya para praktisi dalam pemetaan klasifikasi sedimen dasar laut. Berdasarkan hasil penelitian ini, pemetaan sedimen dasar laut hanya membutuhkan data batimetri multifrekuensi dan tidak membutuhkan data *backscatter*. Selanjutnya data batimetri multifrekuensi diturunkan menjadi data selisih batimetri dan fitur batimetri

multifrekuenси sebagai input DNN untuk klasifikasi sedimen dasar laut. Bagi para peneliti, hasil penelitian ini dapat dijadikan sebagai acuan untuk penelitian lanjutan dengan mengubah parameter yang lain seperti kedalaman, variasi topografi, variasi jenis sedimen dasar laut dan variasi lokasi (lintang dan bujur) yang berbeda.

Tabel 1.1 Daftar metode dan input data penelitian yang telah dilakukan oleh peneliti sebelumnya

No	Metode	Peneliti	Input Data
1	Mosaic	Clarke, 2015; Brown dkk, 2017; Feldens dkk, 2018; Brown dkk, 2019;	BSMulti
2	ARC	Solikin dkk, 2018; Trzcinska dkk, 2021	BSMono
		Vondervoort dan Lekkerker, 2021; Clarke, 2015; Feldens dkk, 2018	BSMulti
3	Hypercube	Ji dkk, 2020	BSMono
		Brown dan Varma, 2018	BSMulti BSF
4	Bayesian	Gaida dkk, 2018	BSMulti
5	GMM & CRF	Buscombe and Grams, 2018	BSMulti
6	RF & SVM	Gavazzi dkk, 2017; Nguyen dkk, 2018; Ji dkk, 2020; Zhao dkk, 2021	BSMono
		Wan dkk, 2022; Zhang dkk, 2022	BSMono BSF
		Runya, dkk, 2021	BSMulti
		Mertikas & Karanzalos (2020)	BSMulti BSF
7	RFDT	Zhi dkk (2014); Xu dkk (2021)	BSMono BSF
8	OBIA	Koop dkk, 2021	BSF
		Janowsky, 2018	BSF BSMulti
9	BTM	Zakariya dkk, 2018	BSF BSMulti
10	PCA	Ahmed dan Demsar, 2013;	BSMono

No	Metode	Peneliti	Input Data
		Tegowsky, 2019; Menandro dkk, 2022	BSMulti

**Catatan:**

1. BSF (Bativetri Single Frekuensi); BMF (Bativetri Multi Frekuensi), BSMono (*Backscatter Monospektral*); BSMulti (*Backscatter Multispektral*)
2. ARA (*Angular Response Analysis*); GMM (*Gaussian Mixture Model*); CRF (*Conditional Random Field*); RF (*Random Forest*); SVM (*Support Vector Machine*); OBIA (*Object Base Image Analysis*); BTM (*Benthic Terrain Model*); PCA (*Principal Component Analysis*); RFDT (*Random Forest Decision Tree*)

## 1.6 Hipotesis

Berdasarkan kerangka pemikiran yang menjadi latar belakang serta tujuan penelitian, maka diajukan hipotesis (jawaban sementara) dengan pernyataan sebagai berikut:

1. MBES multifrekuensi akan menghasilkan kedalaman yang berbeda dari satu frekuensi ke frekuensi yang lain. Selanjutnya kedalaman dari frekuensi yang satu dengan frekuensi yang lain di selisihkan dan akan menghasilkan selisih batimetri. Selisih batimetri ini selanjutnya digunakan untuk mendeteksi seberapa besar ketebalan sedimen dasar laut yang bisa dideteksi oleh MBES multispektral. Ketebalan sedimen dasar laut ini bergantung pada jenis sedimen yang ada di dasar laut. Semakin rendah frekuensi maka semakin dalam penetrasinya ke sedimen dasar. Ketebalan sedipenetrasi bergantung pada jenis sedimen dasar.
2. MBES multispektral akan menghasilkan *bakscatter* dan kedalaman yang berbeda-beda dari satu frekuensi dengan frekuensi lainnya dalam waktu survei yang bersamaan. Selisih batimetri yang lebih besar akan menghasilkan intensitas hamburan balik yang lebih kecil dibandingkan dengan selisih batimetri yang kecil.

3. Kombinasi antar *backscatter* dan batimetri MBES multispektral digunakan untuk memperbaiki kualitas hasil klasifikasi sedimen dasar. Akhirnya akan diperoleh hasil klasifikasi sedimen yang lebih baik dibandingkan dengan metode yang sudah ada.
4. Selama ini kekuatan hamburan balik merupakan fungsi dari frekuensi, jarak (kedalaman), sudut datang, kekerasan sedimen (*hardness*), kekasaran sedimen (*roughness*), kemiringan (*slope*), *batimetric position index (bpi)*, dan *aspect* yang digunakan untuk mengklasifikasi sedimen dasar laut. Penambahan parameter selisih batimetri (ketebalan sedimen) diharapkan akan meningkatkan kualitas (kedekatan dan ketelitian) klasifikasi jenis sedimen yang dihasilkan oleh MBES multifrekuensi

## **BAB 2**

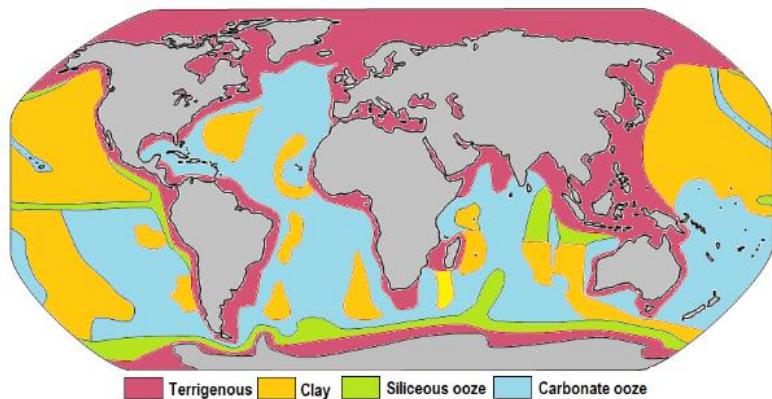
### **KAJIAN PUSTAKA DAN DASAR TEORI**

#### **2.1 Sedimen Dasar Laut**

Sedimen merupakan bahan utama pembentuk morfologi (topografi dan batimetri) pesisir dan laut. Sedimen berasal dari fragmentasi (pemecahan) batuan. Pemecahan tersebut terjadi karena pelapukan (*weathering*) yang dapat berlangsung secara fisik, kimiawi, atau biologis. Berubahnya morfologi pesisir/estuari terjadi sebagai akibat berpindahnya sedimen yang berlangsung melalui mekanisme erosi, pengangkutan (transpor) dan pengendapan (deposisi). Menurut Earle (2015) sedimen dasar laut berasal dari beberapa sumber yang berbeda dan sangat bervariasi dalam komposisi, tergantung pada kedekatan dengan benua (kontinen), kedalaman air (batimetri), arus laut, aktivitas biologis, dan iklim. Sedimen dasar laut (dan batuan sedimen) dapat memiliki ketebalan mulai dari beberapa milimeter hingga beberapa puluh kilometer. Di dekat permukaan, sedimen dasar laut tetap tidak terkonsolidasi, tetapi pada kedalaman ratusan hingga ribuan meter (tergantung pada jenis sedimen dan faktor-faktor lain) sedimen menjadi melunak.

Ada beberapa sumber sedimen dasar laut menurut Earle (2015), yang dapat dilihat pada Gambar 2.1 dan diringkas sebagai berikut:

1. Sedimen terrigenous berasal dari sumber benua yang diangkut oleh sungai, angin, arus laut, dan gletser. Sedimen ini didominasi oleh kuarsa, feldspar, mineral tanah liat, oksida besi, dan bahan organik terrestrial.
2. Sedimen karbonat pelagik berasal dari organisme (foraminifera) yang hidup di air laut (pada berbagai kedalaman, tetapi kebanyakan di dekat permukaan) yang membuat cangkang mereka dari mineral karbonat seperti kalsit.
3. Sedimen silika pelagik berasal dari organisme laut (diatom .dan radiolaria) yang melakukan pengujian dari silika (mikrokristalin kuarsa).
4. Abu vulkanik dan material vulkanik lainnya berasal dari erupsi darat dan bawah laut.
5. Nodul besi dan mangan terbentuk sebagai endapan langsung dari air dasar laut.



Gambar 2.1 Distribusi sumber sedimen di seluruh dunia (Earle, 2015)

Pada Gambar 2.1 diatas dapat dilihat bahwa secara umum sumber sedimen untuk daerah pesisir dan perairan dangkal (*shallow water*) adalah *terrigenous*.

Berdasarkan ukuran partikel sedimen, Wentworth (1922) mengklasifikasikan sedimen seperti yang tercantum dalam Tabel 2.1. Ada beberapa metode yang digunakan untuk menentukan jenis sedimen dengan melihat ukuran sedimennya (IAEA, 2003) yaitu dengan metode analisis saringan (*sieve analysis*), kapasitas penyerapan (*absorption capacity*), analisis kimia (*chemical analysis*) dan analisa spektrometri (*spectrometry analysis*).

Tabel 2.1 Ukuran Butir Sedimen (Wentworth, 1922)

Jenis Sedimen (x)	Jenis Agregat	Ukuran (mm)
Bongkahan ( <i>boulder</i> )	<i>Boulder gravel</i>	$>256$
Berangkal ( <i>cobble</i> )	<i>Cobble gravel</i>	$256 \leq x < 64$
Kerakal ( <i>pebble</i> )	<i>Pebble gravel</i>	$64 \leq x < 4$
Granul ( <i>granule</i> )	<i>Granule gravel</i>	$4 \leq x < 2$
Pasir sangat kasar ( <i>very coarse sand grain</i> )	<i>Very coarse sand</i>	$2 \leq x < 1$
Pasir kasar ( <i>coarse sand</i> )	<i>Coarse sand</i>	$1 \leq x < \frac{1}{2}$

Jenis Sedimen (x)	Jenis Agregrat	Ukuran (mm)
Pasir sedang ( <i>medium sand grain</i> )	<i>Medium sand</i>	$\frac{1}{2} \leq x < \frac{1}{4}$
Pasir halus ( <i>fine sand grain</i> )	<i>Fine sand</i>	$\frac{1}{4} \leq x < \frac{1}{8}$
Pasir sangat halus ( <i>very fine sand grain</i> )	<i>Very fine sand</i>	$\frac{1}{8} \leq x < \frac{1}{16}$
Debu ( <i>silt</i> )	<i>Silt</i>	$\frac{1}{16} \leq x < \frac{1}{256}$
Lumpur ( <i>clay</i> )	<i>Clay</i>	$x \leq 256$

## 2.2 Metode Pengambilan Sedimen Dasar Laut dengan Metode Non-Akustik

### 2.2.1 *Grab Sediment Sampler*

*Grab sediment sampler* atau yang sering disebut dengan *grab sampler* merupakan alat yang dapat digunakan untuk mengambil sampel sedimen dasar laut, yang selanjutnya sedimen tersebut diuji di laboratorium untuk menghitung komposisinya masing-masing jenis sedimennya. *Grab sampler* sangat mudah dioperasikan dan dapat memberikan sampel dasar laut yang cocok untuk dianalisis butirannya (*grain size*) di laboratorium. Ada beberapa jenis *grab sampler* yang tersedia di pasaran dan yang paling umum digunakan yaitu jenis *Shipek*, *van Veen* (Gambar 2.2), *Petersen* dan *Smith McIntyre*.

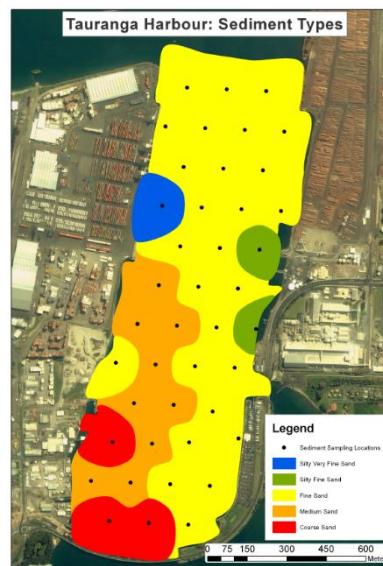


Gambar 2.2 Van Veen *grab sampler*

Kelemahan pengambilan sedimen dasar laut dengan *grab sampler* adalah pengambilan datanya harus dalam posisi diam. Hal ini akan sulit dilakukan untuk mempertahankan posisi (koordinat) di area (laut) dengan gelombang yang tinggi dan arus yang kuat. Pengambilan sampel sedimen dalam jumlah yang banyak yang mewakili area yang akan dipetakan sedimen dasarnya, akan membutuhkan waktu yang cukup lama dan biaya yang cukup besar. Kelemahan lainnya adalah penggunaan alat ini terbatas pada kedalaman tertentu. Semakin dalam perairan, semakin besar tekanannya, yang menyebabkan semakin sulit *grab sampler* untuk mendapatkan sedimen dasar. Selain itu, pada saat pengangkatan sedimen ke atas, sedimen butiran halus yang diambil oleh *grab sampler* ada kemungkinan terlepas dan ada risiko penyumbatan rahang dari partikel kasar (IAEA, 2003). Sampel-sampel sedimen yang diambil, selanjutnya dianalisis di laboratorium, yang merupakan proses yang memakan waktu dan mahal.

Data analisa hasil laboratorium, dengan analisa saringan (*sieving analysis*) yang menjelaskan komposisi dominan sedimen dasar laut menurut skala Wentworth (1922) seperti lempung, lanau, lumpur, pasir, kerikil dan batuan dan digabung dengan data posisi horizontal yang diperoleh dengan pengukuran GNSS (*Global Navigation Satellite System*) (lintang dan bujur), selanjutnya digambar menjadi peta sebaran sedimen dasar. Metode sederhana yang digunakan untuk membuat peta sebaran sedimen tersebut adalah dengan metode interpolasi (Gambar 2.3). Gambar 2.3 menunjukkan peta sebaran sedimen dasar laut di Pelabuhan Tauranga, Selandia Baru. Dengan data sedimen yang diperoleh dari *grab sampler* sebanyak 42 titik sampel dan interpolasi maka diperoleh peta sedimen dasar yang didominasi oleh pasir halus (*fine sand*), pasir sedang (*medium sand*), pasir kasar (*coarse sand*), pasir halus berlumpur (*silty fine sand*) dan pasir sangat halus berlumpur (*silty very fine sand*).

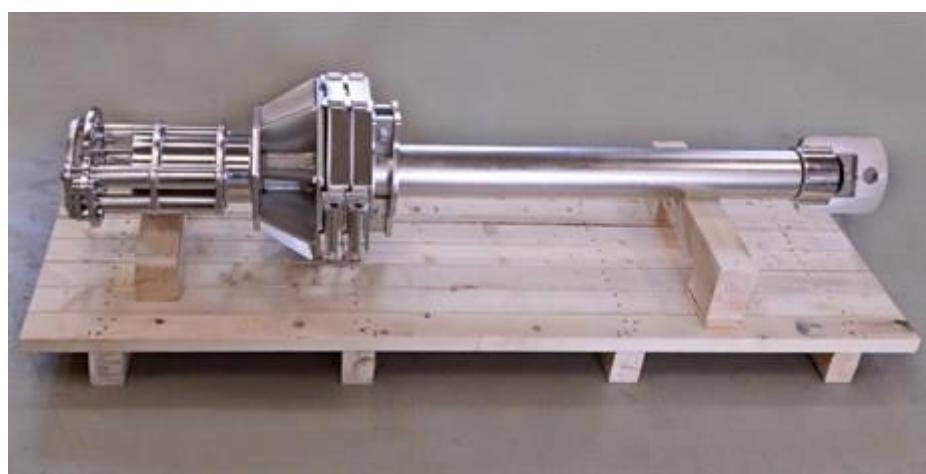
Ketelitian hasil dari interpolasi ini sangat bergantung pada jumlah data sampel yang diambil yang mewakili area yang akan dipetakan. Semakin rapat data yang diambil maka semakin teliti, akan tetapi semakin lama waktu yang dibutuhkan untuk survei dan pengolahannya dan akibatnya semakin mahal biaya yang dikeluarkannya.



Gambar 2.3 Peta sebaran sedimen dari *grab sampler* (Boulay, 2012)

### 2.2.2 *Gravity Core*

Berbeda dari *grab sampler*, *sediment core* dapat mengambil sedimen dasar laut tidak hanya pada permukaan dasarnya saja, tetapi juga dapat mengambil sedimen pada lapisan stratigrafi dengan kedalaman tertentu. Ada beberapa jenis *sediment core* yang digunakan yaitu *gravity core* (Gambar 2.4), *hydraulic core*, *vibro core* dan *physton core*. Aplikasi jenis dari *sediment core* ini bergantung pada kondisi lingkungan dan penelitian yang diinginkan.



Gambar 2.4 *Gravity core*

*Gravity core* merupakan jenis *sediment core* yang paling sering digunakan untuk mengumpulkan sedimen dasar laut. *Gravity core* ini dapat mengambil

sedimen dasar dengan cepat dan terus menerus hingga kedalaman beberapa ribu meter dari dasar laut. Itu juga dapat dioperasikan dengan berbagai jenis kapal. Penerapan *gravity core* adalah untuk pengeringan, rekayasa minyak dan gas lepas pantai, jalur pipa dan kabel dan sangat berguna untuk kontrol jenis tanah dalam survei geofisika. Seperti *grab sampler*, *gravity core* ini juga memiliki kelemahan yang sama jika digunakan untuk pemetaan sedimen dasar laut. *Gravity core* tidak dapat menghasilkan data sedimen primer yang kontinyu sehingga semakin banyak sampel yang dibutuhkan, semakin banyak waktu yang diperlukan, dan pada akhirnya biaya yang dikeluarkan juga lebih signifikan. *Gravity core* sangat cocok untuk mengumpulkan lempung sangat lunak hingga keras karena penetrasi dalam lempung keras atau pasir biasanya terbatas. Seperti halnya *grab sampler*, pembuatan peta sedimen dasar laut dengan *gravity core* dengan menggunakan metode interpolasi. Semakin rapat data yang dikumpulkan maka semakin teliti peta sedimen dasar laut yang dihasilkannya.

Pendekatan konvensional (*grab sampler* dan *sediment core*) untuk mendapatkan informasi tentang komposisi sedimen dasar laut memerlukan biaya yang mahal karena membutuhkan wahana (kapal) dan peralatan khusus, pengukuran memerlukan waktu yang lama, dan membutuhkan analisa laboratorium untuk melihat komposisi sedimen. Selain itu, metode ini hanya menghasilkan informasi titik pengamatan yang satu ke pengamatan titik yang lain, sehingga untuk menghasilkan peta sedimen dasar perlu interpolasi, sehingga hasilnya kurang akurat.

## 2.3 Metode Pemetaan Sedimen Dasar Laut Dengan Metode Akustik

### 2.3.1 Persamaan Dasar Akustik Bawah Air

Sonar (*Sound Navigation and Ranging*) adalah teknologi yang menggunakan gelombang akustik untuk mendeteksi dan menemukan objek di lautan. Sistem sonar aktif, seperti *fish finder*, *echosounder*, *side-scan sonars*, dan *military sonars*, mentransmisikan pulsa suara dan kemudian mendengarkan gema. Sistem sonar pasif mendengarkan suara bawah air untuk mendeteksi sinyal yang menarik, seperti yang dihasilkan oleh hewan, gunung berapi, kapal selam, kebisingan pengiriman, dan sumber lainnya.

Sistem sonar aktif mengirimkan pulsa suara ke dalam air dari proyektor akustik. Pulsa suara ini bergerak atau merambat melalui air, memantul atau berhamburan dari benda-benda yang dilaluinya. Beberapa bagian dari gelombang yang tersebar kemudian diterima oleh sonar. Proses ini menyeimbangkan jumlah energi yang terkait transmisi, propagasi, interaksi target, *noise* dan pemrosesan. Tingkat relatif dari sinyal yang diminati dan kebisingan latar belakang di lautan menentukan apakah sistem sonar dapat mendeteksi gema dari target atau suara yang dihasilkan oleh sumber atau tidak. Untuk memutuskan apakah ada sinyal, operator atau perancang sonar menetapkan ambang deteksi sedemikian rupa sehingga ketika rasio tingkat sinyal terhadap tingkat kebisingan di penerima melebihi ambang ini, keputusan "adanya sinyal" dibuat. Keputusan "tidak ada sinyal" dibuat ketika *signal-to-noise ratio (SNR)* di bawah ambang batas deteksi.

Persamaan sonar adalah cara sistematis untuk memperkirakan *SNR* yang diharapkan untuk sistem sonar pada waktu dan tempat tertentu dan untuk rentang dan kedalaman tertentu. Versi persamaan sonar yang sedikit berbeda digunakan untuk sistem sonar aktif (rentang gema) dan pasif. *Signal-to-noise ratio (SNR)* pada penerima yang ditempatkan bersama dengan sonar aktif adalah:

$$SNR \text{ (decibels)} = SL - 2TL + TS - NL \quad 2.1$$

di mana *SL* adalah tingkat sumber, *TL* adalah kehilangan transmisi antara sonar/penerima dan target, *TS* adalah kekuatan target, dan *NL* adalah tingkat kebisingan sekitar. *SNR*, tingkat sumber, kehilangan transmisi, kekuatan target, dan tingkat kebisingan semuanya diberikan dalam desibel.

Jumlah di mana *SNR* melebihi ambang deteksi, *DT*, disebut kelebihan sinyal (*SE*):

$$SE \text{ (desibel)} = SNR - DT = (SL - 2TL + TS - NL) - DT \quad 2.2$$

Jika *SE* lebih besar dari 0 dB, maka diputuskan bahwa target ada. Jika *SE* negatif, keputusannya adalah target tidak ada.

Pengembangan persamaan sonar biasanya dimulai dengan pembangkitan dan transmisi pulsa suara. Karena sinyal ini merambat menjauh dari proyektor ke jarak  $R$ , maka tekanan gelombang akustik menyebar sebagai gelombang sferis dengan formula sebagai berikut (Lurton dan Lamarche, 2015):

$$p(R) = \frac{p_0}{R} e^{j(\omega t - kR)} e^{-aR} \quad 2.3$$

dimana  $\omega = 2\pi f$  adalah frekuensi sudut,  $f$  adalah frekuensi sonar, dan  $k$  adalah angka gelombang akustik  $k = \omega/c = 2\pi f/c = 2\pi/\lambda$  di mana  $c$  adalah kecepatan suara dan  $\lambda = c/f$  adalah panjang gelombang. Koefisien penurunan eksponensial  $a$  karena penyerapan dalam air. Ketergantungan rentang  $1/R$  dari Persamaan 2.3 sering disebut penyebaran sferis (*spherical spreading*) sering digunakan dan diekspresikan dalam pendekatan pertama terhadap penurunan tekanan yang jauh dari sumbernya (Lurton dan Lamarche, 2015).

Amplitudo tekanan  $p(R)$  dan  $p_0$  dalam Persamaan 2.3 mewakili nilai puncak masing-masing pada jarak  $R$  dan pada jarak referensi 1 m. Seringkali lebih tepat untuk mendeskripsikan referensi sumber amplitudo menggunakan ukuran besaran statistik seperti nilai *root mean square (rms)*, yang dihitung sebagai definisi yang menyiratkan akar kuadrat dari rata-rata pulsa sonar. Untuk sinyal sinusoidal amplitudo konstan (*CW*), seperti pulsa yang digunakan oleh banyak *echosounder*, hubungan antara tekanan *rms* dan tekanan puncak (Lurton dan Lamarche, 2015) adalah sebagai berikut:

$$p_{rms} = p/\sqrt{2} \quad 2.4$$

Energi yang terkait dengan gelombang akustik dapat dipisahkan menjadi energi kinetik (karena partikel fluida bergerak) dan komponen potensial (karena elastisitas media fluida). Intensitas akustik (fluks daya melalui permukaan unit) dari gelombang yang merambat diberikan oleh (Lurton dan Lamarche, 2015):

$$I(R) = \frac{\langle p^2(R) \rangle}{\rho c} = \frac{p_{rms}^2(R)}{\rho c} \quad 2.5$$

Oleh karena itu intensitas sumber  $I_0$  pada 1 m dinyatakan sebagai (Lurton dan Lamarche, 2015):

$$I_0 = p_0^2 / 2\rho c \text{ (W/m}^2\text{)} \quad 2.6$$

Dalam akustik, besaran yang digunakan untuk menyatakan ukuran intensitas adalah desibel ( $dB$ ). Desibel menurut skala logaritmik lebih baik disesuaikan dengan rentang dinamis yang sangat besar dari karakteristik gelombang suara. Desibel adalah unit logaritmik komparatif yang didefinisikan sebagai sepuluh kali logaritma basis-10 yaitu rasio antara dua kuantitas yang homogen dengan energi (intensitas, daya) yang mengacu pada nilai referensi konvensional. Misalnya, nilai referensi untuk tekanan akustik adalah  $1 \mu Pa$ , dan nilai tekanan harus dinyatakan dalam  $dB$  re.  $1 \mu Pa$ . Seringkali nilai referensi  $dB$  terkadang dihilangkan dalam penggunaannya karena kebiasaan (Lurton dan Lamarche, 2015). Tingkat intensitas (*Instensity Level / IL*) didefinisikan dalam  $dB$  sebagai (Lurton dan Lamarche, 2015):

$$IL = 10 \log_{10} \left[ \frac{I}{I_{ref}} \right] \quad 2.7$$

dimana  $I_{ref}$  adalah intensitas referensi. Oleh karena itu, level sumber (*Source Level = SL*) didefinisikan sebagai berikut:

$$SL = 10 \log_{10} \left[ \frac{I_0}{I_{ref}} \right] \quad 2.8$$

Dalam akustik bawah air, intensitas referensi  $I_{ref}$  merupakan intensitas gelombang bidang akustik dengan *rms* adalah  $1 \mu Pa$  ( $I_{ref} = 6,7 \times 10^{-19} \text{ W/m}^2$ ) (Lurton dan Lamarche, 2015).

Saat gelombang akustik meninggalkan proyektor dan bergerak ke dalam air, amplitudo sinyal tekanan berkurang karena penyebaran (*spreading*) dan penyerapan (*absorption*). Kehilangan transmisi (*Transmission Loss / TL*), pada jarak  $R$  didefinisikan dengan persamaan berikut (Lurton dan Lamarche, 2015):

$$TL = 10 \log_{10} \left[ \frac{I(R_{ref})}{I(R)} \right] \quad 2.9$$

dimana  $R_{ref} = 1$  m. Dengan memasukkan Persamaan 2.1 ke dalam Persamaan 2.9 menghasilkan persamaan berikut (Lurton dan Lamarche, 2015):

$$TL = 10 \log_{10} \left[ \frac{e^{-aR_{ref}}}{R_{ref}} \frac{R}{e^{-aR}} \right]^2 \approx 20 \log_{10} R + \alpha R \quad 2.10$$

Dua suku di sisi kanan Persamaan 2.10 disebut dengan penyebaran sferis dan absorpsi, di mana  $\alpha$  adalah koefisien absorpsi logaritmik dengan satuan  $dB/m$ , dan terkait dengan penurunan eksponensial  $a$  sebesar  $\alpha = 10 \log_{10} e^{2a} \approx 8.686 \times a$ .

Kombinasi  $SL$  dan  $TL$  digunakan untuk memperkirakan tingkat tekanan suara (*sound pressure level*),  $SPL = SL - TL$  di beberapa jarak yang diinginkan. Untuk sistem *echosounding*, jarak yang diinginkan ini biasanya jarak ke target. Ketika pulsa sonar mencapai target (misalnya ikan, mikrostruktur turbulen di kolom air, dasar laut) sebagian dari energi pulsa diarahkan kembali atau dihamburkan ke penerima sonar. Kekuatan target (*Target Strength / TS*), digunakan untuk menggambarkan seberapa banyak gelombang suara diarahkan kembali, relatif terhadap seberapa banyak untuk mencapai target di tempat pertama (Lurton dan Lamarche, 2015):

$$TS = 10 \log_{10} \left[ \frac{I_s}{I_i} \right] \quad 2.11$$

di mana  $I_i$  adalah intensitas datang pada target dan  $I_s$  adalah intensitas hamburan ke arah penerima dan pada jarak referensi 1 m dari target. Secara umum, intensitas hamburan bergantung pada karakteristik target sebagaimana gelombang suaranya. Untuk target tertentu  $I_s$  dapat berubah bergantung pada frekuensi sonar, orientasi antara target dan kedua dari gelombang datang dan pantulan, panjang pulsa sonar, dan sifat lain dari proyektor akustik, penerima, dan target (Lurton dan Lamarche, 2015).

Setelah berinteraksi dengan dasar laut, sebagian dari hamburan gelombang merambat kembali menuju target (*backscatter*) dan mengalami hal yang sama berupa kehilangan transmisi berupa penyebaran dan penyerapan seperti pada saat gelombang menuju target. Intensitas yang diterima dapat digambarkan sebagai gema dari target, yang dalam notasi desibel disebut sebagai level gema (*Echo Level / EL*) (Lurton dan Lamarche, 2015):

$$EL = SL - 2TL + TS \quad 2.12$$

Bentuk persamaan sonar ini mengasumsikan bahwa kehilangan transmisi identik dalam perjalanan ke target dan dalam perjalanan kembali ke penerima. Perlu dicatat juga bahwa persamaan sonar dapat diekspresikan dalam hal nilai intensitas daripada tingkat intensitas (dalam *dB*) sebagai (Lurton dan Lamarche, 2015):

$$I_r(R) = \frac{I_0}{R^4} \frac{I_s}{I_i} e^{-2aR} \quad 2.13$$

di mana  $I_r$  adalah intensitas gema yang diamati di penerima,  $R$  adalah jarak target ke sonar.

Level gema mengukur gelombang suara yang ingin diukur, namun demikian target gema bukan satu-satunya gelombang suara yang diterima. Saat mengukur level gema, seringkali dibingungkan oleh gelombang akustik yang tidak diinginkan, yang secara global disebut sebagai *noise* (Lurton dan Lamarche, 2015):

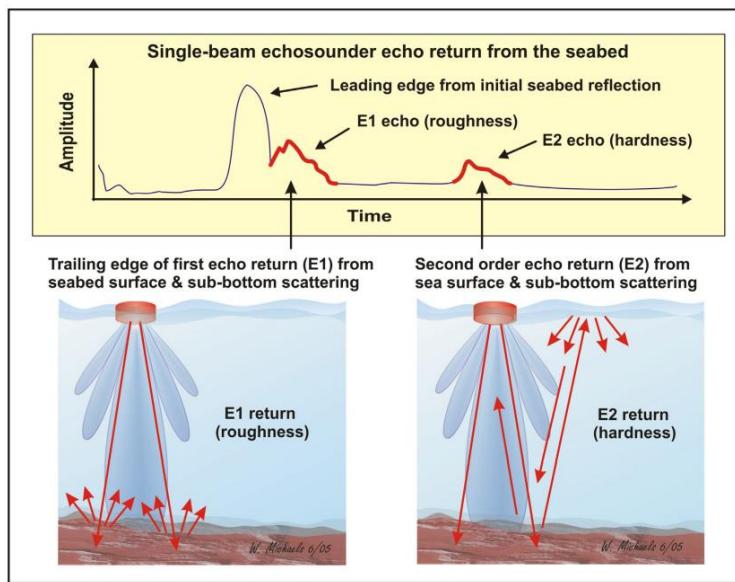
- *ambient noise* (misalnya, lalu lintas kapal, ledakan gelembung di bawah gelombang pecah, hewan laut),
- kebisingan sendiri (*self-noise*) (dihasilkan oleh sonar itu sendiri atau oleh platformnya) atau
- *reverberation* (misalnya, gelombang suara yang diproyeksikan yang tersebar dari objek yang tidak diinginkan).

### 2.3.2 *Backscatter*

*Backscatter* merupakan hamburan balik (pantulan) sinyal gelombang elektromagnetik maupun suara kembali ke sumber asalnya (*receiver*). Dalam dunia hidrografi dan ilmu kelautan, *backscatter* dari gelombang suara digunakan untuk membantu memahami karakteristik dasar laut. *Backscatter* dihitung dengan mengukur intensitas suara yang dipantulkan oleh dasar laut dan diterima kembali oleh *receiver*.

Jenis sedimen dasar laut yang berbeda akan menghamburkan energi suara secara berbeda, dan akan memberi informasi tentang kekerasan (*hardness*) dan kekasaran (*roughness*) relatifnya. Kekerasan didefinisikan sebagai kontras antara impedansi karakteristik air dan dasar laut, dimana impedansi akustik merupakan perkalian antara densitas material dengan kecepatan gelombang suara ( $\rho c$ ). Sedangkan kekasaran yang dimaksud disini adalah kekasaran permukaan akustik, dimana kekasaran permukaan akustik didefinisikan sebagai rasio kekasaran pada panjang gelombang akustik. Kekasaran geometris dinyatakan dengan standar deviasi kedalaman ( $d$ ) dari elevasi antar muka dasar laut. Tidak ada dasar laut yang secara intrinsik kasar atau halus, akan tetapi kekasaran akustik bergantung pada frekuensi akustik yang digunakan.

Nilai kekerasan sedimen dasar yang paling baik yaitu dengan mengarahkan *beam* kurang lebih atau tegak lurus terhadap sedimen dasar laut. Sedangkan nilai kekasaran paling baik jika diukur dengan sudut datang miring (jauh dari nadir). Semakin kasar suatu permukaan sedimen dasar laut maka sinyal akan semakin terpantul pada sudut tertentu. Kekerasan sedimen juga mempengaruhi bagaimana energi dari *beam* dipantulkan. Sedimen dasar laut yang lunak memungkinkan lebih banyak energi untuk menembus, menghasilkan pengembalian sinyal yang lebih lemah, di mana energi balik tersebar dari waktu ke waktu karena dikembalikan dari lapisan yang berbeda dalam sedimen (Anderson, 2007). Jenis sedimen dasar laut yang lebih keras (seperti batu) memantulkan lebih banyak gema daripada jenis dasar yang lebih lunak (seperti lumpur). Adapun jenis dasar yang lebih halus (seperti trotoar) memantulkan lebih banyak gema daripada jenis dasar yang bergelombang (seperti terumbu karang).

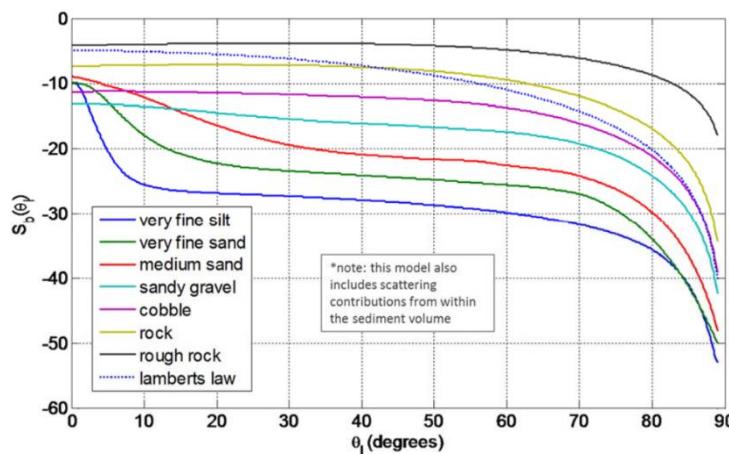


Gambar 2.5 Respon kekasaran (kiri) dan kekerasan (kanan) sedimen dasar laut terhadap sinyal SBES (Anderson, 2007)

Refleksi dan hamburan dari dasar laut dapat dimasukkan ke dalam model yang menggambarkan kekuatan *backscatter* dasar laut di semua sudut datang. Peneliti di *Applied Physics Lab - University of Washington* (APL-UW, 1994) telah mengembangkan model dengan menggunakan pendekatan *Kirchhoff* yaitu mendekati sudut datang normal (*nadir*), model kekasaran komposit, dan dijumlahkan dengan model hamburan balik volume. Model ini telah memasukkan kepadatan dan kecepatan suara air laut dan sedimen serta parameter yang menggambarkan spektrum kekasaran. Persamaan sonar bagian bawah kekuatan hamburan balik dengan perkiraan di area insonifikasi:

$$TS = BS + 10\log_{10}A = 10\log_{10}(\sigma_r + \sigma_v) + 10\log_{10}A \quad 2.14$$

di mana  $r$  dan  $v$  adalah penampang hamburan balik untuk masing-masing kekasaran permukaan dan volume (Jackson dan Richardson, 2007). Gambar 2.6 merupakan model *backscatter* untuk frekuensi 100 kHz dan variasi substrat dari lanau sangat halus ke batuan kasar.



Gambar 2.6 Contoh hamburan balik yang bergantung pada sudut datang untuk berbagai jenis substrat pada 100 kHz, berdasarkan model hasil menggunakan (APL-UW, 1994)

### 2.3.2.1 Kebergantungan Sudut Datang

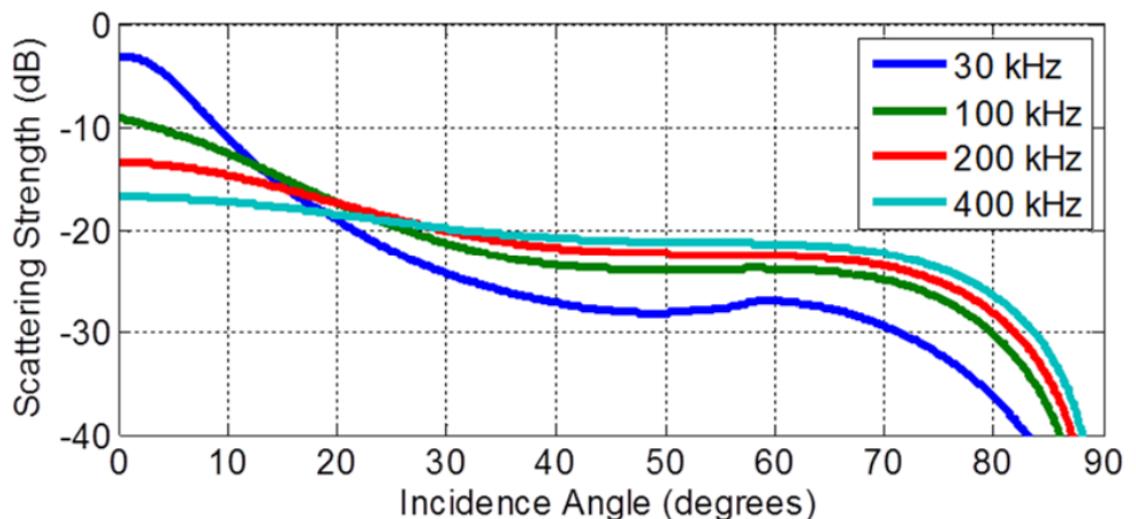
Salah satu prediksi penting dari model kekuatan *backscatter* adalah kebergantungan pada sudut datang (*angle incidence dependence*). Pada sudut datang normal (*nadir*), tingkat gema paling kuat dari dasar laut. Dasar laut yang terdiri dari sedimen ukuran butir yang lebih kecil (misalnya, lanau dan lempung) cenderung memiliki kekasaran rendah, sehingga pengaruh refleksi *specular* berkurang sangat cepat dengan bertambahnya sudut datang. Pada sudut datang miring yang jauh dari nadir, sedikit sekali efek hamburan yang dikembalikan ke *receiver*. Tingkat hamburan balik pada sudut miring dikendalikan oleh kekerasan antarmuka (impedansi) dan kekasaran. Pada *grazing angle* yang sangat rendah, respon hamburan balik dari dasar laut hilang, yang disebabkan oleh (1) dasar laut memotong sedikit (per satuan luas) daya akustik yang tersedia untuknya; (2) respons kekasaran berkurang; dan (3) efek bayangan muncul, mengurangi penampang hamburan balik efektif.

Gambar 2.6 diatas menggambarkan respon sudut *off-nadir* dari tipe sedimen pada frekuensi tinggi 100 kHz. Secara umum, grafik tersebut menunjukkan 3 (tiga) bagian yang berbeda dalam kurva respon. Bagian pertama sudut datang antara nadir ( $0^\circ$ ) dan  $15^\circ$  derajat menunjukkan kekuatan hamburan balik akustik cenderung lebih tinggi, dibandingkan dengan bagian lainnya. Mekanisme interaksi

akustik bawah air di bagian pertama mencakup refleksi *specular*, hamburan permukaan dan lebarnya bergantung pada tipe sedimen dasar laut. Pada bagian ketiga, sudut datang lebih dari  $60^{\circ}$  merupakan mekanisme interaksi akustik bawah air yang dipengaruhi oleh hamburan volume, dimana cenderung ada penurunan cepat dalam hamburan balik. Bagian kedua dari grafik, sudut datang antara  $15^{\circ} - 60^{\circ}$ , didominasi oleh hamburan permukaan yang bergantung pada tipe sedimen dasar laut.

### 2.3.2.2 Kebergantungan Frekuensi

Kekuatan *backscatter* juga bergantung pada frekuensi sonar yang digunakan untuk akuisisi data. Model *backscatter* pada sedimen pasir terhadap beberapa frekuensi yang berbeda dapat dilihat pada Gambar 2.7. Gambar 2.7 menunjukkan bahwa respon dasar laut berubah sebesar 7 dB pada sudut miring, dan hampir 14 dB pada sudut normal. Dengan demikian kebergantungan frekuensi bergantung pada karakteristik spektrum kekasaran.



Gambar 2.7 Contoh hamburan balik yang bergantung pada sudut untuk pasir pada frekuensi yang berbeda (APL-1994)

### 2.3.2.3 Koefisien *Backscatter* Permukaan Dasar Laut

Koefisien *backscatter* permukaan dasar laut, atau penampang *backscatter* per satuan luas permukaan dasar laut,  $m_s$ , berhubungan dengan koefisien *backscatter* volume sedimen, atau penampang per satuan volume sedimen,  $m_v$ , mengikuti formula berikut (Ivakin, 2000; Ivakin, 2004):

$$m_s = |W|^4 \mu^{-2} m_v h_p \quad 2.15$$

di sini,  $W$  adalah koefisien transmisi suara dari antarmuka air - sedimen,  $\mu = \frac{\rho}{\rho_w}$  adalah rasio kepadatan sedimen/air;  $h_p$  adalah kedalaman penetrasi suara ke dalam sedimen pada frekuensi  $f$  dan  $\chi_w$  adalah *grazing angle* (Ivakin, 2000; Ivakin, 2004):

$$h_p = \frac{n_0}{4kIm\sqrt{n^2 - \cos^2 \chi_w}} = \frac{Re\sqrt{n^2 - \cos^2 \chi_w}}{2\beta n_0} \quad 2.16$$

dimana  $k = 2\pi f/c$  adalah angka gelombang,  $\beta = 2k\delta$  adalah koefisien atenuasi, dan  $n = n_0(1 + i\delta)$  adalah indeks refraksi,  $\delta$  adalah parameter kehilangan,  $n_0 = \frac{c_w}{c}$  adalah koefisien refraksi (rasio kecepatan suara di air/sedimen),  $Re$  adalah bilangan *Real* dan  $Im$  adalah bilangan imajiner dari bilangan kompleks. Untuk koefisien transmisi dalam kasus antar muka air – sedimen yang datar, maka  $W = I + V$ , dimana  $V$  adalah koefisien refleksi dasar sedimen. Secara umum, koefisien transmisi dapat memperhitungkan kekasaran dasar laut dan/atau adanya lapisan transisi atas berlapis dalam sedimen

### 2.3.2.4 *Backscatter* Dasar Permukaan

Proyeksi dasar perairan hamburan balik diilustrasikan pada Gambar 2.8. Daya hamburan balik unsur yang dicatat oleh transduser diberikan oleh:

$$dP_{RB}^2 = P_0^2 r^{-4} \exp(-4\alpha r) D^4 S_s dS \quad 2.17$$

di mana  $dP_{RB}$  adalah sinyal tekanan hamburan balik elemen dari dasar laut,  $P_0$  adalah tingkat tekanan sumber,  $r$  adalah jarak, adalah  $\alpha$  koefisien penyerapan,  $D$  adalah fungsi arah, dan  $S_s$  adalah hamburan dasar permukaan. Area unsur  $dS$  terletak di sudut datang, sudut azimut, dan jarak  $r$ , sehingga:

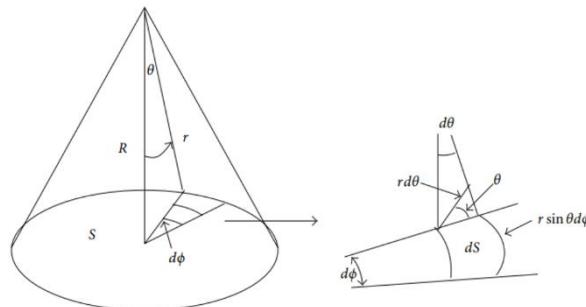
$$dS = r^2 \tan\theta d\theta d\phi \quad 2.18$$

Amplitudo tekanan gema dasar laut diperoleh dengan integrasi:

$$P_{RB}^2 = P_0 r^{-2} \exp(-4\alpha r) \Phi S_s \quad 2.19$$

di mana  $\Phi$  adalah sudut pancaran ekivalen untuk hamburan permukaan

$$\Phi = \int_0^{2\pi} \int_{\theta_1}^{\theta_2} D^4 \tan\theta d\theta d\phi \quad 2.20$$



Gambar 2.8 Prinsip hamburan balik permukaan dasar

### 2.3.2.5 Backscatter Volume Sedimen

Sinyal akustik yang dipancarkan ke permukaan dasar laut, selain mengalami hamburan balik permukaan (*seabed surface backscatter*), sinyal tersebut juga akan mengalami hamburan ke bawah permukaan yang sering diistilahkan dengan hamburan volume sedimen. Hal ini terjadi ketika ada objek yang ditempatkan dibawah permukaan sedimen yang bersifat homogen dan bersifat heterogen dalam sedimen. Benda-benda ini dapat disentuh oleh gelombang datang

yang ditransmisikan di dalam sedimen, dan gema diubah sesuai dengan kontras impedansi benda-benda ini dibandingkan dengan sedimen sekitarnya. Ada beberapa hal yang perlu dipertimbangkan pada saat hamburan balik volume sedimen yaitu seberapa banyak suara yang menembus dasar laut, seberapa jauh suara menembus, dan propagasi kembali dari sedimen melalui antarmuka dasar laut dan kembali ke laut lagi.

Reflektifitas intrinsik individu dari penghambur yang terkubur ini meningkat seiring dengan frekuensi. Efek ini dikompensasi oleh penyerapan di dalam sedimen, yang efeknya meningkat juga dengan frekuensi dan karenanya membatasi jumlah penghambur yang benar-benar dicapai oleh sinyal. Volume hamburan balik sedimen maksimal pada sudut datang miring menengah. Pada sudut yang lebih curam digantikan oleh efek spekular, dan pada *grazing angle* rendah dapat diabaikan karena sulitnya gelombang datang ditransmisikan ke dalam volume sedimen. Efek volume hamburan balik tertinggi untuk soft sedimen, dimana (1) transmisi dari air ke substrat dasar laut berpotensi tinggi karena kontras impedansinya rendah; (2) penyerapan dalam sedimen lebih rendah daripada butiran kasar bahan; (3) substrat didiami oleh hewan atau gas; dan (4) tingkat hamburan balik yang disebabkan oleh kekasaran rendah relatif terhadap kontribusi sedimen volume.

Hamburan volume dapat menjadi kontributor dominan untuk *Sb*, khusus untuk sedimen lunak pada sudut miring dan frekuensi rendah di mana kontribusi terhadap kekasaran permukaan rendah dan substrat cenderung heterogen. Masalah rumit lebih lanjut adalah dasar laut berlapis, terutama di tempat yang keras (dan/atau) kasar substrat ada di bawah lapisan lunak yang tipis. Memisahkan semua kontributor potensial untuk hamburan balik dasar laut untuk mengidentifikasi fitur yang menarik untuk aplikasi tertentu adalah tidak mudah.

Hamburan volume dalam sedimen dapat dikaitkan dengan dua jenis yang berbeda yaitu kontinu dan diskrit. Kasus hamburan dari inklusi diskrit dalam sedimen fluida yang efektif dan mengasumsikan penjumlahan yang tidak koheren dari intensitas yang tersebar untuk penghambur yang berbeda. Dalam kerangka model hamburan tidak koheren, hamburan penampang per satuan volume sedimen dapat disajikan sebagai berikut (Ivakin, 2004):

$$m_v = \frac{1}{V} \sum_{j=1}^N \sigma_j = \frac{N\langle \sigma \rangle}{V} = \int \sigma(a) \psi_N(a) da \quad 2.21$$

di mana  $\sigma$  adalah penampang hamburan dari hamburan individu dan  $\langle \sigma \rangle$  adalah rata-rata, rasio N/V adalah jumlah rata-rata penghambur per satuan volume sedimen,  $a$  adalah parameter yang mencirikan penghambur individu, seperti ukuran, bentuk, sifat material dan lain-lain,

$$\psi_N(a) = \frac{\Delta N_a}{V \Delta a} \quad 2.22$$

adalah fungsi distribusi probabilitas yang menunjukkan jumlah penghambur per satuan volume per interval satuan dari parameter  $a$ . Asumsinya bahwa inklusi memiliki materi yang sama, dan  $a$  dianggap sebagai radius ekuivalen hamburan yang terdistribusi secara acak (jari-jari bola yang memiliki volume yang sama dengan inklusi non-bola). Pada kasus pengukuran relatif volume dan berat biji-bijian adalah setara, dan, menggunakan standar analisis berat fraksional, yang disebut histogram distribusi ukuran volume, dapat diperoleh:

$$\psi_\eta(a) = \frac{\Delta V_a}{\Delta V} \Big|_{\frac{\Delta a}{a} = \eta}, \quad \Delta V_a = \frac{4}{3} \pi a^3 \Delta a, \quad \Delta V = (1 - P)V \quad 2.23$$

dimana  $\Delta V$  adalah bagian volume sedimen yang ditempati oleh inklusi itu sendiri (butir),  $P$  adalah porositas sedimen. Karena  $\psi_\eta$  sebanding dengan  $\eta$  pada kecil  $|\eta|$ , maka fungsi distribusi ukuran volume tanpa dimensi yang dinormalisasi yang digunakan sebagai berikut:

$$\psi_v(a) = \frac{(1-P)\psi_n}{\eta} = \frac{4}{3} \pi a^4 \psi_N(a) = \frac{a \Delta V_a}{V \Delta a} \quad 2.24$$

independen dari interval ukuran yang digunakan.

Model sederhana untuk penghambur individu sebagai bola fluida (mewakili inklusi) dengan parameter akustik, kecepatan dan kepadatan suara,  $c_a$

dan  $|\rho_a|$ , ditempatkan dalam media fluida (mewakili sedimen sekitarnya) dengan parameter masing-masing  $c$  dan  $|\rho|$ . Solusi yang tepat untuk penampang hamburan balik disajikan dalam:

$$\sigma = a^2 F(ka) \quad 2.25$$

dimana  $F$  merupakan fungsi hamburan tanpa dimensi, dengan formula sebagai berikut:

$$F(ka) = \frac{R_0^2}{4} (ka)^4 \left( 1 + \frac{R_0^2}{R^2} (ka)^4 \right)^{-1} \quad 2.26$$

yang merupakan solusi eksak dengan interferensi yang dihaluskan pada osilasi  $ka \geq 1$ . Parameter dan  $R_0$  dan  $R$  didefinisikan sebagai berikut:

$$R_0 = \frac{2}{3} \left( 1 - \frac{\rho c^2}{\rho_a c_a^2} \right) + \frac{\rho_a - \rho}{\rho_a + \rho/2}; \quad R = \frac{\rho_a c_a - \rho c}{\rho_a c_a + \rho c} \quad 2.27$$

akhirnya didapatkan:

$$m_v = \frac{3}{4\pi} \int F(ka) a^{-2} \psi_v(a) da \quad 2.28$$

Persamaan 2.15 dan 2.28 memberikan solusi untuk koefisien hamburan balik dasar laut yang diberikan secara arbitrer distribusi ukuran inklusi diskrit dalam parameter sedimen dan akustik.

### 2.3.3 Model Deteksi Bawah Permukaan Dasar Laut

Berikut ini, dasar laut digambarkan (Gambar 2.9) oleh dua bagian model geoakustik (Guillon dan Lurton, 2001):

- i. Lapisan sedimen disipatif fluida dengan ketebalan  $h$ , dibagi menjadi  $n$  lapisan dasar. Setiap lapisan  $l$  dicirikan oleh kecepatan suaranya  $c_l$ , kepadatan  $\rho_l$ ,

koefisien atenuasi  $\alpha_l$ , ketebalannya  $d_l$ , dan penampang hamburan balik individual  $\sigma_l(\theta_0)$ , dipertimbangkan pada batas atasnya.

- ii. Ruang bawah tanah disipatif fluida semi-tak terbatas, dengan parameter  $c_{n+1}$ ,  $\rho_{n+1}$ ,  $\sigma_{n+1}$ , dan penampang melintang *backscatter*  $\sigma_{n+1}(\theta_0)$ . Ruang bawah tanah di sini hanya terkait ke penetrasi akustik, yang berarti bahwa tidak ada pengembalian energi yang signifikan dari media di bawah antarmuka  $n + 1$ . Tidak terkait dengan struktur geologi tertentu.

Pada lapisan bawah permukaan dasar laut yang berbeda dimodelkan dengan mengikuti pendekatan model APL-UW yang terdiri atas hamburan kekasaran (*roughness scattering*) dan hamburan volume (*volume scattering*). Sinyal hamburan balik diturunkan oleh penjumlahan yang koheren dari sinyal yang diterima dari penghambur yang jatuh dalam area yang diensorifikasi secara instan. Tekanan sinyal suara MBES yang diterima pada waktu dan sudut datang tertentu diberikan sebagai (Gaida dkk., 2019):

$$p(t, \theta) = \sum_{j=1}^J s(t) \sqrt{\sigma_t(\phi_j)} b_p(\theta) \frac{e^{-2\hat{\alpha}r_j}}{r_j^2} \quad 2.29$$

di mana  $s(t)$  adalah tekanan sinyal suara yang ditransmisikan,  $b_p(\theta)$  adalah sudut pancaran dan  $J$  adalah jumlah penghambur  $j$  yang jatuh di area  $A(t)$  yang diensorifikasi secara instan pada saat  $(t)$ .  $\sigma_l(\phi_j)$  adalah penampang melintang hamburan balik target dari penghambur  $j$  di sudut datang  $\phi_j$ . Bagian  $\frac{e^{-2\hat{\alpha}r_j}}{r_j^2}$  memperhitungkan penyebaran geometris dua arah (penyebut) dan atenuasi sinyal dalam propagasi disipatif medium (pembilang). Tekanan sinyal suara yang ditransmisikan  $s(t)$  oleh MBES dapat dinyatakan sebagai gelombang tekanan sinusodial (Gaida dkk., 2019):

$$s(t) = \begin{cases} W(t - t_j)\sqrt{2}p_{rms} \sin(2\pi f(t - t_j)), & 0 < t - t_j < \tau \\ 0 & \text{selainnya} \end{cases} \quad 2.30$$

di mana  $\tau$  adalah panjang pulsa,  $p_{rms}$  adalah akar kuadrat rata-rata (*rms*) tekanan dari pulsa yang ditransmisikan dan  $W(t - t_j)$  adalah fungsi lancip Hanning untuk mencerminkan kelancaran sinyal. Waktu kedatangan setiap penghambur adalah  $t_j = \frac{2h}{c_0 \cos(\phi_j)}$ , di mana  $h$  adalah kedalaman air di bawah MBES,  $c_0$  adalah kecepatan suara dalam air dan  $\phi_j$  adalah sudut datang. Dengan asumsi kolom air homogen, perhitungan  $t_j$  tidak memerlukan pertimbangan pembiasan suara. Pola berkas penerima  $b_p(\theta)$  dinyatakan sebagai (Gaida dkk., 2019):

$$b_p(\theta) = \left( \frac{\sum_{m=0}^{M-1} e^{ik(s \sin \phi_j - \sin \theta)} \frac{m L_R}{M}}{M} \right)^2 \quad 2.31$$

di mana  $M$  adalah jumlah elemen penerima  $m$ ,  $k$  adalah angka gelombang dari sinyal yang ditransmisikan dan  $L_R$  adalah panjang larik penerima.

Hubungan antara bagian  $\sqrt{\sigma_t(\phi_j)}$  dalam ke penampang melintang *backscatter*  $\sigma_t(\phi_j)$  adalah akar kuadrat intensitas dengan tekanan nilai untuk penampang hamburan balik target  $\sigma_t(\phi_j)$  melalui (Gaida dkk., 2019):

$$\sigma_t(\phi_j) = \frac{I_b(\phi_j)}{I_i(\phi_j)} = \left( \frac{p_{rms_b}(\phi_j)}{p_{rms_i}(\phi_j)} \right)^2 \quad 2.32$$

dimana  $I_b$ ,  $I_i$ , dan  $p_{rms_b}$  menunjukkan intensitas dan rms tekanan dari hamburan balik dan gelombang datang. Penampang melintang hamburan balik target adalah terkait dengan penampang melintang hamburan balik melalui area yang diensifikasi secara instan sebagai (Gaida dkk., 2019):

$$\sigma_t(\phi) = \int_{A(t)}^{\square} \sigma_b(\phi) dA \quad 2.33$$

dimana  $\sigma_t(\phi)$  diperoleh dari model. Untuk memperhitungkan fluktuasi statistik yang melekat pada proses hamburan,  $\sigma_b(\phi)$  dimodelkan sebagai variabel

terdistribusi Rayleigh. Di sini,  $A = \frac{\Omega_T}{360} \pi x^2$  (dengan  $\Omega_T$  dalam derajat) mewakili sektor lingkaran dengan jari-jari  $x$  (yaitu, jarak dalam arah *across-track*) dan sudut bukaan  $\Omega_T$  (yaitu,  $\Omega_T = \frac{c_0}{f L_T}$  mewakili sudut bukaan sinar pada transmisi, dengan  $L_T$  panjang larik pemancar (proyektor). Dengan mengganti  $\frac{dA}{dx} = \Omega_T x$  ( $\Omega_T$  dengan dalam radian), berikut ini (Gaida dkk., 2019)

$$\sigma_t(\phi) = \Omega_T \int_{x_{lb}(t)}^{x_{ub}(t)} \sigma_b(\phi) x dx \quad 2.34$$

untuk kasus penghambur diskrit (Gaida dkk., 2019)

$$\sigma_t(\phi) = \Omega_T \sum_{j=1}^J \sigma_b(\phi_j) x_j \Delta x_j \quad 2.35$$

Penampang melintang hamburan balik target di setiap penghambur  $j$  dapat diekspresikan sebagai (Gaida dkk., 2019)

$$\sigma_t(\phi_j) = \Omega_T \sigma_b(\phi_j) x_j \Delta x_j \quad 2.36$$

dimana sudut datang setiap penghambur  $\phi_j$  terhubung ke rentang miring  $r_j$  atau kedalaman air  $h$  melalui jarak horizontal  $x_j$  dari setiap penghambur menuju penerima (Gaida dkk., 2019):

$$\phi_j = \sin^{-1} \left( \frac{x_j}{r_j} \right) \text{ atau } \phi_j = \tan^{-1} \left( \frac{x_j}{h} \right) \quad 2.37$$

Area yang diensorifikasi secara instan, yang mengandung  $J$  penghambur, dibatasi dalam arah horizontal (*across-track*) oleh batas bawah  $x_{lb}$  dan batas atas  $x_{ub}$  melalui (Gaida dkk., 2019)

$$A(t) = \frac{\Omega_T}{360} \pi (x_{ub}^2(t) - x_{lb}^2(t)) \quad 2.38$$

batas atas dapat dituliskan sebagai (Gaida dkk., 2019)

$$x_{ub}(t) = \sqrt{\frac{(c_0 t)^2}{4} - h^2} \quad 2.39$$

Kemiringan yang sesuai pada batas atas adalah  $r_{ub} = \sqrt{x_{ub}^2 + h^2}$

Semakin rendah dapat dinyatakan dengan ketergantungan pada  $t$  sebagai (Gaida dkk., 2019)

$$x_{lb}(t) = 0, \quad t \leq t_{nadir} + \tau \quad 2.40$$

$$x_{lb}(t) = \sqrt{\left(\frac{c_0 t}{2} - \frac{c_0 \tau}{2}\right)^2 - h^2}, \quad t \geq t_{nadir} + \tau \quad 2.41$$

$$\text{dimana } t_{nadir} = \frac{2h}{c_0}$$

Untuk memodelkan sinyal tekanan dalam media berlapis, perambatan suara bawah permukaan dan hamburan di lapisan terkubur perlu dipertimbangkan. Pembiasan sinyal ke bawah permukaan mengubah sudut datang melalui hukum Snell (Gaida dkk., 2019)

$$\frac{\sin(\phi_{j,l+1})}{\sin(\phi_{j,l})} = \frac{c_l}{c_{l-1}} \quad 2.42$$

di mana  $l$  menunjukkan lapisan. Mengingat media berlapis dengan  $L_n$  jumlah total lapisan setiap variabel diperpanjang dengan indeks  $l$ . Batas atas dalam perubahan untuk media berlapis menjadi (Gaida dkk., 2019)

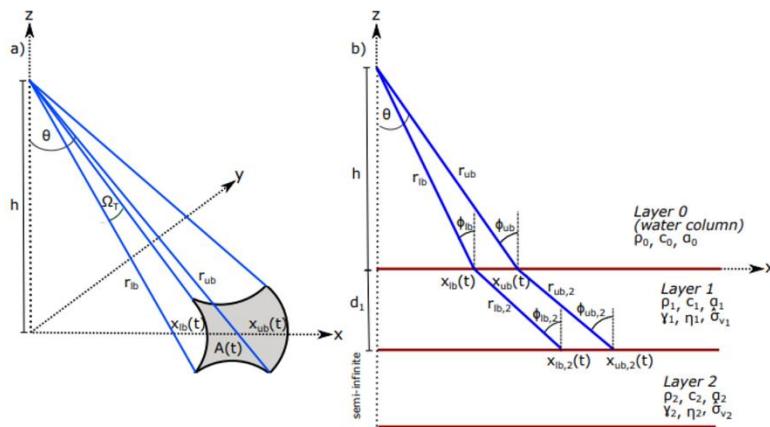
$$x_{ub,L_n}(t) = \sqrt{\frac{(c_0 \delta t_0)^2}{4} - h^2} + \sum_{l=2}^{L_n} \sqrt{\frac{(c_{l-1} \delta t_{l-1})^2}{4} - d_{l-1}^2} \quad 2.43$$

dimana  $c_l$  adalah kecepatan suara dan  $\delta t_l$  waktu tempuh pada lapisan  $l$  dan  $\delta t_0$  adalah waktu tempuh waktu di kolom air. Batas bawah disesuaikan untuk media

berlapis sesuai Gambar 2.9. Untuk mendapatkan sinyal tekanan  $p(t, \theta)$  tersebar dari lapisan medium sinyal individu yang tersebar dari setiap lapisan dijumlahkan secara koheren berdasarkan (Gaida dkk., 2019)

$$p(t, \theta) = \sum_{l=1}^{L_n} p_l(t, \theta) \quad 2.44$$

Untuk lapisan terkubur, istilah atenuasi diperpanjang untuk suara redaman pada sedimen.



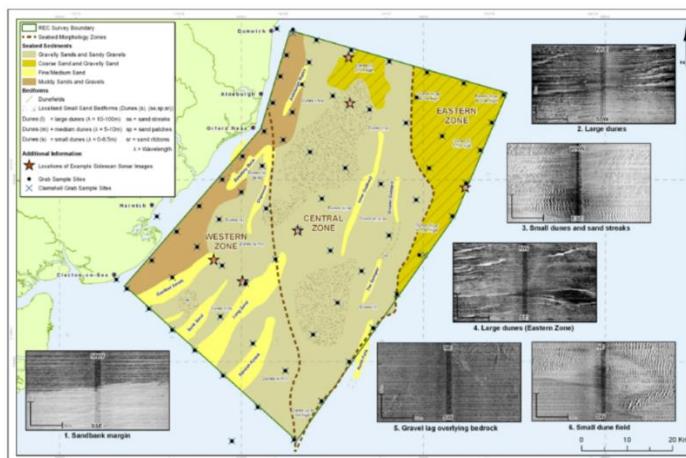
Gambar 2.9 Skema model BS berlapis dan model deteksi bawah. a) jejak MBES di dasar laut b) tampilan profil melintang media berlapis (dua lapis) (Gaida dkk., 2019).

## 2.4 Side Scan Sonar

*Side Scan Sonar* (SSS) merupakan salah satu peralatan akustik yang sangat baik untuk pengamatan bawah laut karena dapat mengukur area yang luas secara efisien dan menghasilkan gambar terperinci dari dasar laut. SSS dapat digunakan untuk pemetaan dasar laut seperti peta laut, deteksi dan identifikasi objek bawah air. Peta sedimen dasar laut dapat digambarkan dengan data SSS yaitu dengan menganalisis sinyal balik (*backscatter*) yang tersebar kembali ke *side-scan sonar* dan pengambilan sampel sedimen dengan menggunakan *grab sampler* atau *sediment core* di beberapa titik untuk validasi jenis sedimen. Pengolahan data SSS

akan menghasilkan peta sebaran sedimen dasar laut (Gambar 2.10) yang bersifat kontinyu).

Barnhardt dkk (1998) menggunakan SSS untuk memetakan dan mengklasifikasikan area dasar laut yang kompleks di Teluk Maine. Survei ini menggunakan klasifikasi visual dari gambar sonar yang divalidasi dengan sampel sedimen. McRea, dkk (1999) menggunakan SSS untuk mengkarakterisasi habitat batuan di dekat Pulau Kruzof, Alaska menggunakan sampel sedimen dan video untuk validasi. Sangat menarik untuk dicatat bahwa sisi yang dapat digunakan dalam survei ini adalah interferometrik dan mampu memberikan batimetri, meskipun hamburan balik yang diklasifikasikan secara visual lebih banyak digunakan untuk menggambarkan tipe habitat. Dalam survei komprehensif dan kuantitatif dari suatu area dalam *English Channel*. Brown et al. (2002) membandingkan jenis sedimen, dan pengambilan sampel biologis dengan klasifikasi *side scan sonar* dari perangkat lunak *DelphMap* untuk mengklasifikasikan biotop bentik. *Gray Level Co-Occurance Matrix (GLCM)* digunakan oleh Cochrane dan Lafferty (2001) untuk membedakan daerah-daerah dengan tekstur berbeda di Kepulauan Channel, California. Collier dan Brown (2005) mengorelasikan data *backscatter* SSS dengan ukuran butir distribusi sedimen dasar laut permukaan. Hasilnya menunjukkan adanya korelasi positif sebesar  $r = 0,73$  antara intensitas *backscatter* rata-rata dengan ukuran butiran sedimen rata-rata.

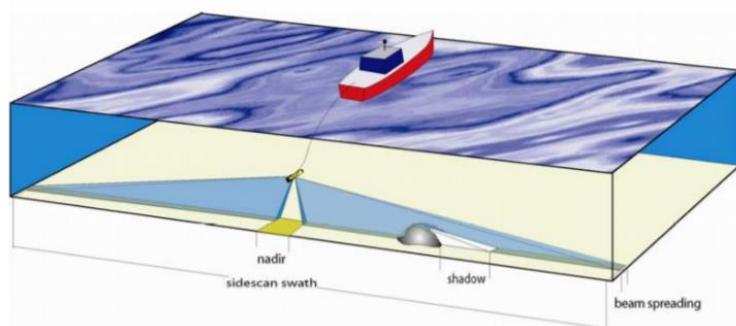


Gambar 2.10 Peta sedimen dasar *Outer Thames Estuary* dengan SSS

(Selby, dkk., 2009)

Berthold (2017) menggunakan SSS untuk klasifikasi sedimen dasar laut di German Bight dengan metode Jaringan Saraf Konvolusional (*Convolutional Neural Networks*). Hasil penelitian ini menunjukkan bahwa area studi diklasifikasi kedalam empat tipe sedimen yaitu sedimen halus, pasir dan sedimen kasar serta sedimen campuran, dengan akurasi pasir paling tinggi yaitu 83% dan akurasi sedimen halus yang paling rendah yaitu 11%. Lubis, dkk (2017) menggunakan SSS tipe *C-Max CM2* dengan frekuensi 325 kHz di Laut Punggur, Kepulauan Riau, Indonesia. Hasil penelitiannya menunjukkan bahwa sedimen dasar laut didominasi oleh pasir dibandingkan dengan lumpur. Selain itu juga ditemukan bangkai kapal yang tenggelam di Trek 1 dan Trek 3.

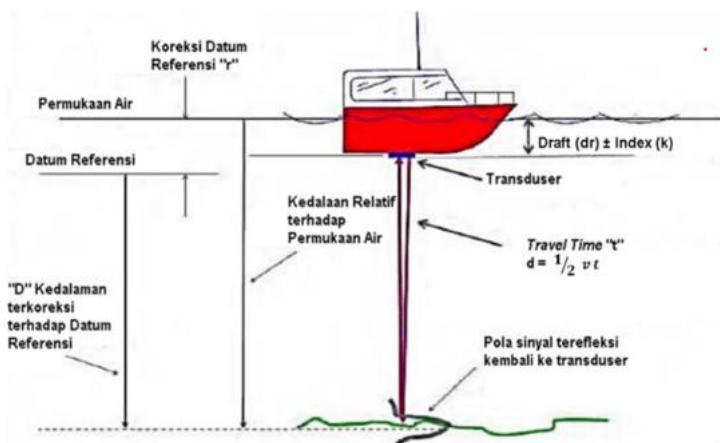
Kelemahan dari survei dengan SSS ini adalah untuk mendapatkan posisi horisontal dari SSS yang tepat dan akurat. Hal ini disebabkan oleh instalasi alat SSS yang pada umumnya ditarik dengan kapal atau yang dikenal dengan istilah *tow-fish* dengan sepanjang kabel (Gambar 2.11). Kabel *tow-fish* tidak stabil posisinya dan bergantung pada gelombang dan arus laut, sehingga penentuan posisi *tow-fish* tidak akurat walaupun menggunakan *GNSS RTK*. Untuk mendapatkan hasil citra dengan resolusi yang tinggi maka *tow-fish* harus diletakkan sedekat mungkin dengan permukaan dasar laut. Semakin dalam lautan maka akan membutuhkan semakin panjang kabel untuk menarik *tow-fish* dan tentunya tidak mudah untuk mengukur dengan kedalaman lebih dari 1000 meter. Selain posisi horisontal yang kurang teliti, hasil kedalaman (batimetri) dari SSS juga kurang teliti. Untuk menghasilkan informasi kedalaman dan sedimen dasar laut yang akurat perlu digabung dengan survei dengan *Single Beam Echosounder (SBES)*.



Gambar 2.11 *Tow-fish SSS* (Penrose, 2005)

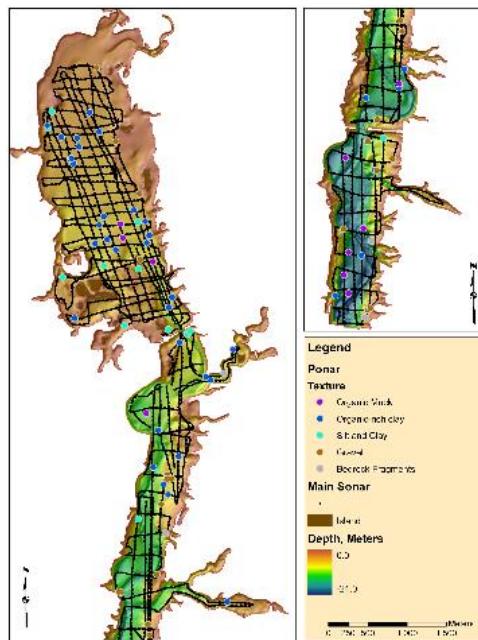
## 2.5 Single Beam Echo Sounder

*Single Beam Echo Sounder* (SBES) merupakan salah satu peralatan dengan menggunakan gelombang akustik untuk menentukan kedalaman air laut. Sampai saat ini, SBES masih sering digunakan dalam survei hidrografi untuk pembuatan peta batimetri. Prinsip dasar SBES adalah mengukur waktu tempuh dua arah (*two way ranging*) antara pembangkit gelombang akustik yang disebut dengan transduser (*transmitter* dan *receiver*) dan permukaan dasar laut (Gambar 2.12).

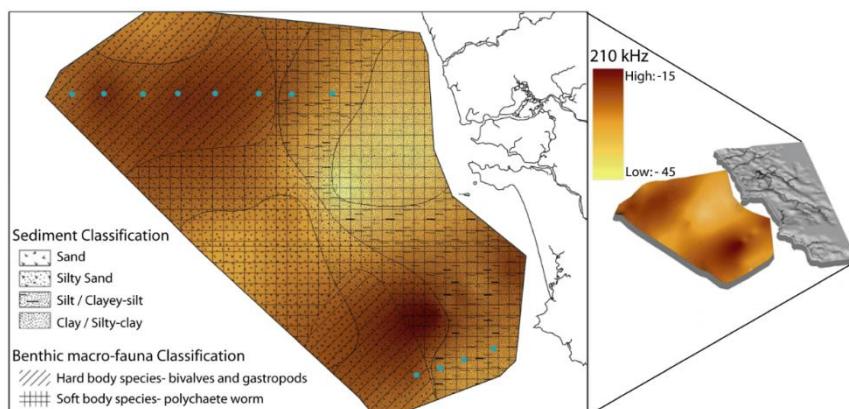


Gambar 2.12 Prinsip SBES (US Army, 2013)

Pemetaan batimetri dengan SBES dimana datanya bergantung pada jumlah lajur perum, maka diperlukan interpolasi kontur untuk merapatkan datanya (Gambar 2.13). Proses yang sama dilakukan untuk mendapatkan peta distribusi sedimen dasar dengan menggunakan *backscatter* SBES dan divalidasi dengan data sedimen dasar yang diambil dengan *grab sampler* atau *gravity core* (Gambar 2.14).



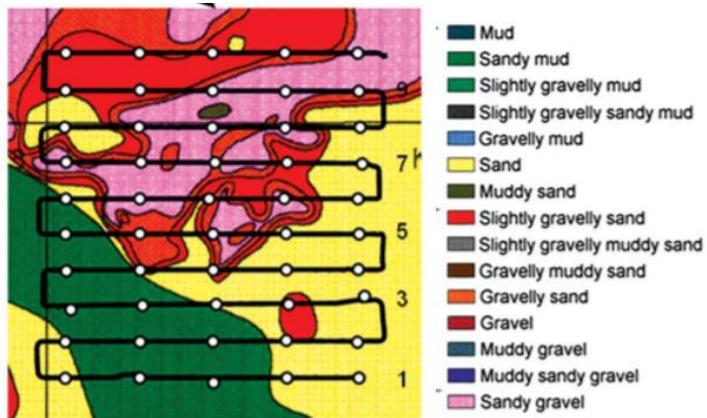
Gambar 2.13 Lajur perum dan peta batimetri dari SBES (Venteris and May 2014)



Gambar 2.14 Peta sedimen dasar laut dengan *Backscatter* SBES (Haris, dkk, 2012)

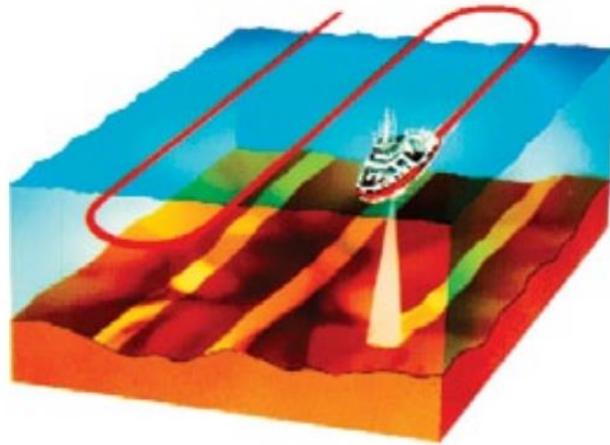
Snellen, dkk (2011) menggunakan SBES untuk klasifikasi sedimen dasar laut dengan menggunakan dua metode yaitu *echo envelope* dan evolusi. Metode *echo envelope* memaksimalkan informasi dalam sinyal akan tetapi membutuhkan model dan optimasi yang kompleks. Sedangkan metode evolusi bertujuan untuk mengurangi informasi sinyal menjadi energi saja dan langsung menghubungkannya dengan koefisien refleksi untuk mendapatkan informasi kuantitatif tentang parameter sedimen. Metode pertama menyediakan informasi variasi tipe sedimen

(ukuran sedimen) (Gambar 2.15), serta menyediakan estimasi untuk kekuatan spektral dan parameter volume hamburan. Dalam pendekatan kedua, kurangnya informasi tentang parameter-parameter ini dan terbatasnya *beamwidth* SBES ditunjukkan untuk menghambat konversi energi gema menjadi koefisien refleksi.



Gambar 2.15 Peta sebaran sedimen dasar dengan SBES (Snellen, dkk 2011)

Kelemahan dari SBES ini adalah hanya dapat mengukur satu titik per gelombang gema akustik yang dipancarkan. Spesifikasi SBES ditentukan oleh sudut pancaran (*beam angle*) dan frekuensi gelombang akustik yang ditransmisikan dari transduser. Keunggulan SBES ini adalah biaya operasional yang relatif lebih murah, mudah dioperasikan, dapat digunakan untuk mengukur kedalaman sampai ribuan meter (bergantung pada frekuensinya), pengolahan data yang mudah dan simpel dan menggunakan dual frekuensi (frekuensi rendah dan frekuensi tinggi) secara bersamaan dalam satu *ping* selama survei (Anderson, dkk., 2008). Kelemahan dari SBES yang lain adalah hasil dari survei SBES ini mempunyai resolusi spasial yang rendah yang bergantung pada spasi antar lajur perumnya (*sounding line*) (Gambar 2.16). Semakin rapat lajur perumnya maka semakin teliti hasilnya akan tetapi akan membutuhkan waktu survei yang lebih lama dan akhirnya biaya yang ditimbulkan akan semakin tinggi. Resolusi spasial yang rendah akan mengakibatkan objek yang berbahaya (*feature hazard*) untuk keperluan navigasi tidak akan terdeteksi kalau objek tersebut tidak dilewati oleh kapal survei pada lajur perumnya (Kearns, and Breaman, 2010).



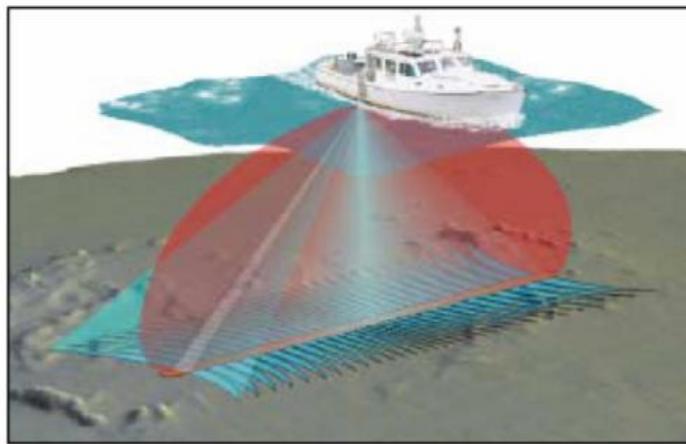
Gambar 2.16 Resolusi spasial SBES (Kearns, and Breaman, 2010)

## 2.6 Multi Beam Echo Sounder

### 2.6.1 Prinsip Multi Beam Echo Sounder

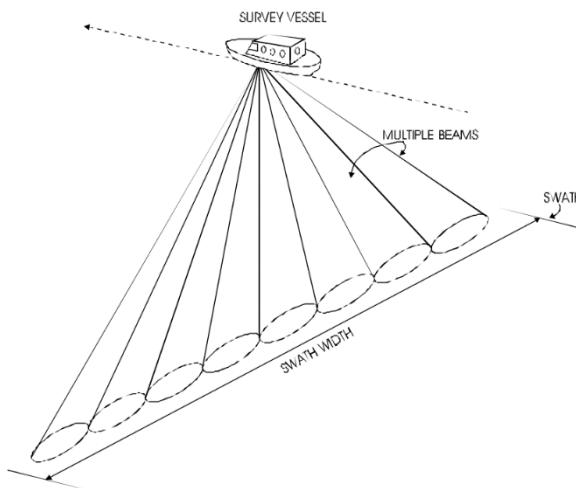
*Multi Beam Echo Sounder* (MBES) digunakan untuk meningkatkan cakupan dasar (*bottom coverage*) yang nantinya akan meningkatkan produktifitas pada saat survei hidrografi dilakukan. Setiap *beam*-nya akan menghasilkan resolusi kedalaman yang ekivalen dengan beam yang ada pada SBES. Akan tetapi akurasinya akan menurun dengan meningkatnya sudut sapuan (*swath angle*) (de Jong, dkk., 2010). Ada dua sistem MBES yaitu sistem *swath* (*swath system*) dan sistem sapuan (*sweep system*). Sistem *swath* menghasilkan banyak *beam* dengan *transducer* tunggal, sedangkan sistem sapuan menggunakan banyak transducer dalam bentuk susunan yang dipasang di samping kapal (kanan dan kiri) dan tegak lurus kapal. Akan tetapi sistem sapuan ini sudah lama ditinggalkan.

Secara umum prinsip umum MBES diilustrasikan pada Gambar 2.17 (Penrose, dkk., 2005), dimana *sonar* transduser memancarkan pulsa akustik yang disebarluaskan di dalam jalur lebar yang tegak lurus (*wide across-track*) dan jalur sempit yang searah (*narrow along-track angular sector*). Array penerima diarahkan secara tegak lurus ke transmisi *array* membentuk sejumlah besar balok menerima yang sempit di trek dan dikemudikan secara bersamaan di berbagai arah lintas trek dengan proses *beam forming*.



Gambar 2.17 Prinsip MBES (Penrose, dkk., 2005)

MBES merupakan instrumen akustik yang dapat mengukur kedalaman dasar laut lebih dari satu lokasi dengan sekali pancaran (*ping*). Dengan demikian, data MBES mempunyai resolusi spasial yang lebih tinggi dibandingkan dengan data SBES. Sekali pancaran sinyal MBES akan memetakan area yang berbentuk *swath* (Gambar 2.18) yang tegak lurus terhadap lajur survei (SeaBeam, 2000).



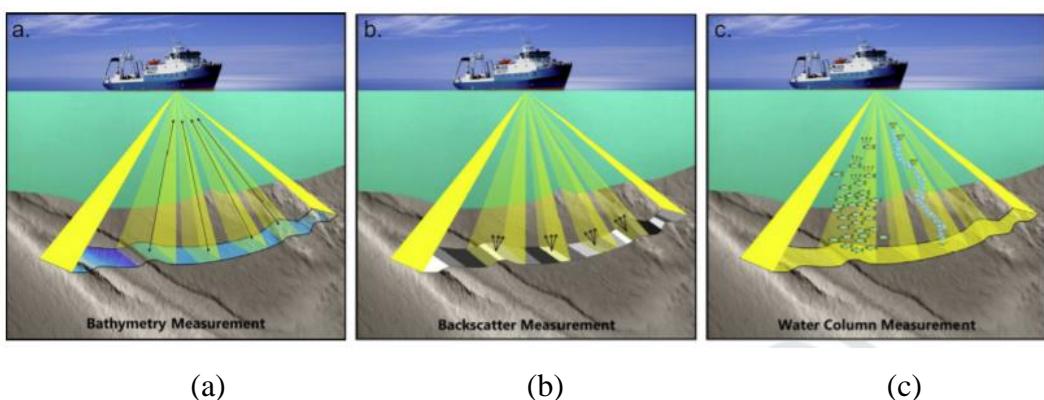
Gambar 2.18 *Swath Multi Beam Echo Sounder* (SeaBeam, 2000)

Biaya peralatan dan perlengkapan untuk survei dengan MBES jauh lebih mahal dibandingkan dengan survei SBES. Hal ini disebabkan oleh peralatan yang digunakan survei MBES jauh lebih kompleks dan lengkap dibandingkan dengan SBES. Akan tetapi biaya mahal tersebut dikompensasi dengan pelaksanaan survei yang jauh lebih cepat yang menghemat berkurangnya waktu pengoperasian kapal

dan resolusi spasial data yang dihasilkan juga jauh lebih rapat dibandingkan dengan SBES. Kelemahan lain dari MBES ini adalah volume data yang besar dan membutuhkan kalibrasi kompleks (*pitch*, *yaw*, *roll*, dan profil kecepatan suara).

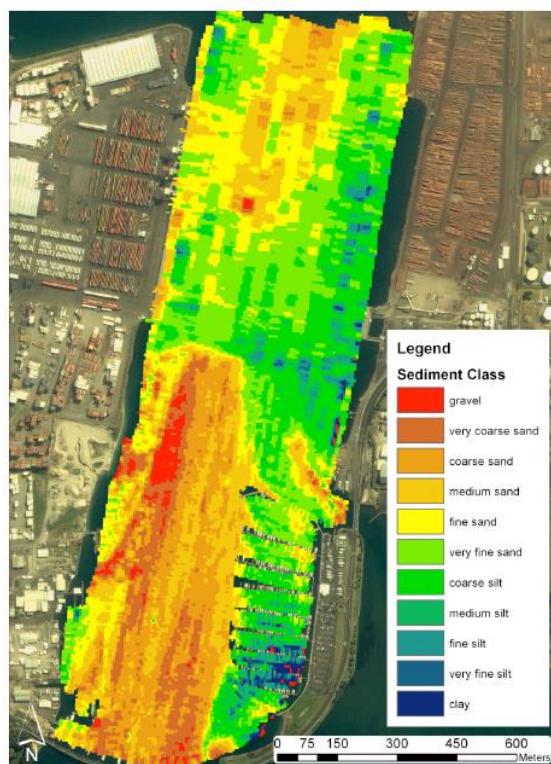
### 2.6.2 Backscatter MBES

Pada awalnya, pertama kali munculnya teknologi MBES digunakan untuk survei batimetri dan hidrografi dengan tujuan memetakan dasar laut. Daya tarik utama MBES ini adalah cakupan dasar laut area luas yang ditawarkan oleh sistem *swath* (Gambar 2.19 (a)) dari satu lintasan platform survei, memberikan data navigasi yang unggul dibandingkan dengan SBES, yang pada akhirnya mengurangi risiko bagi surveyor di laut. Selain untuk keperluan pemetaan batimetri dengan menyapu seluruh area yang dipetakan (*full coverage*), MBES juga mampu digunakan untuk pemetaan sedimen dasar laut dengan memanfaatkan hambur balik (*backscatter*) (Gambar 2.19 (b)) sinyal akustik yang dipancarkannya (de Moustier, 1986). *Backscatter* MBES ini mirip dengan *backscatter side scan sonar* (Colbo, 2014), dan dapat digunakan untuk mengklasifikasi dasar laut yang berupa karakteristik kekerasan (*hardness*) dan kekasaran (*roughness*) karakteristik dan sangat berharga pengukuran saat mempelajari geologi permukaan dasar laut. Selain itu, pengembalian gelombang akustik juga dapat dideteksi dari benda-benda yang berada di kolom air (*water column*) seperti ikan, gelembung gas, sedimen laying dan lainnya (Gambar 2.19 (c))



Gambar 2.19 Aplikasi MBES: (a) batimetri, (b) *backscatter* (c) *water coloumn* (Colbo, 2014)

Hambur balik gelombang akustik merupakan gelombang akustik yang dipancarkan oleh transduser (*transmitter – receiver*) ke sedimen dasar laut dan menghasilkan sebagian dari sinyal pantulan (hamburan balik) yang kembali ke transduser dikenal dengan istilah *backscatter*. Nilai reflektivitas yang mewakili reflektivitas dasar laut, diperoleh dengan amplitudo dari sinyal balik dan mencakup beragam sudut datang transducer. Reflektifitas yang tinggi menunjukkan sedimen dasar yang keras seperti pasir dan batu kerikil, dan reflektivitas yang rendah menunjukkan sedimen dasar laut yang lunak seperti lumpur dan lempung. MBES dapat mencirikan sedimen dasar laut dengan menggunakan sifat geo-akustiknya seperti ukuran butir, kekasaran, kecepatan suara dan porositas (Brown & Blondel, 2009). Karakter sedimen tersebut dapat ditentukan melalui pengukuran tidak langsung dari hambur balik (*backscatter*) dan perbandingannya dengan model teoritis (Fonseca & Mayer, 2007). Nilai *backscatter* lebih tinggi pada substrat keras, seperti batu, dan lebih lemah pada sedimen lunak seperti lumpur.

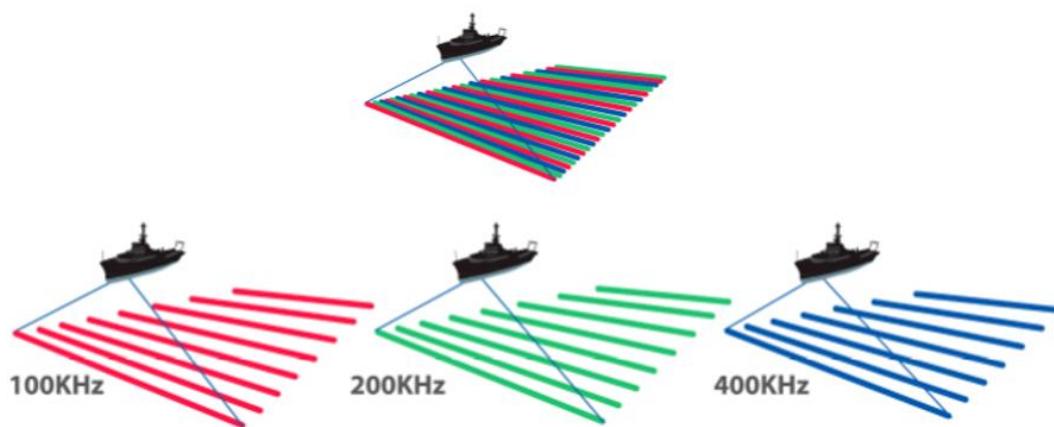


Gambar 2.20 Peta sedimen dasar laut dengan MBES (Boulay, 2012)

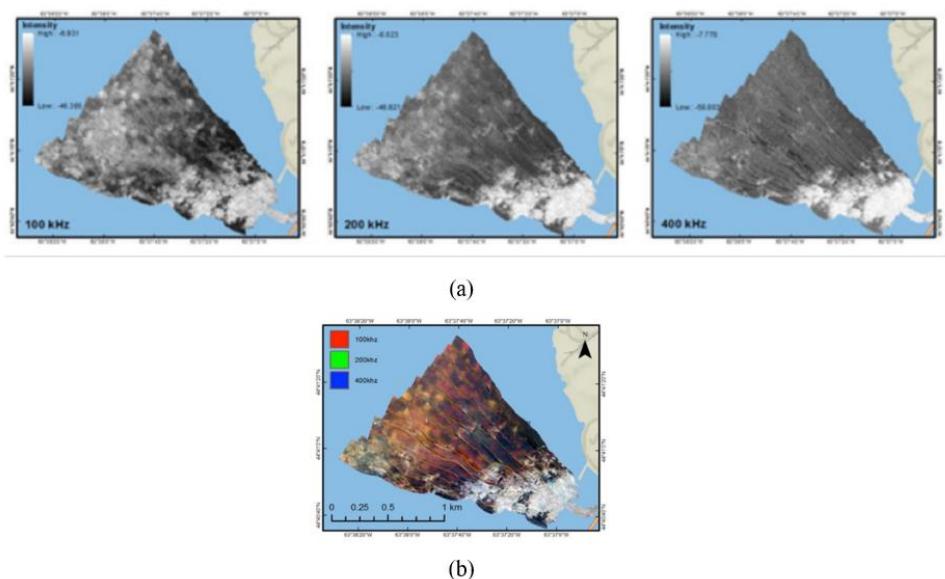
Data MBES yang didukung dengan data sampel sedimen dasar laut yang diambil dengan *grab sampler* ataupun *gravity core* dapat menghasilkan peta distribusi sedimen dasar yang kontinyu dan mempunyai resolusi yang lebih baik dibandingkan dengan data lain yang ada saat ini (Gambar 2.20).

### 2.6.3 MBES Multi Frekuensi

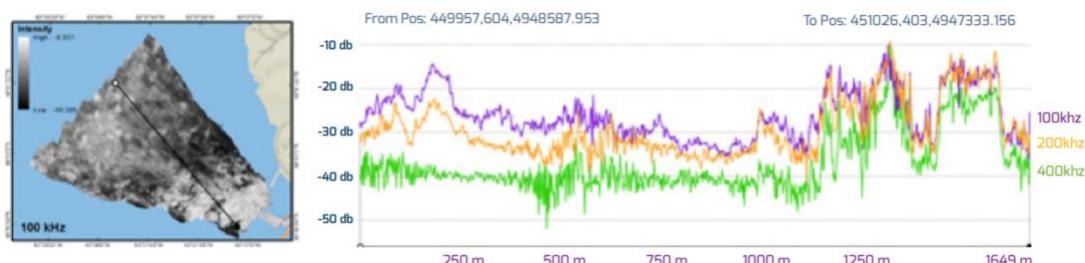
Pada tahun 2017, R2Sonic LLC, memproduksi MBES R2Sonic 20 series (2020, 2022, 2024 dan 2026) multi mode frekuensi. Produk ini memungkinkan untuk akuisisi data lebih dari satu frekuensi (multi frekuensi) dalam sekali survei berdasarkan *ping-by-ping*. Produk MBES R2Sonic 20 series ini merupakan salah satu produk yang mempunyai kemampuan secara simultan (Gambar 2.21) untuk mengumpulkan data secara simultan dari beberapa frekuensi sekaligus dalam sekali pengambilan data dari sistem MBES (Brown, dkk., 2017 dan Brown, dkk., 2019). Hasil survei MBES multispektral dari masing-masing frekuensi yang diolah dapat digabung (mosaik) satu sama lain (Gambar 2.22) (Brown, dkk., 2017 dan Brown, dkk., 2019). Gambar 2.23 menunjukkan perbedaan profil intensitas hamburan balik dari frekuensi yang berbeda di lokasi yang sama.



Gambar 2.21 MBES Multi frekuensi berbasis *ping by ping* (Brown, dkk., 2017 dan Brown, dkk., 2019)



Gambar 2.22 *Backscatter MBES* (a) multispektral dan (b) gabungan warna  
(Brown, dkk., 2017 dan Brown, dkk., 2019)



Gambar 2.23 Perbandingan perbedaan intensitas hamburan balik dalam satu lokasi survei antara mosaik multispektral (Brown, dkk., 2017 dan Brown, dkk., 2019)

## 2.7 Review Pemetaan Klasifikasi Sedimen Dasar Laut dengan MBES

### Multispektral

Saat ini, hanya R2Sonic yang memproduksi satu-satunya MBES yang mampu melakukan survei pada beberapa frekuensi (hingga 5) dalam satu lintasan dan dengan satu sistem yaitu dengan *mode* multifrekuenpsi. *Mode* multifrekuenpsi dapat diterapkan pada survei hamburan balik, menawarkan kemungkinan untuk mengumpulkan data hamburan balik multifrekuenpsi. Intensitas respon akustik untuk setiap frekuensi berbeda-beda tergantung dari jenis sedimennya. Dengan membandingkan respons yang berbeda ini, para ilmuwan dapat membangun peta

*red, green, blue* (RGB) dasar laut, yang telah terbukti menjadi langkah pertama menuju karakterisasi dasar. Kemampuan R2Sonic yang mensurvei hingga 5 frekuensi dalam satu lintasan (*ping by ping*) dan dengan satu MBES memberikan beberapa keuntungan (R2Soinc, 2022):

- Meningkatkan produktivitas
- Ini mengurangi biaya yang terkait dengan survei multifrekuensi tradisional yang memerlukan beberapa MBES atau beberapa lintasan
- Semua 5 frekuensi memiliki *grazing angle* yang sama, yang meningkatkan keseragaman, akurasi, dan presisi

Beberapa produsen menggabungkan data hamburan balik dengan kolom air dan kemampuan multi-frekuensi, memungkinkan lebih banyak informasi untuk dikumpulkan. Keuntungan menggabungkan *backscatter* dengan data kolom air adalah objek di kolom air dapat diidentifikasi dengan lebih baik. Kombinasi *backscatter* dengan multi-frekuensi sangat berguna untuk klasifikasi bawah dasar laut. Karena bahan dapat bereaksi secara berbeda terhadap frekuensi yang berbeda, mengukur hamburan balik pada frekuensi yang berbeda tetapi pada saat yang sama dapat memberikan algoritma klasifikasi informasi yang lebih baik untuk digunakan.

Perkembangan selama satu dekade terakhir pemetaan sedimen dasar laut dengan mengaplikasikan MBES multi frekuensi untuk mendapatkan backscatter multispektral sedimen dasar laut dapat dilihat pada Tabel (Tabel 2.2). Clarke (2015) mencoba menggabungkan 2 MBES yaitu frekuensi rendah EM710 (70-100 kHz) dan frekuensi tinggi EM2040 (200-400 kHz) untuk mendapatkan *backscatter* multispektral. Hasil penelitiannya menunjukkan ada perbaikan dalam hal diskrimansi sedimen dasar laut. Hal ini ditunjukkan dengan perubahan kurva response sudut (*Angular Response Curve / ARC*) dari satu frekuensi dengan frekuensi lainnya. Kelemahan dari penelitian Clarke ini adalah masih menggunakan 2 type alat MBES yang berbeda sehingga kurang efektif dan efisien dalam hal akuisisi data di lapangan. Brown, dkk (2017) dan Brown, dkk (2019) mengevaluasi penggunaan MBES multifrekuensi (100 kHz, 200 kHz dan 400 kHz) untuk menghasilkan multispektral *backscatter* dalam sekali survei pengukuran (Gambar 2.19). Ide dasar penggunaan multifrekuensi ini adalah seperti satelit penginderaan jauh dengan menggunakan beberapa panjang gelombang (multispektral).

Penggunaan multispektral bertujuan untuk memperbaiki hasil pemetaan sedimen dasar dengan menggunakan *MBES*.

Brown dan Varma (2018) menggunakan MBES multispektral (100 kHz, 200 kHz dan 400 kHz) R2Sonic2026 berbasis *ping by ping* di 2 lokasi yang berbeda dengan kedalaman 13 - 85 m (Bedford Basin) dan 20 – 70 m (Patricia Bay). Metode klasifikasi yang digunakan untuk mengklasifikasi sedimen dasar lautnya adalah *hypercube* multidimensi. Hasil dari tiga area pengujian menunjukkan bahwa pendekatan tersebut dapat digunakan untuk mengidentifikasi karakteristik pola di dasar laut secara akurat, menawarkan pendekatan yang serbaguna, dapat diulang, dan mudah digunakan untuk segmentasi dasar laut. Dengan menggunakan data di lokasi yang sama, Gaida, dkk (2018) menggunakan MBES multispektral dan metode *Bayesian* multispektral menghasilkan adanya indikasi informasi tambahan pada klasifikasi sedimen di dasar laut, dan menghasilkan diskriminasi akustik yang lebih baik dibandingkan dengan frekuensi tunggal.

Peneliti lainnya, Buscombe dan Grams (2018) dengan menggunakan data MBES multispektral R2Sonic2026 (90 kHz, 100 kHz, 200 kHz, 300 kHz dan 450 kHz) dan metode *Gaussian Mixture Model* (GMM) dan *Condition Random Field* (CRF) menunjukkan hasil yang kurang sensitif terhadap jumlah spesifik dan lokasi pengamatan dasar laut daripada model generatif. Costa (2018) dengan metode *Boosted Regression Tree* (BRT) menunjukkan bahwa metode BRT di lingkungan beriklim sedang, mampu memetakan habitat bentik secara andal dan akurat menggunakan data multispektral (100 kHz, 200 kHz dan 400 kHz). Selain itu, hasilnya juga menunjukkan bahwa data multispektral dapat meningkatkan kemampuan untuk membedakan antara sedimen dasar yang halus.

Feldens, dkk (2018) dengan metode mosaik dan *angular response curve* (ARC) pada *backscatter* multi frekuensi ini dapat memperbaiki interpretasi fitur sedimen dasar yang halus. Selain itu juga mosaik multispektral sangat menjanjikan untuk mendeteksi kehidupan bentik, yang dapat bervariasi dari waktu ke waktu. Namun, untuk aplikasi praktis data multispektral untuk pemetaan habitat, masih ada kekurangan informasi untuk menginterpretasikan banyak fitur hambur balik dari dasar laut. Hasil penelitian Gaida, dkk (2019) dengan menggunakan MBES multi frekuensi dan metode *Layer Backscatter Model* (LBM), *Bottom Detection Model*

(BTM) dan *Angular Response Curve* (ARC) menghasilkan beberapa hasil penelitian sebagai berikut:

1. Selisih batimetri terukur perbedaan antara frekuensi terendah (90 kHz) dan tertinggi (450 kHz) di daerah berlumpur sedimen mencapai nilai hingga 60 cm tergantung pada lokasi dan sudut datang.
2. Dalam korespondensi spasial dengan variasi perbedaan kedalaman, tingkat *backscatter* pada frekuensi terendah bervariasi hingga 15 dB untuk sedimen berlumpur sedangkan *backscatter* pada frekuensi tertinggi hanya menunjukkan variasi kecil.
3. Deteksi bawah permukaan dengan MBES menunjukkan bahwa batimetri diukur pada frekuensi tertinggi dan terendah dapat digunakan untuk menentukan ketebalan lapisan tipis (~20 cm).

Gaida, dkk (2019) menyarankan untuk menganalisis *backscatter* multispektral yang dikombinasikan dengan perbedaan batimetri antar frekuensi untuk memastikan interpretasi dan klasifikasi yang benar atas data *backscatter* multispektral.

Mertikas & Karanzalos (2020) masih menggunakan data yang sama yaitu MBES Multispektral R2Sonic 2026 dengan frekuensi 100 kHz, 200 kHz dan 400 kHz dan metode *Random Forest* dan *Support Vector Machines* mampu mengevaluasi secara kualitatif dan kuantitatif yang dilakukan beserta perbandingannya dengan *metode lainnya* menunjukkan potensi yang cukup menjanjikan dari pendekatan yang digunakan. Runya, dkk (2021) menggunakan MBES multispektral dengan 3 alat Kongsberg Simrad EM3002 (300 kHz), Simrad EM302 (30 kHz) dan EM1002 (95 kHz) dan metode *Texture Extraction (the Grey Level Co-occurrence Matrix (GLCM))* untuk meningkatkan analisis data secara visual dan meningkatkan pemahaman tentang variabilitas frekuensi tekstur untuk sedimen yang berbeda. Hasil penelitian menunjukkan bahwa analisis multispektral mempunyai kelebihan dalam hal pemrosesan, penyimpanan data, dan mengatasi gangguan operasional selama akuisisi dengan frekuensi rendah (30 kHz).

Vondervoort dan Lekkerkerk (2021) menghasilkan penelitian yang kontradiktif dengan peneliti lainnya yaitu penggunaan *bakcscatter* multispektral MBES tidak mampu memperbaiki kualitas hasil klasifikasi sedimen. Vondervoort dan Lekkerkerk mencoba menggunakan frekuensi 200 kHz, 400 kHz dan 700 kHz

di perairan Vinkeveense Plassen, the IJ (Amsterdam) and Ijmuiden, Nederland. Metode klasifikasi yang digunakannya adalah *angle response analysis* (ARA). Klasifikasi sedimen monospektral dengan frekuensi 400 kHz hasilnya mempunyai akurasi yang lebih baik dibandingkan dengan multispektralnya.

Selama sembilan tahun terakhir (2015 – 2023) penelitian terkait dengan MBES multispektral didominasi oleh penggunaan R2Sonic 2026 yang berbasis pada *ping by ping* dan menggunakan kombinasi 3 frekuensi 100 kHz, 200 kHz dan 400 kHz. Hanya Gaida, dkk (2019) dengan menggunakan R2Sonic 2026 multi-mode dengan 5 frekuensi 90 kHz, 100 kHz, 200 kHz, 300 kHz dan 450 kHz. Masing-masing peneliti menggunakan metode yang berbeda untuk melakukan klasifikasi sedimen dasar laut dengan MBES multi frekuensi ini. Secara umum ada 2 metode klasifikasi data *backscatter* MBES baik *single* maupun *multi* frekuensi (Lurton dan Lamarche, 2015) yaitu pemrosesan sinyal (*signal processing*) dan pemrosesan citra (*image processing*).

Tabel 2.2 *Review* hasil penelitian dari peneliti sebelumnya terkait dengan penggunaan MBES multifrekuensi dalam klasifikasi sedimen dasar laut.

No	Deskripsi	
1	Peneliti	Clarke, 2015
	Frekuensi (kHz)	EM710 (70 - 100); EM2040 (200 - 400)
	Kedalaman (m)	1. Saipan Reef (26 – 40) 2. Cordova Channel Dunefield (14 – 38) 3. Roberts Point (15 – 34)
	Metode	<i>Angular Response Curve (ARC)</i>
	Hasil	1. MBES Multifrequency dapat membedakan perubahan pola spasial 2. Terjadi perubahan ARC secara signifikan baik dalam bentuk maupun tingkat sebagai fungsi frekuensi.
	Review	1. Terobosan baru dalam hal penggunaan MBES multispektral untuk klasifikasi sedimen dasar laut

No	Deskripsi	
		2. Kelemahannya masih menggunakan lebih dari satu MBES dan dilaksanakan pada waktu yang berlainan
2	Peneliti	Brown (2017)
	Frekuensi (kHz)	R2Sonic2026 (100, 200 dan 400)
	Kedalaman (m)	1. Bedford Basin (13 – 85) 2. Patricia Bay (20 – 70)
	Metode	Mosaik Backscatter
	Hasil	1. Evaluasi terhadap penggunaan MBES multifrequency 2. Memperbaiki hasil interpretasi dan klasifikasi sedimen dasar laut
	Review	1. Hanya menggunakan satu alat MBES berbasis <i>ping by ping</i> (menghemat waktu dan biaya) 2. Ide yang digunakan seperti yang digunakan di remote sensing yaitu kombinasi band multispektral)
3	Peneliti	Brown & Varma (2018)
	Frekuensi (kHz)	R2Sonic2026 (100, 200 dan 400)
	Kedalaman (m)	1. Bedford Basin (13 – 85) 2. Patricia Bay (20 – 70)
	Metode	Multidimensional <i>Hypercube (Hypercube Segmentation)</i>
	Hasil	Hasil dari dua area pengujian menunjukkan bahwa pendekatan tersebut dapat digunakan untuk mengidentifikasi pola di dasar laut secara akurat, serbaguna, dapat diulang, dan mudah digunakan untuk segmentasi dasar laut.
	Review	Berbasis pada <i>ping by ping</i> survei (hanya 1 alat yang digunakan) pada saat survei.

No	Deskripsi	
		Metodologi ini menawarkan potensi yang sangat besar untuk memperbaiki bagaimana cara menyimpan, memanipulasi dan mengklasifikasi kumpulan data geospasial
4	Peneliti	Gaida, dkk (2018)
	Frekuensi (kHz)	R2Sonic2026 (100, 200 dan 400)
	Kedalaman (m)	<ol style="list-style-type: none"> <li>1. Bedford Basin (13 – 85)</li> <li>2. Patricia Bay (20 – 70)</li> </ol>
	Metode	<i>Multispectral Bayesian</i>
	Hasil	<ol style="list-style-type: none"> <li>1. Adanya informasi tambahan pada <i>seabed</i></li> <li>2. Menghasilkan diskriminasi akustik yang lebih baik pada sedimen dasar laut</li> <li>3. Bergantung pada lokasi <i>seabed</i></li> </ol>
	Review	Masih diperlukan sampel lapangan yang akurat untuk mendapatkan hasil yang lebih baik
5	Peneliti	Buscombe & Grams (2018)
	Frekuensi (kHz)	R2Sonic2026 (100, 200 dan 400)
	Kedalaman (m)	<ol style="list-style-type: none"> <li>1. Bedford Basin (13 – 85)</li> <li>2. Patricia Bay (20 – 70)</li> </ol>
	Metode	<i>Gaussian Mixture Model &amp; Conditional Random Field</i>
	Hasil	<ol style="list-style-type: none"> <li>1. CRF terbukti kuat untuk pengklasifikasi diskriminatif sedimen dasar laut.</li> <li>2. Model generatifnya dapat diterapkan pada area substrat tanpa pengamatan lapisan,</li> </ol>
	Review	Model CRF kurang sensitif terhadap jumlah spesifik dan lokasi pengamatan dasar laut daripada model generatif
6	Peneliti	Feldens, dkk (2018)
	Frekuensi (kHz)	Norbit iWBMSe (200, 400 dan 600)
	Kedalaman (m)	German Bight (15 – 18)

No	Deskripsi	
7	Metode	<i>Backscatter Mosaiks dan Angular Response Curve (ARC)</i>
	Hasil	<p>1. Penggunaan frekuensi 200 kHz menunjukkan peningkatan kepekaan terhadap perubahan komposisi dasar laut</p> <p>2. Mosaik multi-frekuensi sangat menjanjikan untuk mendeteksi kehidupan bentik, yang dapat bervariasi dari waktu ke waktu</p>
	Review	Masih ada kekurangan informasi untuk menginterpretasikan banyak fitur hambur balik dari dasar laut.
7	Peneliti	Gaida, dkk (2020)
	Frekuensi (kHz)	R2Sonic2026 (90, 100, 200, 300 dan 450)
	Kedalaman (m)	<p>1. Vlietland Lake (5 – 35)</p> <p>2. Port of Rotterdam (22 – 25)</p>
	Metode	<p>1. <i>Layer Backscatter Model (LBM)</i></p> <p>2. <i>Bottom Detection Model (BTM)</i></p> <p>3. <i>Angular Response Curve (ARC)</i></p>
	Hasil	<p>1. Selisih batimetri terukur perbedaan antara frekuensi terendah (90 kHz) dan tertinggi (450 kHz) di daerah berlumpur sedimen mencapai nilai hingga 60 cm tergantung pada lokasi dan sudut datang.</p> <p>2. Dalam korespondensi spasial dengan variasi perbedaan kedalaman, tingkat BS pada frekuensi terendah bervariasi hingga 15 dB untuk sedimen berlumpur sedangkan BS pada frekuensi tertinggi hanya menunjukkan variasi kecil.</p> <p>3. Deteksi bawah permukaan dengan MBES menunjukkan bahwa batimetri diukur pada</p>

No	Deskripsi	
8		frekuensi tertinggi dan terendah dapat digunakan untuk menentukan ketebalan lapisan tipis (~20 cm).
	Review	Penelitian ini belum menjawab korelasi antara ketebalan sedimen (selisih batimetri) dengan <i>backscatter</i> monospektral maupun multispektral
	Peneliti	Brown, dkk (2019)
	Frekuensi (kHz)	R2Sonic2026 (100, 200 dan 400)
	Kedalaman (m)	Bedford Basin (13 – 85)
	Metode	Mosaik
	Hasil	Menggabungkan beberapa frekuensi dari data MBES multispektral dalam studi pemetaan habitat menawarkan peluang potensial untuk perbaikan diskriminasi habitat.
	Review	Klasifikasi sedimen dasar hanya berdasarkan analisa kuantitatif (interpretasi) dari kombinasi frekuensi
	Peneliti	Mertikas & Karanzalos (2020)
9	Frekuensi (kHz)	R2Sonic2026 (100, 200 dan 400)
	Kedalaman (m)	1. Bedford Basin 13 – 85) 2. Patricia Bay (20 – 70)
	Metode	<i>Random Forest &amp; Support Vector Machines</i>
	Hasil	Evaluasi kualitatif dan kuantitatif yang dilakukan beserta perbandingannya dengan <i>metode lainnya</i> menunjukkan potensi yang cukup menjanjikan dari pendekatan yang digunakan
	Review	Klasifikasi sedimen dengan metode ini menghasilkan akurasi yang lebih baik dibandingkan dengan metode lainnya

No	Deskripsi	
10	Peneliti	Runya, dkk (2021)
	Frekuensi (kHz)	EM3002(300); EM302 (30); EM1002(95)
	Kedalaman (m)	Hempton's Turbot Bank (HTB) off the north coast of Ireland (20 – 70)
	Metode	<i>Texture Extraction (the grey level co-occurrence matrix (GLCM))</i>
	Hasil	<ol style="list-style-type: none"> <li>1. Analisis visual data meningkatkan pemahaman tentang variabilitas frekuensi tekstur untuk sedimen yang berbeda</li> <li>2. Hasil penelitian menunjukkan keuntungan frekuensi rendah (30 kHz), melalui analisis multispektral, yang menghadirkan beban dalam hal kekuatan pemrosesan, penyimpanan data, dan gangguan operasional selama akuisisi</li> </ol>
	Review	Kelemahannya masih menggunakan 3 alat yang berbeda untuk melakukan akuisisi data di waktu yang berbeda
11	Peneliti	Vondervoort dan Lekkerkerk (2021)
	Frekuensi (kHz)	R2Sonic 2024 (200 kHz, 400 kHz dan 700 kHz)
	Kedalaman (m)	Vinkeveense Plassen, the IJ (Amsterdam) and IJmuiden
	Metode	<i>Angle Response Analysis</i>
	Hasil	<ol style="list-style-type: none"> <li>1. MBES Multispektral tidak memberi perbaikan kualitas klasifikasi sedimen</li> <li>2. Frekuensi 700 kHz akan menghasilkan saturasi gambar yang berlebihan</li> </ol>
	Review	Hasil ini kontradiktif dengan hasil penelitian sebelumnya

## **2.8 Deep Neural Network**

*Machine Learning* (ML) digunakan untuk mengajari mesin cara menangani data dengan lebih efisien. Dengan banyaknya kumpulan data yang tersedia, permintaan untuk pembelajaran mesin meningkat. Banyak industri menerapkan pembelajaran mesin untuk mengekstrak data yang relevan. Tujuan dari pembelajaran mesin adalah untuk belajar dari data. Banyak penelitian telah dilakukan tentang bagaimana membuat mesin belajar sendiri tanpa diprogram secara eksplisit. Banyak matematikawan dan pemrogram menerapkan beberapa pendekatan untuk menemukan solusi dari masalah ini yang memiliki kumpulan data yang sangat besar. Untuk memecahkan masalah data, terdapat banyak algoritma yang mampu mengatasinya. Berbeda karakteristik datanya, berbeda pula penggunaan jenis algoritma ML yang digunakan. *Data scientist* mengungkapkan bahwa tidak ada satu jenis algoritma yang cocok untuk semua pemecahan masalah data terbaik. Jenis algoritma yang digunakan tergantung pada jenis masalah yang ingin dipecahkan, jumlah variabel, jenis model yang paling cocok untuk itu, dan seterusnya. (Mahesh,2019).

ML adalah cabang dari kecerdasan buatan (*artificial intelligence*) yang bertujuan untuk memungkinkan mesin melakukan pekerjaan dengan terampil menggunakan perangkat lunak cerdas. ML mempelajari teori agar komputer mampu belajar dari data. ML melibatkan berbagai disiplin ilmu seperti statistika, ilmu komputer, matematika, bahkan ilmu kebumian. ML menggunakan teori-teori statistik untuk membentuk model matematis. Model dapat bersifat *predictive* (untuk mempelajari masa depan), atau *descriptive* (untuk memperoleh pengetahuan dari data), atau gabungan dari keduanya (Simeone, 2018).

Penerapan ML juga dapat dilakukan pada analisis spasial. ML menghasilkan pemodelan data geospasial seperti prediksi spasial (klasifikasi dan pemetaan); bahaaya alam dan penilaian risiko lingkungan; perkiraan sumber daya terbarukan; analisis, pemodelan dan visualisasi data sosial ekonomi multivariat, prediksi deret waktu lingkungan, hidro-informatika, perlakuan dan klasifikasi citra penginderaan jauh, asimilasi data dan model berbasis sains dan lain-lain. Fitur utama dari model/algoritma ML adalah algoritma tersebut belajar dari data dan dapat digunakan dalam kasus ketika fenomena yang dimodelkan tidak dijelaskan

dengan baik, yang merupakan kasus di banyak aplikasi data geospasial. Model pembelajaran mesin adalah alat adaptif, yang saat ini banyak digunakan untuk menyelesaikan prediksi, karakterisasi, optimasi dan banyak masalah lainnya (Kanevski et al., 2008).

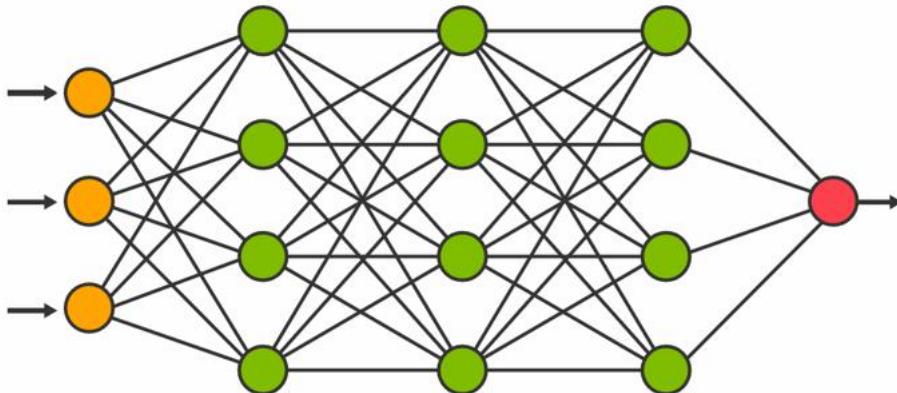
*Neural network* merupakan salah satu metode klasifikasi berbasis kecerdasan buatan yang mengadopsi kemampuan otak manusia dalam hal memberikan stimulus, melaksanakan proses dan menghasilkan output (Kusumadewi, 2004). *Neural network* menggunakan simpul yang saling terhubung satu sama lain dalam struktur berlapis yang menyerupai otak manusia. Kemampuan otak manusia dalam mengolah informasi merupakan hasil proses yang kompleks di dalam otak. Oleh karena itu, *neural network* menciptakan sistem adaptif yang digunakan oleh komputer untuk belajar dari kesalahannya dan memperbaikinya secara terus menerus.

*Neural network* mempunyai keunggulan dalam menggabungkan data spektral dan non spektral. Selain itu *neural network* juga mempunyai kemampuan untuk mengingat data dalam jumlah berapapun (*big data*) yang akan dilatihkan serta mengenali data yang belum dilatihkan (Arif, 2011). Dalam dunia penginderaan jauh, *neural network* digunakan untuk mengekstrasi informasi dari citra satelit berbasis data nilai spectral dan data non spectral. Kemampuan *neural network* dalam menangani fenomena yang kompleks (heterogen) merupakan suatu keunggulan dibandingkan dengan metode klasifikasi parametrik (konvensional) seperti *maximum likelihood*.

Salah satu metode klasifikasi dalam *neural network* yang digunakan adalah Metode klasifikasi *Multilayer Perceptron* (MLP). Proses klasifikasi MLP dilakukan setelah penentuan daerah contoh (supervisi) dan algoritma yang digunakan pada pelatihan untuk proses klasifikasi ini yaitu perambatan balik. Proses klasifikasi dilakukan dengan simulasi beberapa parameter pada jaringan MLP. Adapun tahapan yang dilakukan adalah sebagai berikut (Kusumadewi, 2004):

1. Menentukan fungsi aktivasi sigmoid, dimana fungsi ini dengan mudah untuk membedakan dan dapat meminimalkan perhitungan kapasitas pelatihan, sinyal tak terbatas ke dalam sinyal terbatas dalam daerah ambang antara 0 sampai 1.

2. Menentukan lapisan tersembunyi (*hidden layer*) adalah lapisan yang menerima respon bobot dari lapisan input untuk diteruskan pada lapisan output.
3. Menentukan kecepatan belajar (*learning rate*) misalnya konstanta belajar yang digunakan secara default yaitu 0,001s.
4. Menentukan nilai momentum (*training momentum*), untuk mengatur besarnya efek perubahan bobot sebelumnya, nilai ini berada dalam interval nilai nol sampai satu.
5. Menentukan jumlah iterasi yaitu merupakan suatu proses yang digunakan secara berulang-ulang (pengulangan) dalam menyelesaikan suatu permasalahan dalam klasifikasi.
6. Menentukan nilai toleransi selama pelatihan akan terhenti. Nilai RMS akan digunakan sebagai batas iterasi. Iterasi akan berhenti jika nilai RMS < nilai batas toleransi yang ditetapkan pada jaringan ataupun jumlah *epoch* yang telah mencapai batas yang telah ditentukan.



Gambar 2.24 Skema struktur *Neural Network*

Setiap hasil simulasi klasifikasi MLP akan dilakukan pengujian akurasi dan waktu eksekusi. Uji akurasi dilakukan untuk menilai ketelitian data hasil klasifikasi. Tahap ini diawali dengan penentuan sampel di lapangan. Sampel yang diperoleh digunakan untuk *training area* dan uji akurasi pada setiap kelas klasifikasi. Selanjutnya uji akurasi dengan membuat confusion matrix/error matrix (matriks kesalahan). Matriks kesalahan ini membandingkan hubungan antara data lapangan yang telah diketahui dengan hasil proses klasifikasi. Uji akurasi yang akan diterapkan dengan menggunakan akurasi keseluruhan (*overall accuracy*), akurasi

penghasil (*producer accuracy*), akurasi pemakai (*user accuracy*) dan koefisien Kappa (McCoy, 2005) menjelaskan suatu hasil interpretasi dapat digunakan keperluan analisis jika tingkat ketelitiannya mencapai minimal 80-85%.

## 2.9 Evaluasi Akurasi (Kualitas) Klasifikasi

Matriks evaluasi digunakan untuk mengevaluasi kualitas hasil dari klasifikasi dengan tahapan pelatihan (*training stage*) dan tahapan pengujian (*testing stage*) (Hossin dan Sulaiman, 2015). Pada tahapan pelatihan, matriks evaluasi digunakan sebagai pembeda untuk membedakan dan memilih solusi optimal yang digunakan untuk memprediksi klasifikasi berikutnya, sehingga algoritma klasifikasi menjadi lebih optimal. Sedangkan pada tahap pengujian, matriks evaluasi digunakan sebagai evaluator untuk mengukur efektivitas *classifier* yang dihasilkan ketika diuji dengan data yang tidak terlihat.

### 2.9.1 Metrik Konfusi Diskriminator

Evaluasi diskriminasi dari solusi terbaik (optimal) selama pelatihan klasifikasi dapat didefinisikan berdasarkan matriks konfusi seperti yang ditunjukkan pada Tabel 2.3. Matriks konfusi (atau matriks kesalahan) umumnya digunakan sebagai metode kuantitatif untuk mengkarakterisasi akurasi klasifikasi data penginderaan jauh (*remote sensing*). Tabel 2.3 menunjukkan korespondensi antara hasil klasifikasi dengan data referensi. Dari matriks konfusi ini, *True Positif* (TP) dan *True Negatif* (TN) menunjukkan jumlah contoh positif dan negatif yang diklasifikasikan dengan benar. Sedangkan *False Positif* (FP) dan *False Negatif* (FN) menyatakan banyaknya kesalahan klasifikasi negatif dan positif, masing-masing.

Tabel 2.3 Matriks konfusi diskriminator

<i>Predictive / Actual</i>	Kelas positif sebenarnya	Kelas negatif sebenarnya
Kelas positif prediksi	<i>True positive</i> (TP)	<i>False negative</i> (FN)
Kelas prediksi negatif	<i>False positive</i> (FP)	<i>True negative</i> (TN)

## 2.9.2 Indikator Akurasi

Tingkat ketelitian (akurasi) hasil klasifikasi terhadap data in-situ diindikasikan dengan nilai *Overall Accuracy* (OA), *User's Accuracy* (UA), *Producer's Accuracy* (PA) dan *Kappa Coefficient* (Ukrainski, 2016). *Overall Accuracy* dapat diformulasikan sebagai berikut (Ukrainski, 2016):

$$OA = \frac{TP+TN}{TP+FP+FN+TN} \quad 2.45$$

OA merupakan rasio jumlah yang benar identifikasi dengan jumlah total klasifikasi. Nilai OA berkisar antara 0 dan 1 ( $0 \leq OA \leq 1$ ).

Selain akurasi keseluruhan (OA), akurasi identifikasi dari masing-masing kelas perlu dinilai. Untuk itu diperlukan sel non-diagonal dalam matriks konfusi yang berisi informasi tentang ketidaksesuaian antara klasifikasi dengan data *in situ*. Ada dua jenis kesalahan yaitu perkiraan yang terlalu rendah (kesalahan kelalaian) dan perkiraan yang terlalu tinggi (kesalahan komisi). Untuk setiap kelas, kesalahan komisi terjadi ketika prosedur klasifikasi menetapkan piksel ke kelas tertentu yang sebenarnya bukan miliknya. Jumlah piksel yang secara keliru ditetapkan ke suatu kelas ditemukan di sel kolom kelas di atas dan di bawah diagonal utama. Dan jika kita bagi jumlah ini dengan jumlah total piksel kelas, kita akan mendapatkan kesalahan komisi relatif (*Com*) (Ukrainski, 2016):

$$Com = \frac{FP}{TP+FP} \quad 2.46$$

Besarnya kesalahan komisi juga dijelaskan oleh indikator *Producer's Accuracy* (PA) yaitu jumlah piksel yang diidentifikasi dengan benar dibagi dengan jumlah total piksel dalam gambar referensi (Ukrainski, 2016).

$$PA = \frac{TP}{TP+FP} \quad 2.47$$

Hubungan antara nilai *Com* dan PA sebagai berikut (Ukrainski, 2016):

$$PA = 1 - com \quad 2.48$$

Untuk setiap kelas, kesalahan penghilangan terjadi ketika piksel yang sebenarnya milik satu kelas, dimasukkan ke dalam kelas lain. Dalam matriks konfusi, jumlah piksel yang dihilangkan ditemukan di sel baris ke kiri dan ke kanan dari diagonal utama. Jumlah sel-sel ini adalah nilai absolut dari penghilangan kelas. Dan jika kita membagi jumlah ini dengan jumlah total piksel kelas dalam gambar yang diklasifikasikan, kita akan mendapatkan kesalahan penghilangan relatif ( $Om$ ) (Ukrainski, 2016):

$$Om = \frac{FN+TN}{TP+FN} \quad 2.49$$

Akurasi pengguna (UA) adalah indeks lain yang mencirikan jumlah kesalahan kelalaian. Ini adalah jumlah piksel yang diidentifikasi dengan benar dari suatu kelas, dibagi dengan jumlah total piksel kelas dalam gambar yang diklasifikasikan (Ukrainski, 2016):

$$UA = \frac{TP}{TP+FN} \quad 2.50$$

Nilai  $Om$  dan UA terhubung (Ukrainski, 2016):

$$UA = 1 - Om \quad 2.51$$

Indikator akurasi lainnya adalah *Kappa Coefficient* (Koefisien Kappa ( $\kappa$ )) atau yang sering diistilahkan juga dengan *Cohen's Kappa*. *Cohen's Kappa* merupakan ukuran yang menyatakan konsistensi pengukuran yang dilakukan oleh dua penilai atau nilai konsistensi antar dua metode pengukuran. Dalam evaluasi model ML yang dimaksud penilai disini adalah prediksi dan observasi. Parameter ini digunakan pada umumnya untuk klasifikasi dua kelas. Dengan menggunakan matriks konfusi sebagaimana telah dijelaskan pada Tabel 2.4, *cohen's kappa* dapat ditentukan dengan persamaan berikut (Chicco et al., 2021; Ukrainski, 2016).

$$\kappa = \frac{2 \times ((TP \times TN) - (FP \times FN))}{((TP + FP) \times (FP + TN)) + ((TP + FN) \times (FN + TN))} \quad 2.52$$

Hal ini dapat mengambil nilai dari 0 sampai 1. Jika koefisien *kappa* sama dengan 0, tidak ada kesepakatan antara gambar diklasifikasikan dan gambar referensi. Jika koefisien *kappa* sama dengan 1, maka citra klasifikasi dan citra *ground truth* benar-benar identik. Jadi, semakin tinggi koefisien *kappa*, semakin akurat klasifikasinya. Tidak ada standar umum untuk menilai signifikansi nilai dari *Cohen's kappa*, namun banyak penelitian yang menggunakan klasifikasi signifikansi nilai *Cohen's kappa* sebagaimana dalam Tabel 2.4 (Cohen, 1960).

Tabel 2.4 Klasifikasi nilai *chohen's kappa* (Cohen, 1960)

Nilai Kappa	Kualitas Model
< 0,01	Tidak ada konsistensi
0,01 – 0,20	Sedikit konsistensi
0,21 – 0,40	Konsistensi cukup
0,41 – 0,60	Konsistensi sedang
0,61 – 0,80	Konsistensi substansial
> 0,80	Konsistensi hampir sempurna

## 2.10 Variabel Penelitian

Variabel penelitian merupakan segala sesuatu yang ditentukan oleh peneliti dalam bentuk apa saja untuk memperoleh informasi dan menarik kesimpulan (Sugiyono, 2009). Berdasarkan hubungan sebab-akibat antar variabel penelitian, Winarno (2013) mengelompokkan jenis variabel penelitian sebagai berikut:

a. Variabel terikat

Variabel terikat merupakan *output* dari suatu penelitian, dimana variabel ini dipengaruhi oleh variabel lainnya. Variabel terikat tidak bisa dimanipulasi

melainkan diamati variasinya sebagai hasil dari hipotesa variabel bebas. Dalam penelitian ini, yang menjadi variabel terikat adalah klasifikasi sedimen dasar laut.

b. Variabel bebas

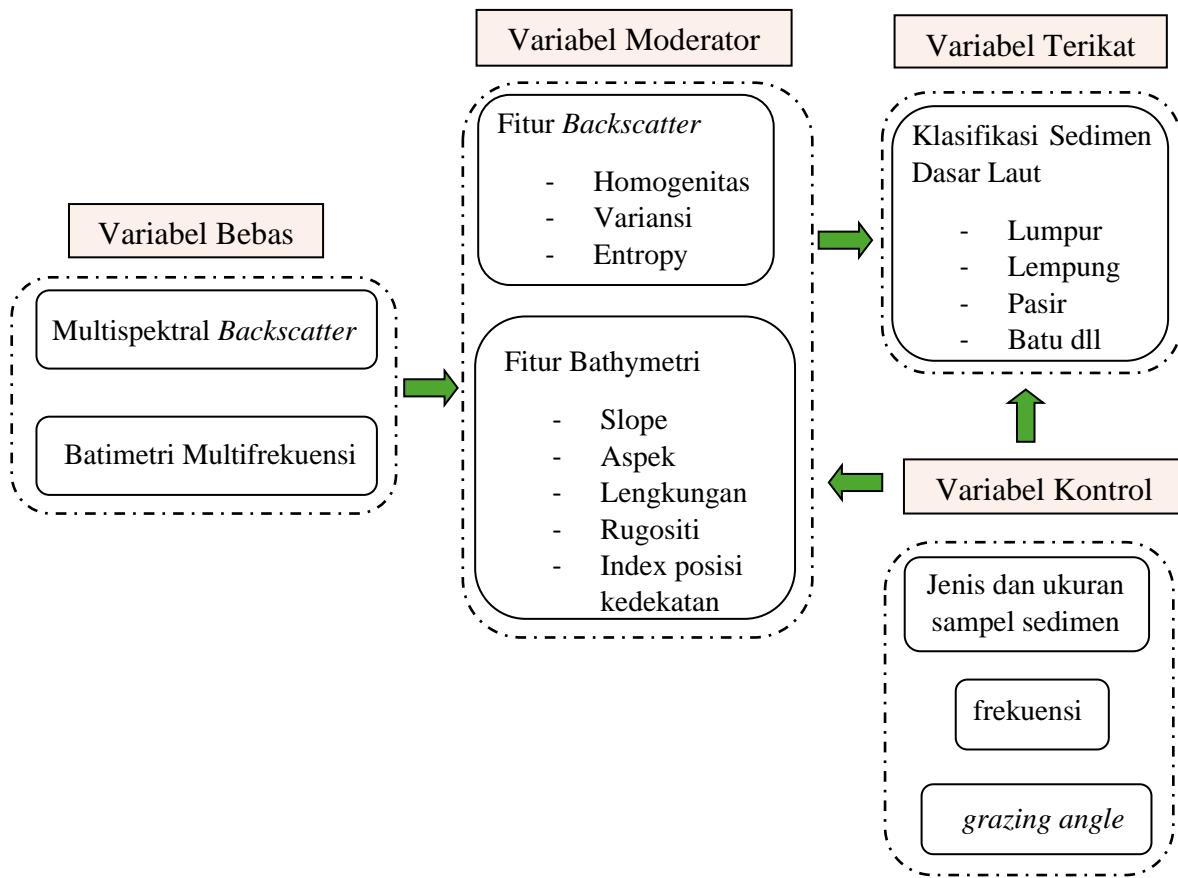
Variabel bebas merupakan variabel yang menjadi sebab terjadinya variabel terikat, dimana variable ini bisa diamati, diukur, dan dimanipulasi untuk mencari hubungan dengan variable lain. Variabel bebas yang digunakan dalam penelitian ini adalah data batimetri multifrekuensi dan *backscatter* multispektral hasil pengukuran dari MBES multifrekuensi.

c. Variabel moderator

Variabel moderator adalah variabel antara yang merupakan variabel bebas sekunder yang menentukan apakah mempengaruhi hubungan antara variabel bebas primer dan variabel terikat. Variabel moderator merupakan variabel yang diukur, dipilih dan dimanipulasi untuk mengungkap apakah faktor tersebut mengubah hubungan antara variabel bebas dan terikat. Data turunan batimetri (kemiringan, lengkungan, aspek, rugositi, dan index posisi kedekatan) dan turunan *backscatter* (homogenitas, variansi, entropy) dalam penelitian ini merupakan variabel moderator.

d. Variabel kontrol

Variabel kontrol merupakan faktor-faktor yang dapat dikontrol oleh peneliti, dimana jika tidak dikontrol akan mempengaruhi hubungan antara variabel bebas dengan variabel terikat. Penetapan suatu variabel menjadi variabel moderator adalah untuk dipelajari (dianalisis) pengaruhnya, sedangkan penetapan variabel kontrol adalah untuk dinetralkan/disamakan pengaruhnya. Variable kontrol yang digunakan pada penelitian ini adalah jenis sampel sedimen yang digunakan untuk *training site* seperti jenis dan ukuran sampel sedimen.



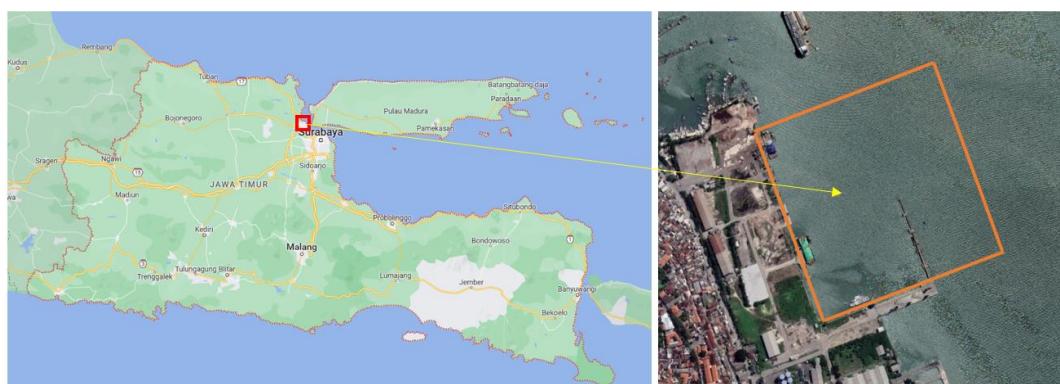
Gambar 2.25 Hubungan antara variabel penelitian (*conceptual framework*)

## BAB 3

### METODOLOGI PENELITIAN

#### 3.1 Lokasi Penelitian

Lokasi penelitian ini terletak di area pelabuhan PT. Gresik Jasa Tama (PT. GJT) di Kabupaten Gresik, Provinsi Jawa Timur (Gambar 3.1) dengan koordinat  $7^{\circ}8'52'' - 7^{\circ}7'9''$  LS dan  $112^{\circ}39'38'' - 112^{\circ}39'46''$  BT dan mempunyai kedalaman sekitar 0 – 15 m. Perairan ini termasuk kedalam perairan dangkal. Sedimen dasar di perairan ini didominasi oleh sedimen halus seperti lempung (*clay*), debu (*silt*) dan pasir (*sand*). Adapun alasan lokasi penelitian disini adalah belum pernah dilakukan penelitian ini di area perairan sangat dangkal (*very shallow water*) di wilayah tropis. Selain itu, lebih mudah untuk melakukan pengambilan sampel sedimen dengan *grab sampler* di kedalaman kurang dari 15 m.



Gambar 3.1 Lokasi Penelitian (google earth.com)

#### 3.2 Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data primer, yang langsung melakukan pengukuran survei batimetri dengan MBES multifrekuenpsi R2Sonic 2020, pengamatan pasang surut sesaat pada saat melakukan survei dan pengukuran profil kecepatan gelombang suara di bawah air di area penelitian. Selain itu juga melakukan pengambilan sampel sedimen dengan menggunakan *grab sampler* di beberapa titik lokasi studi. Data sekunder yang diperlukan adalah data referensi vertikal (*chart datum*) yang ada di area pelabuhan sebagai acuan kedalaman, data *bore hole* dan data *sub bottom profiler* di area studi.

### **3.3 Peralatan**

Peralatan yang digunakan dalam penelitian ini adalah sebagai berikut:

1. *Multi Beam Echo Sounder Multi Frequency* (R2Sonic 2020) berfungsi untuk pengambilan data kedalaman dan intensitas dasar laut.
2. *Sound Velocity Profiler* (AML)
3. *Tide gauge*
4. *GNSS RTK* dan *heading sensor*
5. *Inertial Motion Unit* (IMU)
6. *Van Veen Grab sampler*

### **3.4 Metodologi Penelitian**

Secara umum metodologi penelitian yang akan dilakukan pada penelitian ini adalah sebagai berikut (Gambar 3.2)

#### **3.4.1 Tahap Persiapan**

Tahap persiapan merupakan tahap awal yang harus dilakukan, yang meliputi:

a. Kajian pustaka

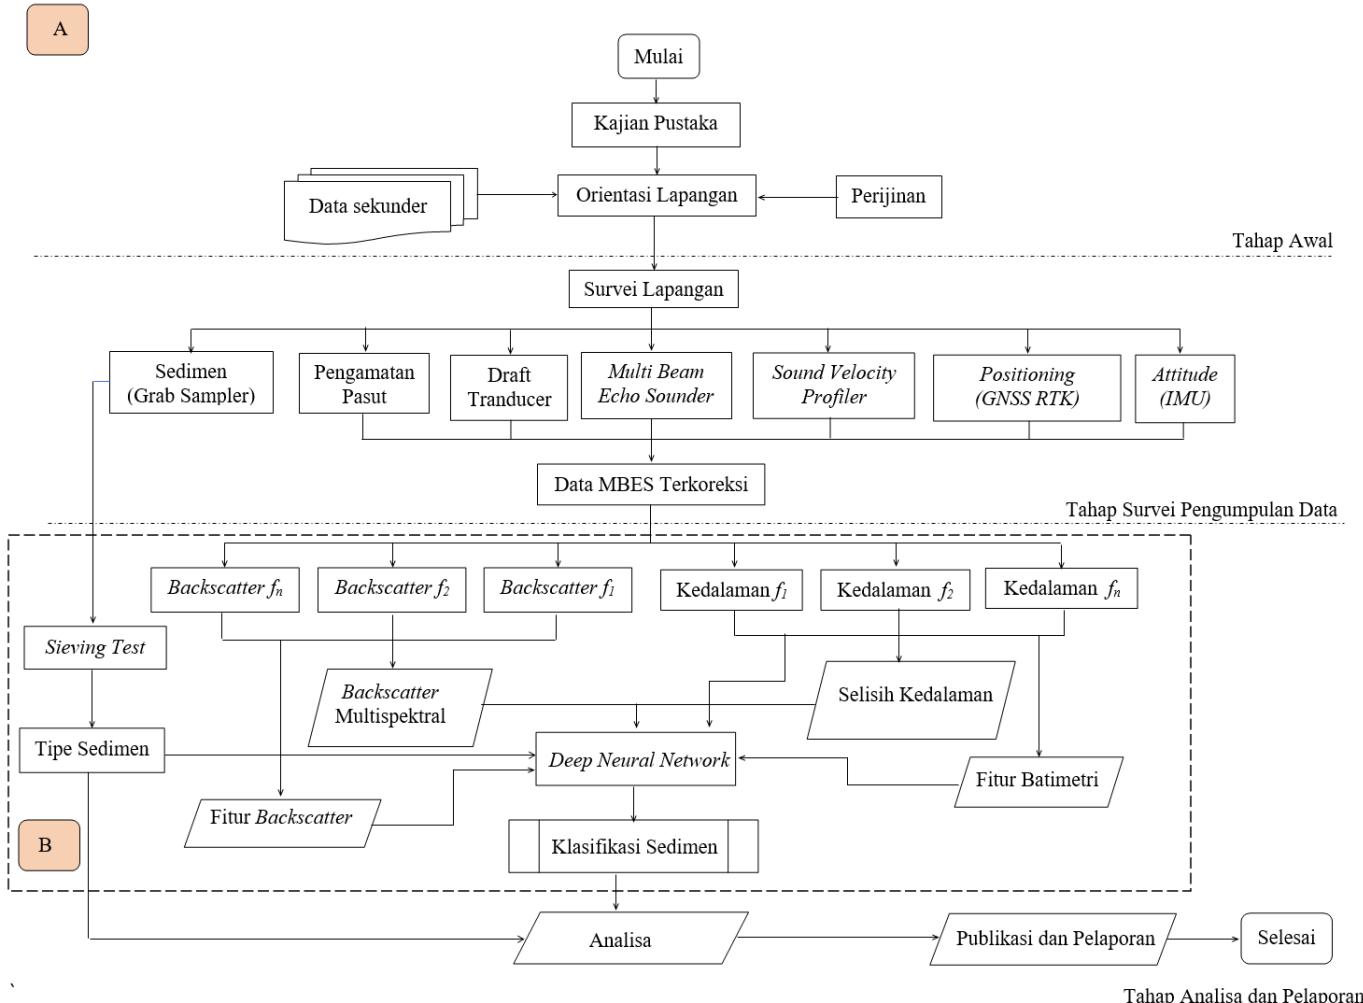
Kajian pustaka bertujuan untuk merumuskan masalah yang belum terpecahkan dalam pemetaan sedimen dasar laut dengan *MBES* multifrekuensi dan mengumpulkan teori dan aplikasi terkait dengan klasifikasi sedimen dasar laut dengan *MBES* multifrekuensi

b. Pengumpulan Data Sekunder

Pengumpulan data sekunder bertujuan untuk mendukung survei *MBES* yang akan dilakukan seperti peta Lingkungan Pantai Indonesia lembar Gresik, pengumpulan data referensi vertikal yang digunakan (*chart datum*), pengumpulan data *bore hole* dan *sub bottom profiler* untuk mendukung pelaksanaan penelitian pada saat pengumpulan data maupun analisa.

c. Perijinan Survei

Perijinan survei kepada pihak-pihak yang terkait dengan pelabuhan dengan tujuan untuk memperlancar kegiatan selama survei di lapangan



Gambar 3.2 Diagram alir metodologi penelitian

d. Orientasi Lapangan

Orientasi lapangan bertujuan untuk menguasai medan (lapangan) yang akan disurvei, kendala apa saja yang ditemui selama di lapangan dan solusi untuk mengatasi kendala tersebut. Hasil orientasi lapangan ini digunakan untuk perencanaan survei lapangan.

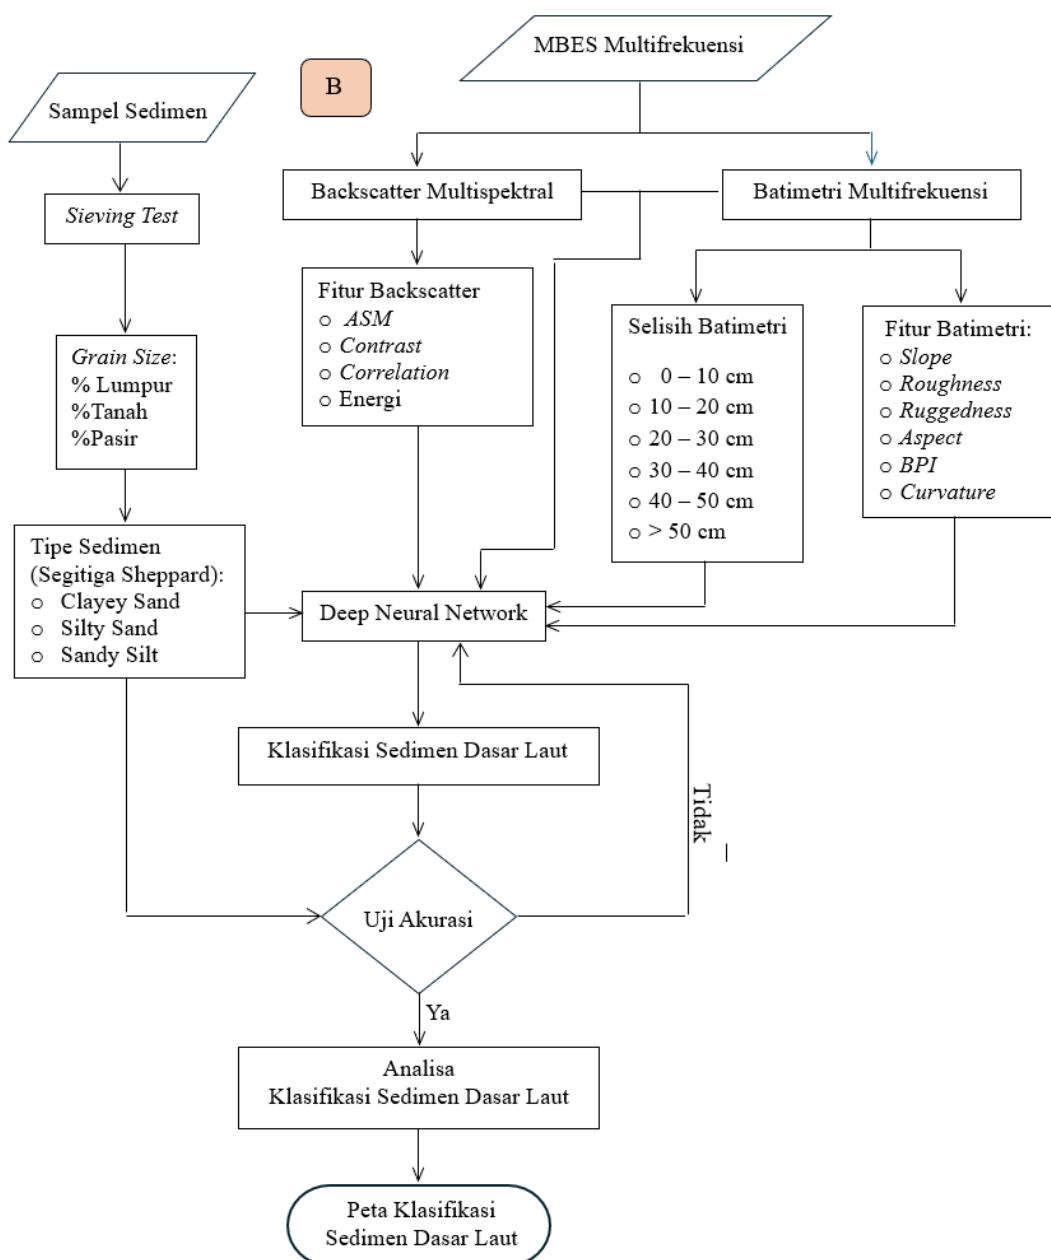
### 3.4.2 Tahap Survei Lapangan

Survei lapangan dalam penelitian ini meliputi kegiatan survei sebagai berikut:

- a. Pengamatan Pasang Surut bertujuan untuk koreksi pasang surut pada saat survei *MBES* dilaksanakan. Selain itu pengamatan pasang surut bertujuan untuk menghubungkan data survei dengan data referensi vertikal (*chart datum / chart depth*) yang akan digunakan untuk peta batimetri
- b. Pengamatan *RTK GNSS* bertujuan untuk menentukan posisi horisontal / koordinat (X, Y) *tranducer* dari *MBES* dan arah kapal (*heading*).
- c. Pengukuran *attitude* bertujuan untuk mengkalibrasi *MBES* terhadap gerakan kapal (*pitch, roll* dan *yaw*).
- d. Pengukuran *MBES* bertujuan untuk menentukan kedalaman area survei dan *backscatter MBES* multispektral untuk mengklasifikasi sedimen dasar laut. Survei ini menggunakan *MBES* multifrekvensi R2Sonic2020 dengan frekuensi 200 kHz, 250 kHz, 300 kHz, 350 kHz dan 400 kHz yang dilaksanakan dengan sekali survei yang berbasiskan pada *ping by ping* basis.
- e. Pengukuran *Sound Velocity Profiler* bertujuan untuk menentukan profil kecepatan gelombang suara di dalam air yang nantinya digunakan koreksi gelombang suara yang dipancarkan oleh *MBES*.
- f. Pengukuran sedimen dengan *grab sampler* tipe *Van Veen Grab* bertujuan untuk mengambil sampel sedimen dasar laut yang selanjutnya diuji di laboratorium untuk menentukan jenis dan ukuran butir sedimen.

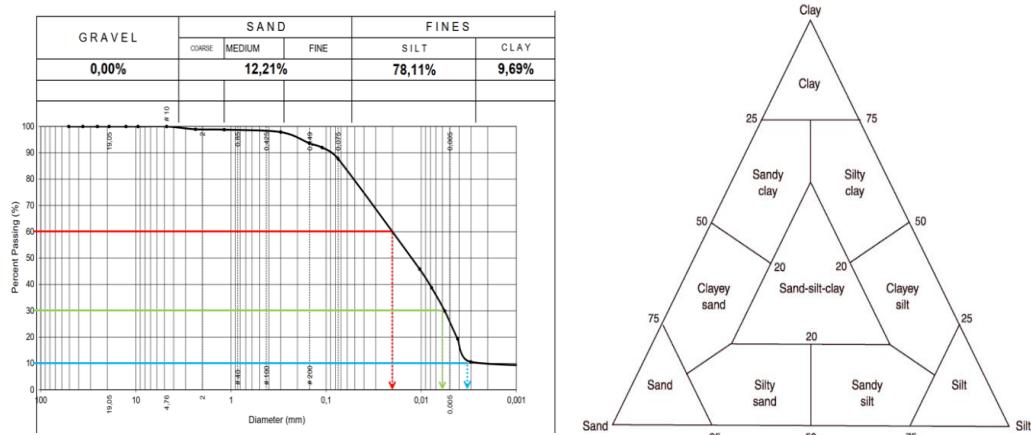
### 3.4.2 Tahap Pengolahan Data dan Analisa

Pengolahan Data dan Analisa hasil pengolahan data dalam kegiatan penelitian ini dapat dilihat pada diagram alir Gambar 3.3.



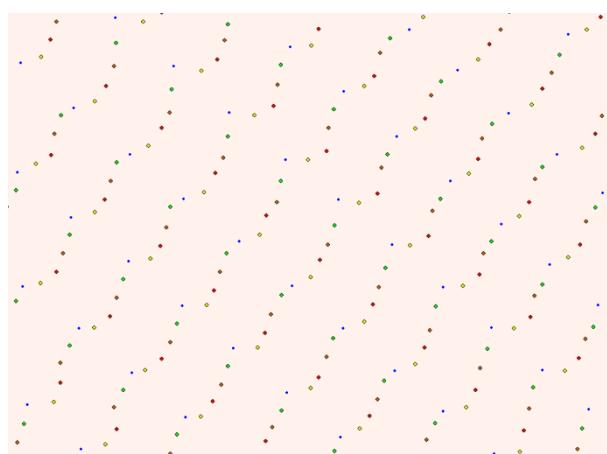
Gambar 3.3 Proses pengolahan data klasifikasi sedimen dasar laut

- Uji laboratorium sampel sedimen bertujuan untuk menentukan jenis dan ukuran butir sedimen (*grain size analysis*). Dengan menggunakan metode *sieve analysis*, ukuran sedimen dapat ditentukan masing-masing persentase untuk kerikil (*gravel*), pasir (*sand*) dan lumpur (*clay*). Dari hasil prosentase ukuran sedimen tersebut, selanjutnya jenis sedimen dapat ditentukan dengan menggunakan segitiga *Sheppard* (Gambar 3.4).



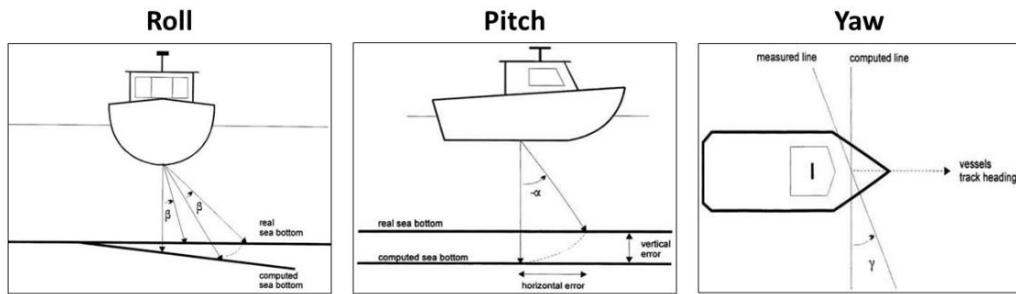
Gambar 3.4 Ukuran sedimen (kiri) dan segitiga *Sheppard* (kanan)

- b. Data MBES multifrekuenyi terdiri atas satu file yang merupakan gabungan dari beberapa frekuensi (dalam hal ini 5 frekuensi yaitu 200 kHz, 250 kHz, 300 kHz, 350 kHz dan 400 kHz) (Gambar 3.5). Oleh karena itu, data ini harus dipisahkan menurut frekuensi yang disetting pada saat survei yaitu 5 frekuensi tersebut.



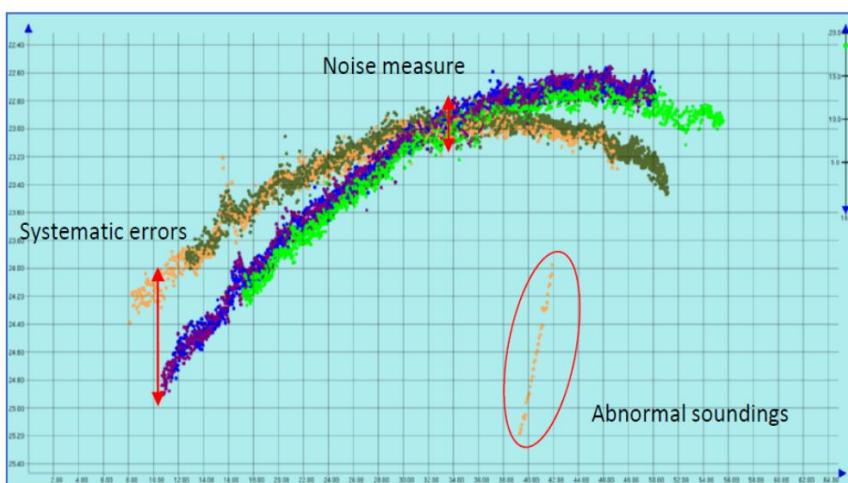
Gambar 3.5 Titik-titik kedalaman berdasarkan frekuensi (biru = 200 kHz, hijau = 250 kHz, orange = 300 kHz, merah = 350 kHz dan kuning = 400 kHz)

- c. Melakukan koreksi *patch test* pada data MBES multifrekuensi yaitu dengan menghitung ketidaksejajaran (*misalignment*) letak transduser terhadap sumbu x (*roll*), sumbu y (*pitch*) dan sumbu z (*yaw*) (Gambar 3.6). Hasil *patch test* tersebut digunakan untuk koreksi sebelum data MBES diproses lebih lanjut.



Gambar 3.6 *Patch test* untuk menghitung sudut *roll*, *pitch* dan *yaw*

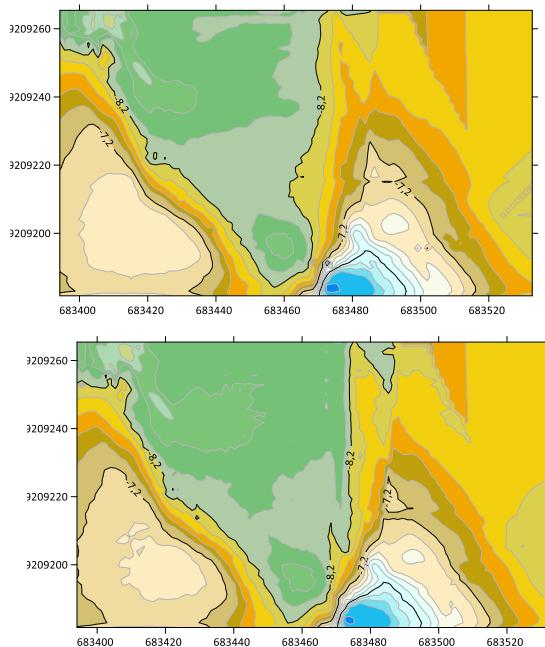
- d. Melakukan editing data MBES dari *noise*. Pada saat data MBES divisualisasikan dalam bentuk 2D maupun 3D akan terlihat titik-titik kedalaman yang tidak normal (*anomaly*) yang disebabkan oleh berbagai faktor seperti ikan, sedimen layang, sampah atau yang lainnya (Gambar 3.7). Untuk itu diperlukan *editing* dari *noise* tersebut yaitu dengan cara menghapus titik-titik tersebut.



Gambar 3.7 *Editing* data MBES (Deunf, et al, 2019)

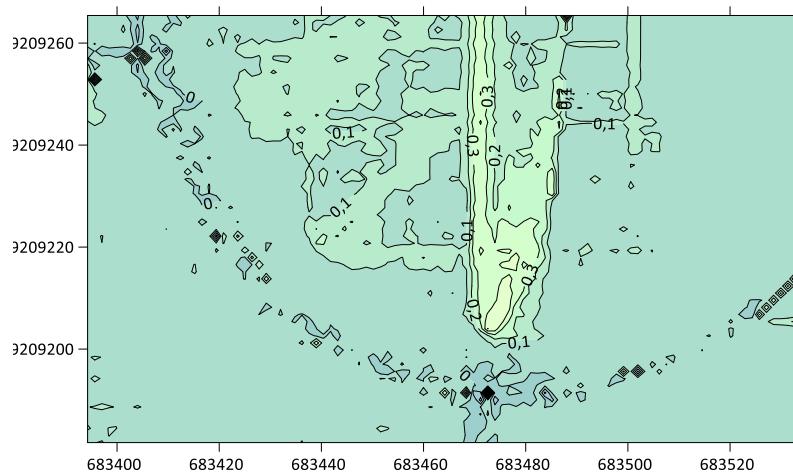
- e. Pengolahan data kedalaman MBES multifrekuensi. Setelah masing-masing frekuensi dipisahkan ke dalam file masing-masing, selanjutnya dihitung masing-masing kedalaman untuk masing-masing frekuensi dengan memasukkan koreksi *draft tranducer*, koreksi pasut, koreksi kecepatan gelombang dan

mengacu ke referensi kedalaman yang digunakan. Selanjutnya titik-titik kedalaman masing-masing frekuensi tersebut di buat garis kontur kedalamannya (Gambar 3.8)



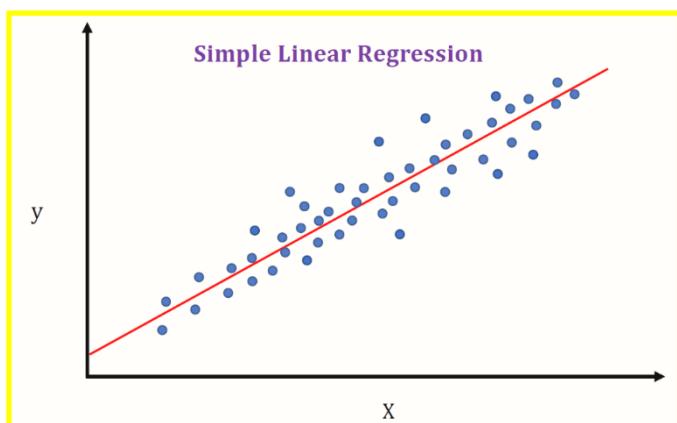
Gambar 3.8 Kontur kedalaman frekuensi 400 kHz (kiri) dan 250 kHz (kanan)

- Menghitung selisih kedalaman. Kedalaman masing-masing frekuensi di selisihkan satu sama lain untuk melihat selisih kedalaman antar frekuensi. Gambar 3.9 menunjukkan selisih kedalaman antar frekuensi 250 kHz dengan 400 kHz yang berkisar 0 – 30 cm.



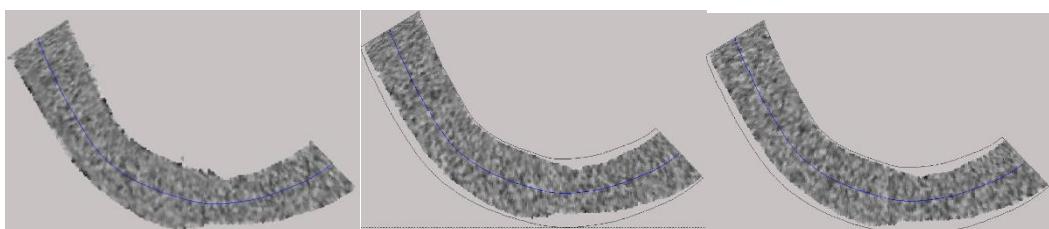
Gambar 3.9 Selisih kedalaman frekuensi 250 kHz dengan 400 kHz

- g. Menganalisa hasil selisih kedalaman (ketebalan) sedimen dari MBES multifrekuensi. Frekuensi yang berbeda akan menghasilkan kedalaman yang berbeda. Hipotesisnya, permukaan dasar laut dengan sedimen yang keras (ukuran sedimen besar) seperti batuan, tidak ada selisih kedalaman antar frekuensi dan sedimen yang halus seperti lumpur, akan menghasilkan selisih kedalaman bergantung pada selisih frekuensi yang digunakan. Semakin besar selisih frekuensinya maka semakin besar selisih kedalamannya. Selanjutnya selisih kedalaman antar frekuensi tersebut akan dikorelasikan dengan jenis sedimen dengan metode regresi linear (Gambar 3.10).



Gambar 3.10 Regresi linier x (jenis sedimen) dan y (selisih kedalaman)

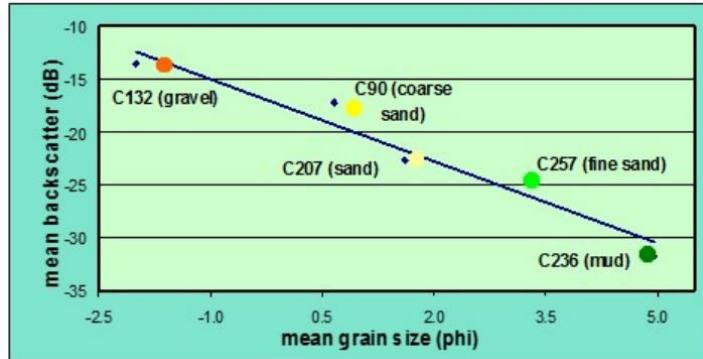
- h. Data *backscatter* MBES multifrekuensi. Selain data batimetri, masing-masing frekuensi juga memiliki data intensitas *backscatter* yang dapat digambarkan pada Gambar 3.11. masing-masing frekuensi ( $f_1, f_2, f_3, f_4$ , dan  $f_5$ ) area survei



Gambar 3.11 Intensitas *backscatter* 200 kHz (kiri), 300 kHz (tengah) dan 400 kHz (kanan)

- i. Mengoverlaykan hasil *backscatter* masing-masing frekuensi untuk menghasilkan *backscatter* multispektral di area survei

- j. Menganalisa korelasi *backscatter* MBES dengan jenis sedimen. Beberapa titik kedalaman yang mempunyai nilai *backscatter* monospektral (masing-masing) frekuensi dan *backscatter* multispektral (overlay beberapa frekuensi) dikorelasikan dengan jenis sedimen dengan persamaan regresi linear (Gambar 3.12)



Gambar 3.12 Korelasi antara ukuran sedimen (x) dengan kekuatan *backscatter* (y)

- k. Menganalisa klasifikasi sedimen dasar laut berdasarkan data MBES yang divalidasi dengan data sedimen dengan menggunakan metode *Deep Neural Network*, yaitu dengan input:
- batimetri dan selisih batimetri
  - batimetri, selisih batimetri dan fitur batimetri
  - batimetri dan *backscatter* monospektral dan multispektral
  - batimetri, selisih batimetri, fitur batimetri multifrekuensi, *backscatter*, dan fitur *backscatter* multispektral.
- l. Validasi Kuantitatif dan Qualitatif

Validasi peta klasifikasi dilakukan berdasarkan metrik kuantitatif standar. Secara khusus, semua matriks konfusi dihitung dan diperiksa. Selain itu, metrik standar Akurasi Keseluruhan (*OA*), Akurasi Pengguna (*UA*), Akurasi Produsen (*PA*) dan koefisien Kappa (*Kappa*) juga dihitung, dibandingkan dan didiskusikan untuk setiap kasus. Selain itu model yang ada, diuji di lokasi yang lain dengan karakteristik perairan yang kurang lebih sama.

### **3.4.3 Tahap Pelaporan dan Publikasi**

Hasil akhir dari penelitian ini adalah:

- a. Peta Batimetri 2D dan 3D
- b. Peta Selisih Batimetri
- c. Peta Klasifikasi Sedimen Dasar Laut
- d. Publikasi paper di seminar internasional dan jurnal internasional

*“Halaman ini sengaja dikosongkan”*

## **BAB 4**

### **HASIL PENELITIAN DAN PEMBAHASAN**

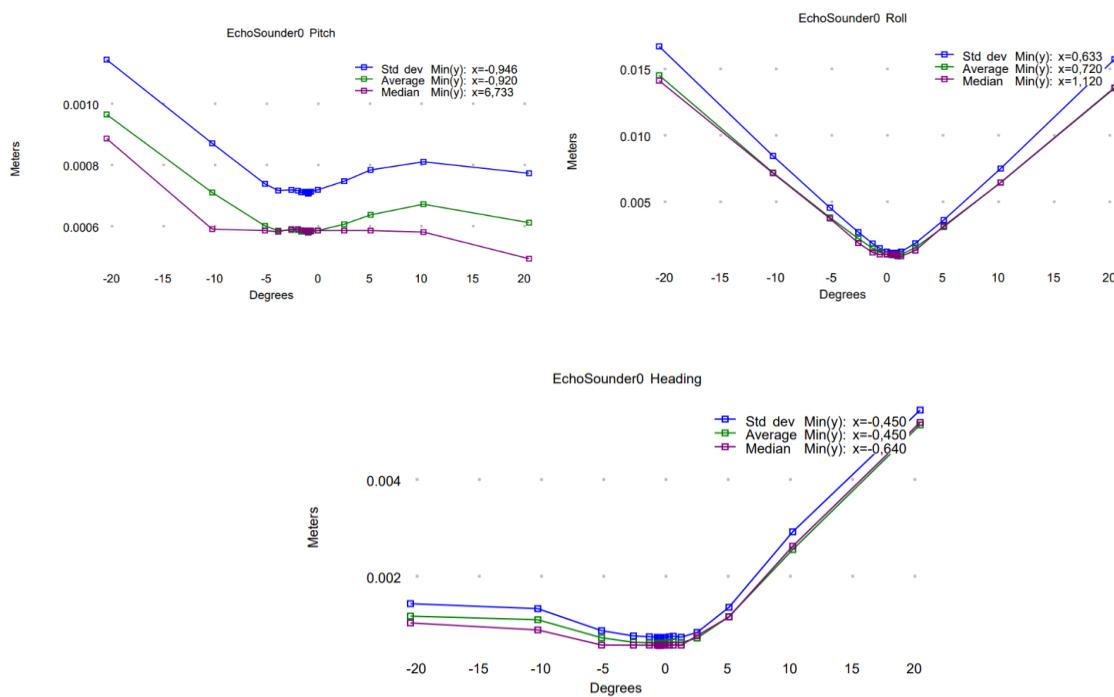
#### **4.1 Analisa Batimetri Multifrekuensi**

##### **4.1.1 Analisa Uji Tempel (*Patch Test*)**

Pada saat survei batimetri dengan MBES, beberapa sensor dipasang di kapal yaitu sensor navigasi (*Global Navigation Satellite System / GNSS*), sensor *Inertial Motion Unit* (IMU), dan sensor sonar (MBES) itu sendiri. Sensor navigasi bertujuan untuk mengukur kecepatan, arah, dan posisi kapal. Sensor IMU mengukur gerakan kapal (*pitch*, *roll*, *heave*, dan *yaw*). MBES digunakan untuk mengirim dan menerima gelombang suara untuk menentukan kedalaman air dan karakteristik dasar laut. Saat memasang ketiga sensor tersebut, terjadi ketidaksejajaran sehingga menyebabkan kesalahan sistematis. Oleh karena itu, sebelum survei dilaksanakan, pengujian yang sering disebut dengan *patch test* (uji tempel) harus dilaksanakan terlebih dahulu. Uji tempel ini bertujuan untuk memperbaiki kesalahan sistematis yang disebabkan oleh perbedaan posisi dan sudut pemasangan sensor. Sistem yang dikalibrasi dengan benar akan menunjukkan batimetri yang sama pada pengujian berulang terhadap variabel seperti kecepatan, arah, dan gerak kapal.

Pada umumnya, sinkronisasi waktu antara sensor MBES dan sensor navigasi tidak terjadi *delay* waktu (latensi). Jika terjadi latensi maka posisi kedalaman di area lereng akan bergeser secara lateral dengan perubahan kecepatan kapal survei. Pengukuran *roll* dilakukan pada satu jalur survei, diukur bolak-balik (dua kali) dan pada kecepatan kapal survei yang sama. Kesalahan dalam *roll* akan menghasilkan kesalahan dalam kedalaman suara area yang sama. Pengukuran *pitch* sama dengan *roll*, diukur bolak-balik dan pada kecepatan yang sama tetapi pada lokasi lereng di dasar laut. Efek kesalahan *pitch* meningkat secara signifikan dengan kedalaman lereng akan bergeser untuk arah timbal balik. Pengukuran *yaw* menggunakan dua garis paralel dengan kapal dalam arah yang sama pada garis. Kesalahan *yaw* akan ditunjukkan dengan pergeseran posisi objek.

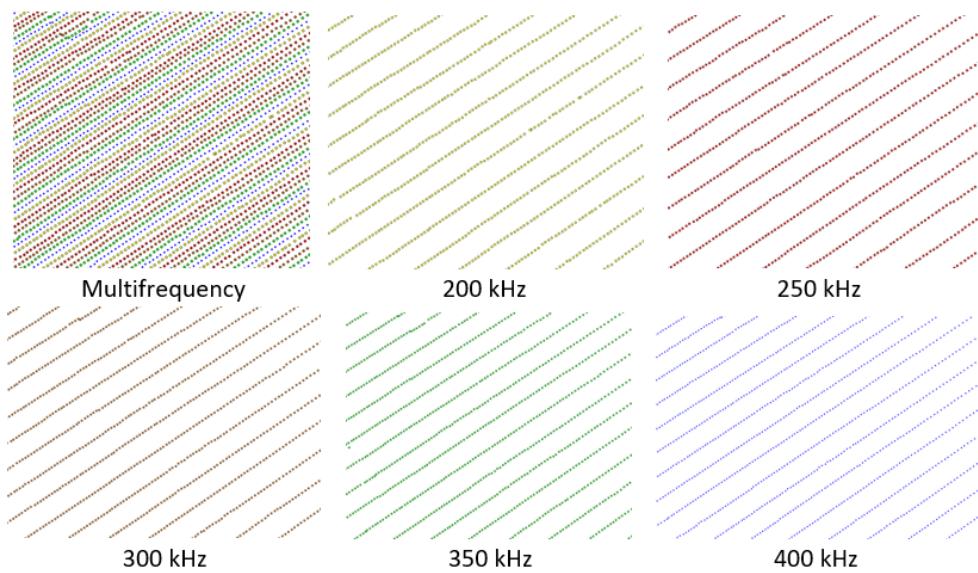
Gambar 4.1 menunjukkan hasil uji tempel, dengan *pitch* di -0.950, *roll* di -0.630, dan *heading* di -0.450. Menurut Brennan (2017), hasil uji tempel ini masuk toleransi yang diijinkan yaitu kurang dari  $1,5^{\circ}$ . Selanjutnya nilai-nilai uji tempel (*pitch*, *roll*, dan *heading*) dan latensi harus dimasukkan ke dalam perangkat lunak pengumpulan dan pengolahan data.



Gambar 4.2 Grafik nilai uji tempel (a) *pitch*, (b) *roll*, dan (c) *heading*

#### 4.1.2 Analisa Kerapatan Data MBES Multifrekuensi

Penelitian ini menggunakan multifrekuensi MBES R2Sonic 2020 dengan lima mode yaitu 200 kHz, 250 kHz, 300 kHz, 350 kHz, dan 400 kHz. Data multi frekuensi MBES dari survei masih berupa satu file dan harus dipisahkan menjadi lima file untuk setiap frekuensi. Kerapatan data setiap file adalah seperlima dari file asli. Jarak antar data (interval data) antara baris satu dengan baris berikutnya untuk masing-masing frekuensi lima kali dibandingkan dengan data di file aslinya.



Gambar 4.3 Kepadatan data MBES multifrekuensi dan setiap frekuensi

#### 4.1.3 Model Batimetri Digital MBES Multi Frekuensi

MBES adalah teknologi sonar yang paling efisien dan banyak digunakan untuk pemetaan dasar laut. Fungsi utama MBES adalah untuk mendeteksi sejumlah kedalaman di sepanjang petak bagian bawah (*footprint*). Transduser mengirimkan pulsa suara yang dipantulkan dari bawah dan diterima oleh serangkaian transduser untuk mendapatkan kedalaman ini di sektor sudut tertentu. Dalam dekade terakhir, beberapa produsen telah membuat MBES yang tidak hanya mampu menghasilkan satu frekuensi tetapi lebih dari satu frekuensi dengan satu survei berdasarkan *ping-by-ping*.

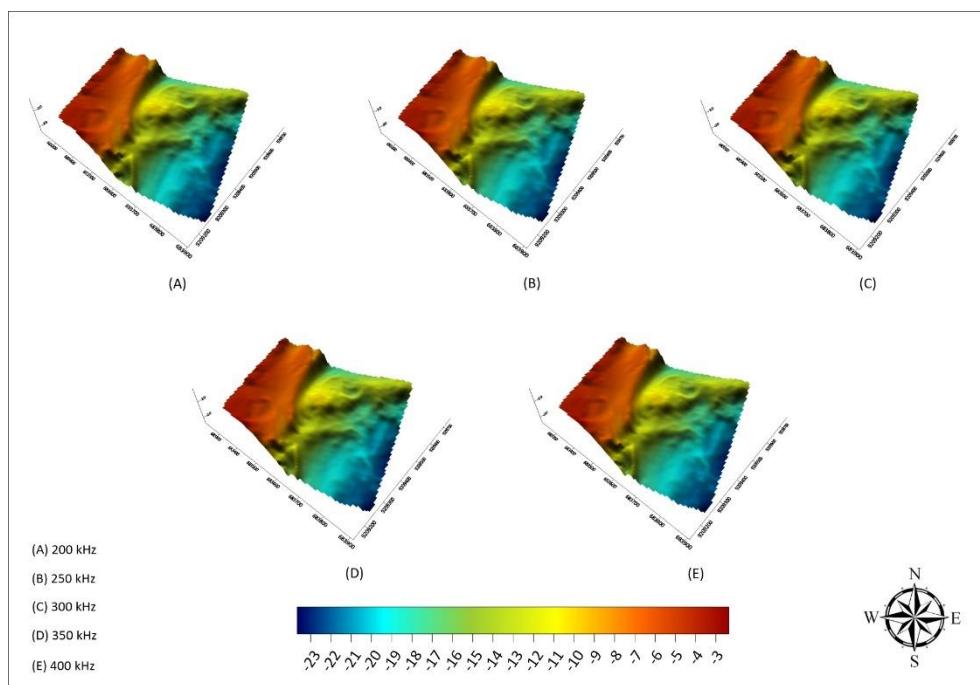
Data batimetri yang diperoleh MBES multifrekuensi harus mengikuti standar yang ditetapkan oleh Organisasi Hidrografi Internasional (IHO) S-44 edisi ke-6 (IHO, 2020). Ada lima kategori survei area mengenai persyaratan akurasi IHO S-44 untuk survei batimetri: *Order 2*, *Order 1b*, *Order 1a*, *Special Order*, dan *Exclusive Order*. Setelah data multifrekuensi pemrosesan MBES, nilai kedalaman total ketidakpastian horisontal (*Total Horizontal Uncertainty* / THU) untuk setiap frekuensi adalah 0,1 m, dan nilai kedalaman total ketidakpastian vertikal (*Total Vertical Uncertainty* / TVU) untuk setiap frekuensi adalah 0,2 m. Hasil ini mengacu pada IHO S-44 yang disimpulkan dalam orde khusus karena kedalaman maksimum

yang diijinkan THU adalah 2 m, dan kedalaman TVU adalah 0,25 m. Nilai kedalaman THU mengikuti rumus:

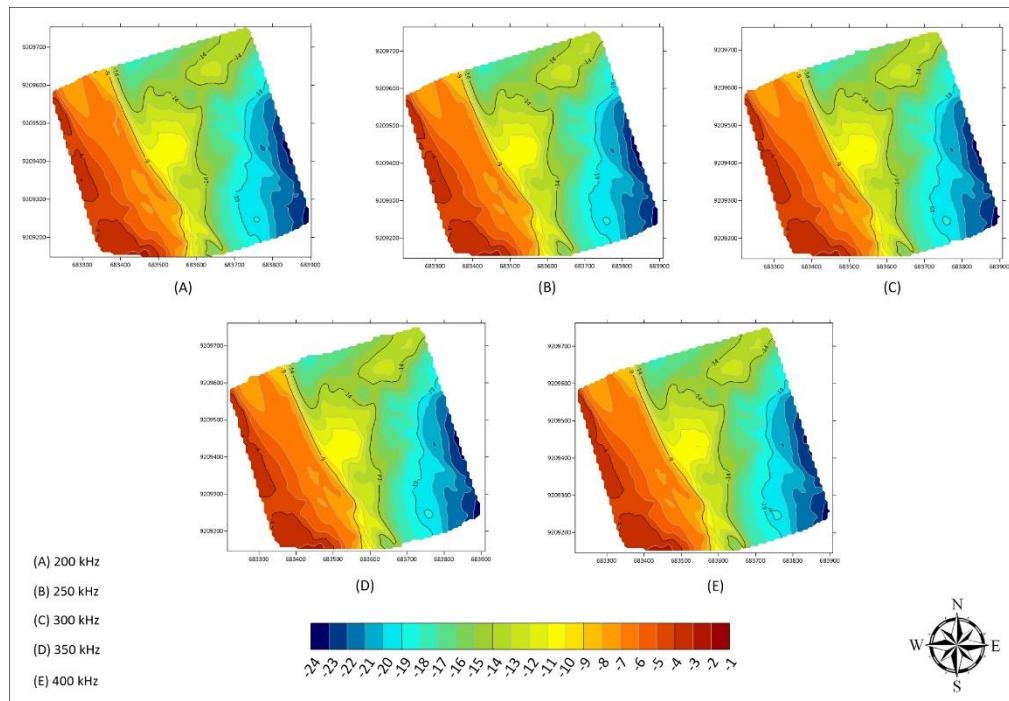
$$TVU_{max}(d) = \sqrt{a^2 + (b \times d)^2} \quad 4.1$$

di mana  $a = 0,25$  dan  $b = 0,0075$ , dan  $d$  adalah kedalaman. Dalam studi kasus ini, area survei dikategorikan berdasarkan order khusus.

Model batimetri digital (MBD) adalah model komputasi spasial yang secara otomatis menyajikan informasi kedalaman dasar laut. MBD diperlukan untuk menampilkan informasi survei kelautan. Ada beberapa metode untuk membangun MBD dasar laut, seperti interpolasi *linier*, *inverse distance weighted* (IDW), fungsi *spline*, *kriging*, dan lain-lain. Penelitian ini menggunakan metode interpolasi *Kriging* berdasarkan teori variabel regional dan fungsi semi varian sebagai alat bantu. Di bawah varians perkiraan minimal, metode interpolasi *Kriging* mempertimbangkan keacakan perubahan lapangan dan korelasi sampel diskrit (Wu dkk., 2021). Metode ini memberikan perkiraan linier optimal yang tidak bias.



Gambar 4.4 Model Batimetri Digital untuk masing-masing frekuensi



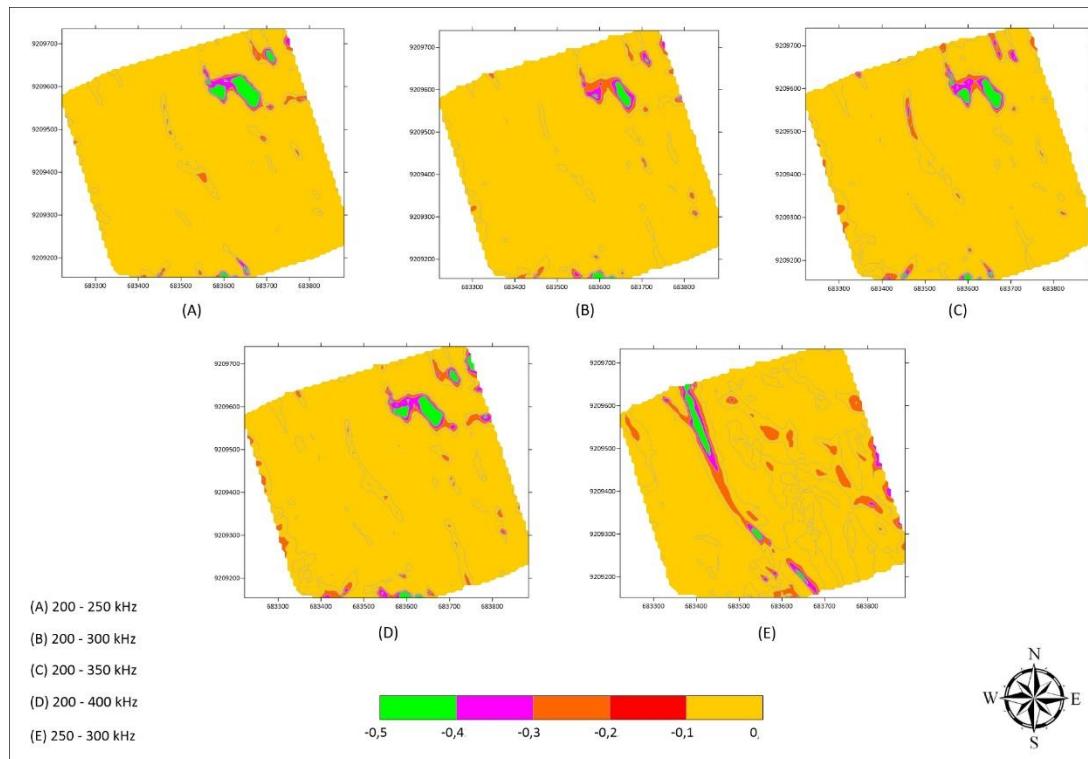
Gambar 4.5 Kontur kedalaman 2D masing-masing frekuensi

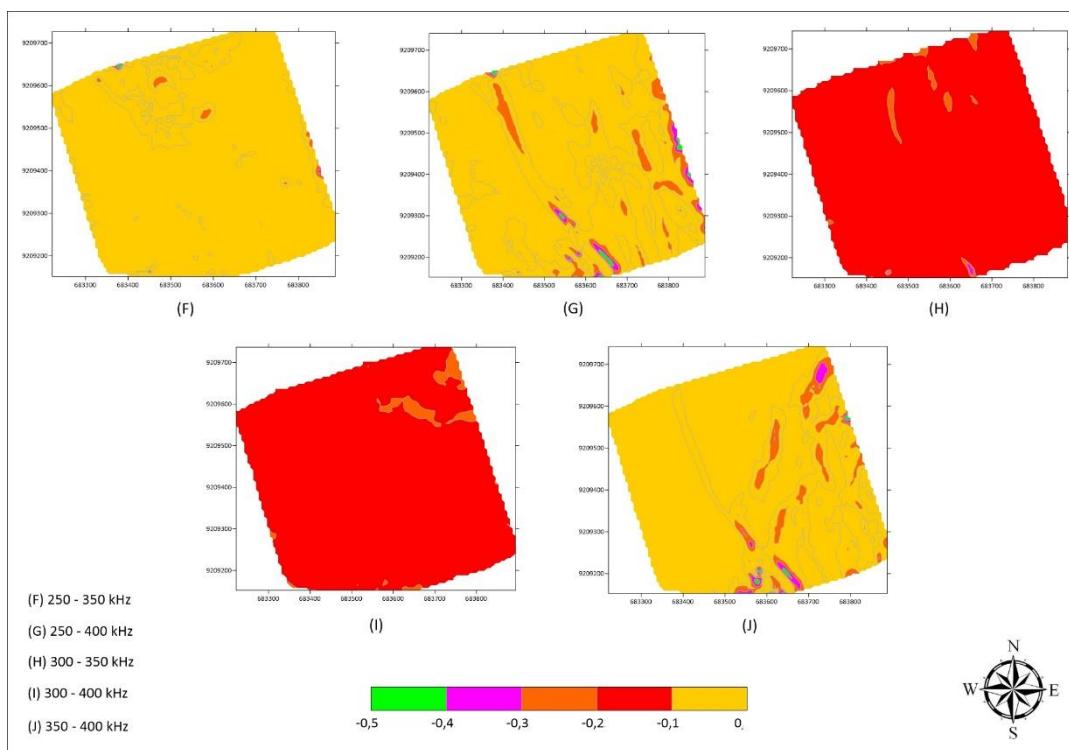
Gambar 4.3 menunjukkan model batimetri digital 3D dan Gambar 4.4 menggambarkan kontur kedalaman laut 2D untuk setiap frekuensi 200 kHz, 250 kHz, 300 kHz, 350 kHz, dan 400 kHz. Secara umum, kedalaman lokasi survei untuk setiap frekuensi menunjukkan kedalaman antara -2,5 m LWS dan -24,5 m LWS. Kedalaman sebelah barat area survei yaitu di area tepi pantai adalah dari -1,5 m LWS hingga -6,5 m LWS. Di tengah area survei, area masuk ke pelabuhan, kedalaman berkisar antara -6,5 m LWS hingga -14,5 m LWS; di sebelah barat, alur pelayaran pelabuhan Surabaya (APBS) mempunyai kedalamannya antara -14,5 m LWS dan -24,5 m LWS.

#### 4.1.4 Selisih Batimetri Antar Frekuensi

Pemrosesan data batimetri dilakukan dengan perangkat lunak Eiva, menerapkan penyaringan manual dan *spline* untuk menghilangkan artefak. Data batimetri kemudian dipisahkan per frekuensi dan di-grid menjadi grid  $1 \text{ m} \times 1 \text{ m}$ . Setelah ini, permukaan (*surface*) batimetri yang diperoleh untuk frekuensi yang

berbeda dikurangi satu sama lain untuk menghitung selisih batimetri yang diukur antar frekuensi. Setiap nilai kedalaman di setiap frekuensi dikurangi dengan nilai kedalaman frekuensi yang lain. Nilai kedalaman di frekuensi rendah dikurangi dengan nilai kedalaman di frekuensi tinggi. Sebagai contoh, Gambar 4.5, selisih kedalaman 200 – 250 kHz berarti kedalaman frekuensi 200 kHz dikurangi dengan nilai kedalaman di frekuensi 250 kHz. Gambar 4.5 menunjukkan semua hasil dari setiap pengurangan kedalaman antar frekuensi. Secara umum selisih kedalaman antar frekuensi menunjukkan selisih kedalaman 0 – 10 cm, kecuali selisih kedalaman antar frekuensi 300 kHz dengan kedalaman 350 kHz dan 400 kHz yang mempunyai selisih kedalaman 10 – 20 cm. Ada sebagian kecil area yang mempunyai selisih kedalaman 20 cm – 50 cm yang ditunjukkan dengan warna pink dan warna hijau.





Gambar 4.6 Selisih batimetri antar frekuensi MBES multi frekuensi

#### 4.1.5 Analisis Volume Selisih Batimetri

Dalam pekerjaan pengeringan, diperlukan data kedalaman permukaan 1 (eksisting) dan permukaan 2 (aktual). Idealnya, permukaan 1 dan permukaan 2 harus diukur dengan menggunakan alat survei MBES dengan spesifikasi yang sama, seperti frekuensi dan lebar *beam* yang sama, untuk menghasilkan kedalaman yang konsisten. Dalam studi kasus ini, perbedaan volume akan terlihat jika data yang digunakan pada permukaan 1 dan permukaan 2 menggunakan frekuensi yang berbeda. Data multi-frekuensi MBES di sini menggunakan mode 200 kHz, 250 kHz, 300 kHz, 350 kHz, dan 400 kHz, yang masing-masing secara bersamaan menghasilkan kedalaman di area survei yang sama (*ping by ping*). Tabel 4.1 berikut menunjukkan matriks volume galian dan timbunan (*cut and fill*) antar permukaan eksisting dan permukaan aktual dengan menggunakan nilai kedalaman dengan frekuensi yang berbeda.

Permukaan 1, yang digunakan untuk menghitung volume pada Tabel 4.1 adalah frekuensi yang lebih rendah daripada permukaan 2. Misalnya, baris pertama,

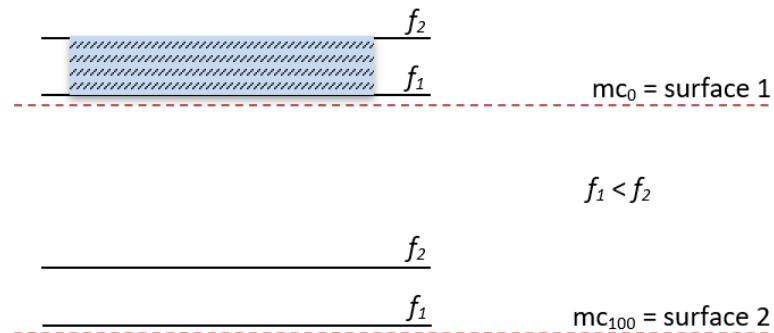
volumenya adalah 200 kHz – 250 kHz, yang berarti bahwa permukaan pertama adalah 200 kHz, dan permukaan kedua adalah 250 kHz. Nilai volume di atas diagonal utama menunjukkan volume timbunan, dan nilai di bawah diagonal utama menunjukkan volume galian. Untuk perhitungan volume antara 200 kHz dan 250 kHz, 146,912 m<sup>3</sup> harus diisi (diagonal atas) dan 2279,310 m<sup>3</sup> harus digali (diagonal bawah). Begitu juga sebaliknya, jika permukaan 1 adalah 250 kHz dan permukaan 2 adalah 200 kHz, maka ada sebanyak 2279,310 m<sup>3</sup> diisi sedimen (diagonal bawah) dan 146,912 m<sup>3</sup> untuk dipotong (diagonal atas).

Tabel 4.1 Volume keruk (*cut and fill*) selisih kedalaman antar frekuensi

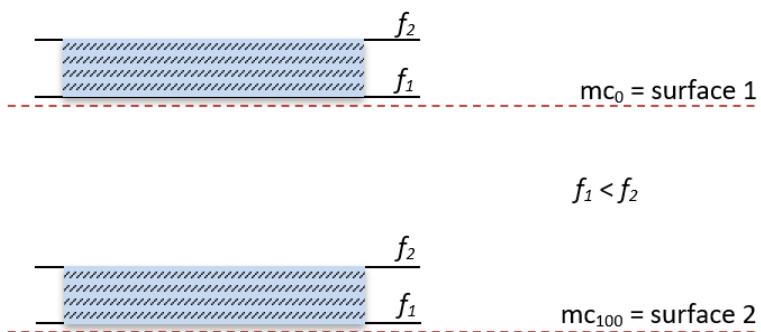
Volume (m <sup>3</sup> )	200 kHz	250 kHz	300 kHz	350 kHz	400 kHz
200 kHz	-	146,912	169,567	53,750	29,253
250 kHz	2279,310	-	420,036	32,060	46,039
300 kHz	4484,795	2619,716	-	1420,434	774,435
350 kHz	3904,702	1742,619	928,353	-	99,829
400 kHz	4943,502	2831,407	1345,516	1162,547	-

Dalam hal pekerjaan pengerukan, volume yang digunakan adalah volume keruk (*dredging*). Tabel 4.1 menunjukkan bahwa volume pengerukan antara frekuensi dengan frekuensi rendah sebagai permukaan 1 berarti bahwa nilai volume pengerukan jauh lebih besar daripada permukaan 2 ketika frekuensi yang lebih rendah digunakan, kecuali untuk volume pengerukan antar frekuensi 300 - 350 kHz. Volume pengerukan dimana frekuensi yang lebih rendah adalah sebagai permukaan 1, volume penggalian terkecil ditunjukkan oleh volume 300 kHz – 350 kHz, yaitu 928.353 m<sup>3</sup>, dan volume pengerukan yang sangat besar ditunjukkan oleh 200 kHz – 400 kHz, yaitu 4943.502 m<sup>3</sup>. Dengan luas 6,2 ha, volume pengerukan berkisar antara 0,015 m<sup>3</sup>/m<sup>2</sup> – 0,080 m<sup>3</sup>/m<sup>2</sup>. Hal ini berarti apabila permukaan 1 (survei  $mc_0$ ) menggunakan frekuensi yang lebih rendah ( $f_1$ ) dibandingkan frekuensi pada permukaan 2 ( $mc_{100}$ ), maka akan terjadi perbedaan (kelebihan) volume pengerukan antara 0,015 m<sup>3</sup>/m<sup>2</sup> – 0,080 m<sup>3</sup>/m<sup>2</sup> (Gambar 4.6). Sebaliknya, Gambar 4.7

menunjukkan permukaan 1 ( $mc_0$  survei) menggunakan frekuensi yang lebih tinggi ( $f_2$ ) dari permukaan 2, akan terjadi pengeringan berlebih 2 kali lipat dari  $0,015 \text{ m}^3/\text{m}^2 - 0,080 \text{ m}^3/\text{m}^2$  atau  $0,030 \text{ m}^3/\text{m}^2 - 0,160 \text{ m}^3/\text{m}^2$ .



Gambar 4.7 Kelebihan volume pengeringan jika  $mc_0$  menggunakan  $f_1$  dan  $mc_{100}$  menggunakan  $f_2$



Gambar 4.8 Kelebihan volume pengeringan jika  $mc_0$  menggunakan  $f_2$  dan  $mc_{100}$  menggunakan  $f_1$

Jika diasumsikan luas pengeringan adalah 1 ha, selisih volume pengeringan antara frekuensi maksimum berkisar antara  $420 \text{ m}^3$  hingga  $680 \text{ m}^3$ . Nilai ini hanya 4,2% - 6,8%, dibandingkan dengan total pengeringan dalam 1 ha yang dilakukan sedalam 1 m dengan total volume  $10000 \text{ m}^3$ . Semakin dalam pengeringan, semakin kecil persentase selisih volumenya, karena volume keruknya semakin besar akan tetapi selisih volumenya tetap (Tabel 4.2).

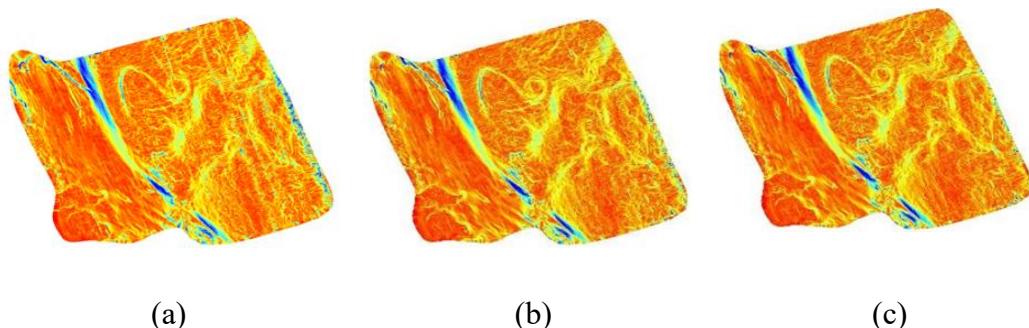
Tabel 4.2 Pengaruh penggunaan frekuensi yang berbeda terhadap volume pengerukan dalam 1 ha

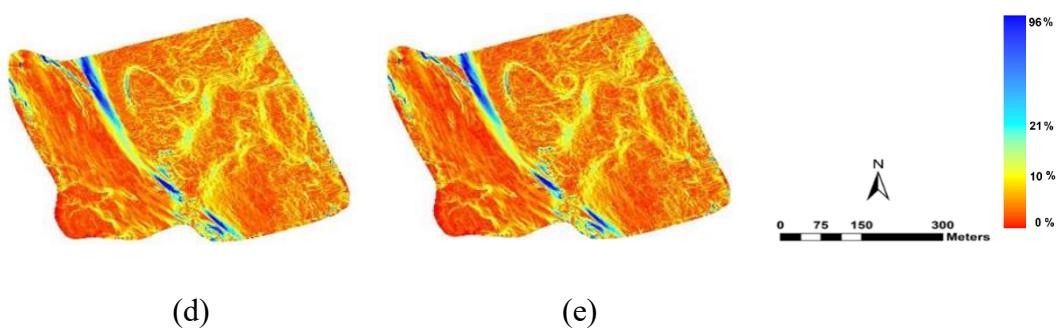
Ketebalan pengerukan	Volume Pengerukan	Perbedaan minimum ( $m^3$ )	%	Perbedaan maksimum ( $m^3$ )	%
1 m	10000	420	4.20	680	6.80
2 m	20000	420	2.10	680	3.40
3 m	30000	420	1.40	680	2.27
4 m	40000	420	1.05	680	1.70
5 m	50000	420	0.08	680	1.36

#### 4.1.6 Analisa Fitur Batimetri

##### 4.1.6.1 Kemiringan

Kemiringan merupakan turunan pertama dari data batimetri untuk mengukur perubahan ketinggian relatif terhadap jarak horizontal. Memahami peta lereng memberikan wawasan penting tentang karakteristik morfologi dasar laut, yang dapat mempengaruhi proses hidrodinamika, pola sedimentasi, dan distribusi habitat bawah laut. Dalam penelitian ini, setiap frekuensi menghasilkan kemiringan yang hampir sama. Secara umum, pada Gambar 4.8, daerah penelitian memiliki kemiringan sangat datar dan landai dengan prosentase kemiringan kurang dari 7% (merah), landai 7% - 15% (kuning), agak curam dengan kemiringan 15% – 30% (biru muda) dan beberapa tempat sangat curam dengan kenaikan lebih dari 30% (biru tua). Area batas biru dan merah menunjukkan batas tebing. Dalam kasus ini, area dengan kemiringan curam dan sangat curam diperkirakan area dengan sedimen dasar yang keras (pasir – gravel).

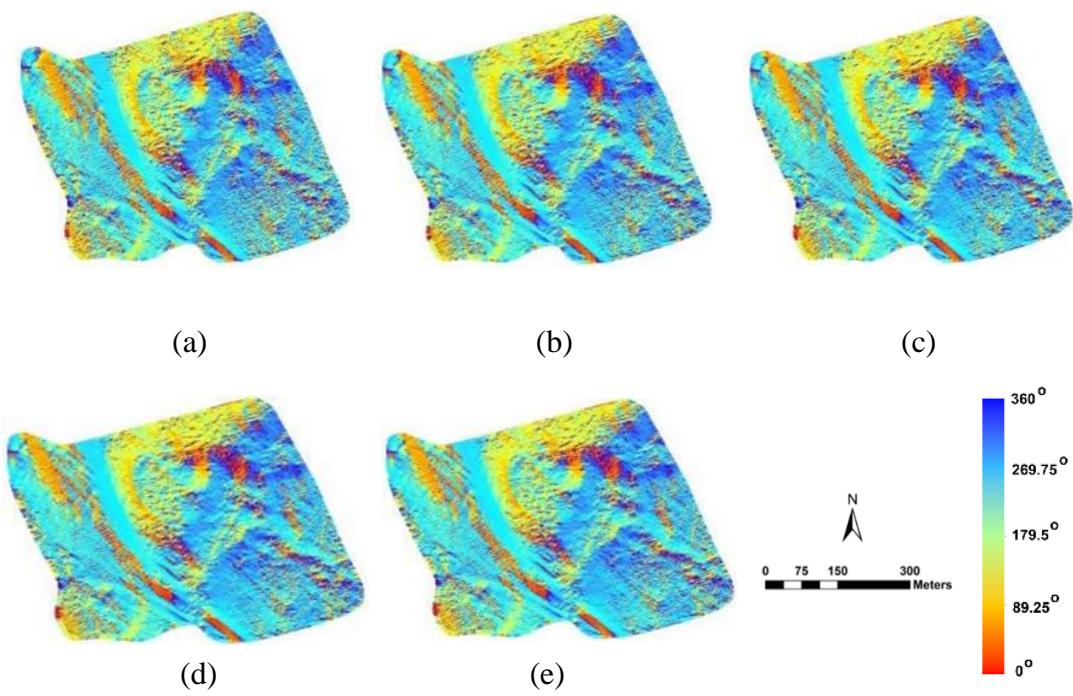




Gambar 4.9 Kemiringan dasar laut area survei (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 350 kHz (e) 400 kHz

#### 4.1.6.2 Aspek

Wajah lereng di setiap urutan, seperti utara, selatan, timur, atau barat, disebut sebagai arah wajah lereng dalam menghasilkan karakteristik kedalaman. Melihat permukaan searah jarum jam dari utara memungkinkan seseorang untuk menghitung aspek. Distribusi flora dan fauna laut, serta pola arus laut dan sedimen, semuanya dipengaruhi oleh faktor ini. Interaksi antara morfologi dasar laut dan proses samudera membantu mendeteksi fitur seperti sungai, lembah, punggung bukit, dan daerah datar di bawah air.

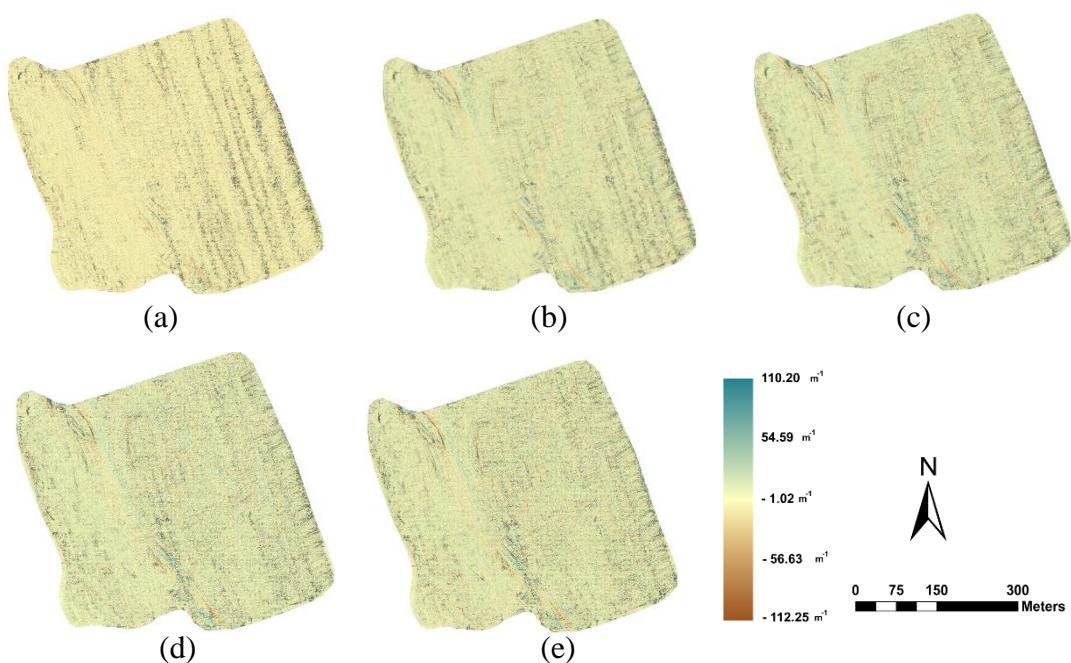


Gambar 4.10 Aspek Fitur batimetri (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 350 kHz (e) 400 kHz

Gambar 4.9 menunjukkan sebagian besar wilayah penelitian memiliki lereng utara – barat, disajikan dengan warna biru. Warna kuning ke hijau menunjukkan aspek di area tepi sebelah utara dengan arah selatan – timur (90-180). Area kecil berorientasi dari utara - timur (0–90) dilambangkan dengan warna merah.

#### 4.1.6.3 Kelengkungan (*Curvature*)

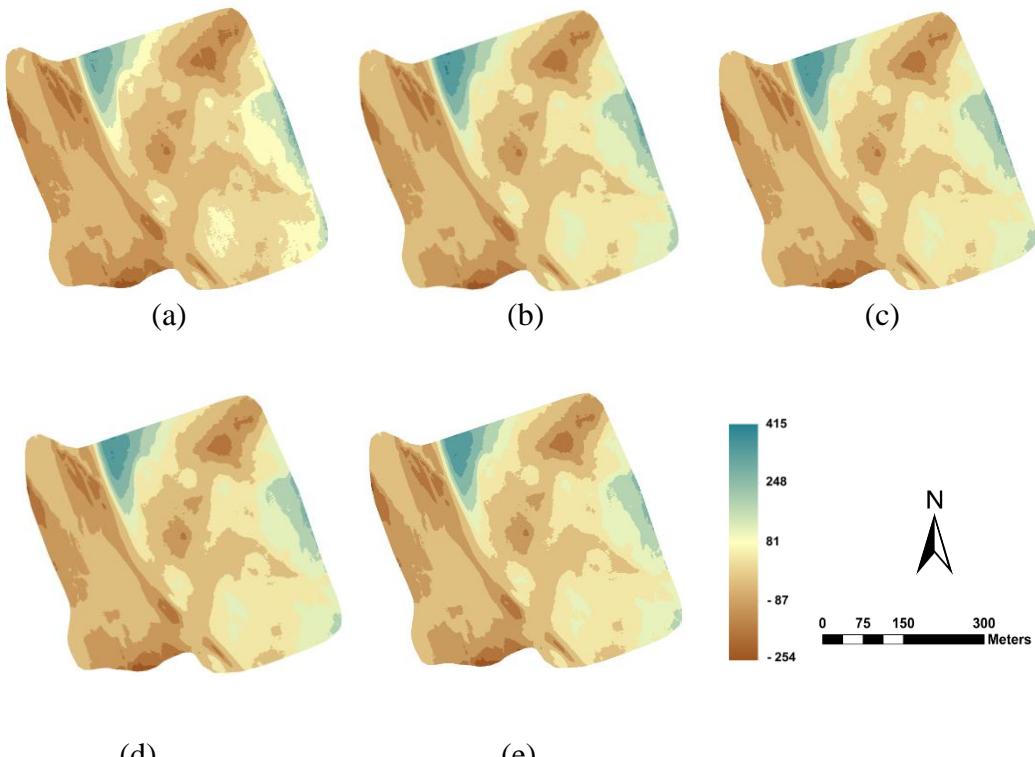
Turunan kedua dari permukaan pengukur kedalaman disebut kelengkungan, dan ini menggambarkan bagaimana sudut dasar laut berubah di sekitar suatu titik. Nilai kelengkungan positif mewakili kelengkungan puncak luar permukaan dasar laut. Memahami kelengkungan dalam analisis yang dihasilkan dari fitur kedalaman dapat menawarkan wawasan tentang formasi geologi bawah laut, fitur topografi seperti punggung bukit, lembah, atau terumbu karang, dan hubungan antara interaksi antara proses oseanografi dan morfologi dasar laut. Setiap kelengkungan di area penelitian di setiap frekuensi ditunjukkan pada Gambar 4.10. Secara umum, nilai kelengkungan untuk setiap frekuensi adalah sama dengan nilai antara  $0 \text{ m}^{-1}$  dan  $10 \text{ m}^{-1}$ .



Gambar 4.11 Kelengkungan fitur batimetri (a) 200 kHz (b) 250 kHz (c) 300 kHz  
(d) 350 kHz (e) 400 kHz

#### 4.1.6.4 Indeks Posisi Batimetri (*Bathymetric Position Index*)

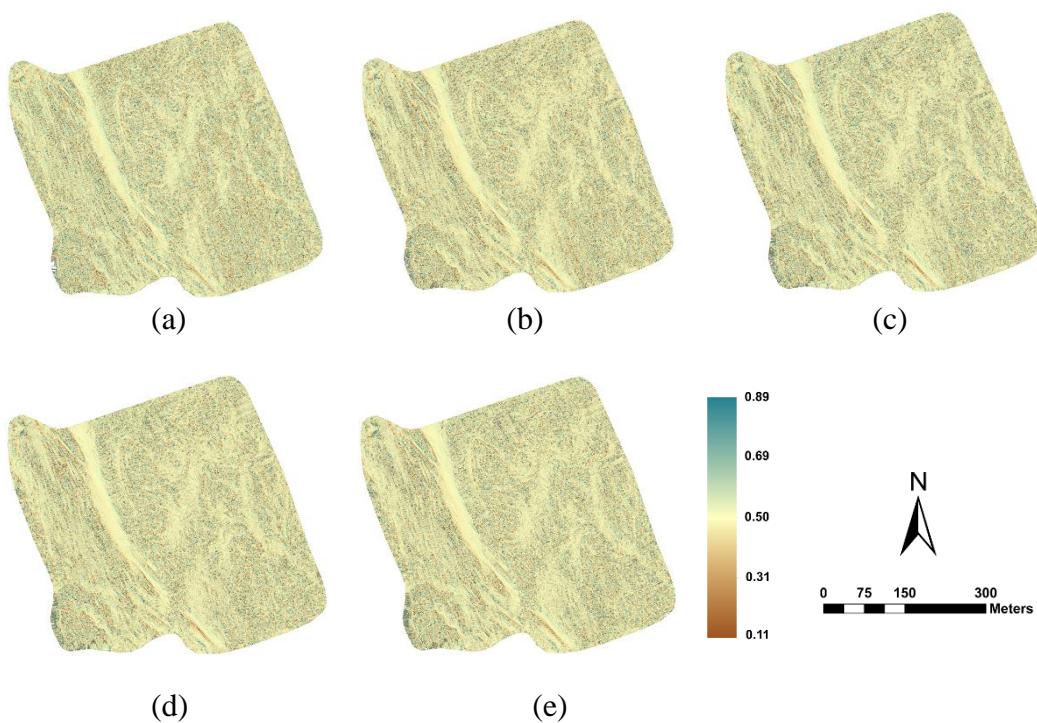
Indeks Posisi Batimetri (BPI) mengukur di mana area yang direferensikan relatif terhadap area yang melingkupinya. BPI ditentukan dari kumpulan informasi batimetri input, dan perhitungan indeks posisi topografi disesuaikan dalam lingkungan bumi. Nilai sel positif (kuning ke hijau pada Gambar 4.11) di dalam kumpulan informasi BPI menandakan sorotan dan lokal yang lebih tinggi dari zona sekitarnya. Oleh karena itu, wilayah dengan nilai positif, sebagian besar, mencirikan tepi dan sorotan terkait lainnya di dalam wilayah yang melingkupi. Selain itu, nilai sel negatif (coklat pada Gambar 9.11) di dalam kumpulan informasi BPI menunjukkan sorotan dan lokal yang lebih rendah dari rentang yang melingkupi. Rentang nilai sel negatif terutama mencirikan lembah dan sorotan terkait lainnya di dalam kumpulan informasi batimetri. Nilai BPI mendekati nol adalah rentang level (di mana kemiringan mendekati nol) atau daerah dengan kemiringan konsisten (di mana kemiringan titik sama sekali lebih menonjol daripada nol).



Gambar 4.12 BPI fitur batimetri (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 350 kHz (e) 400 kHz

#### 4.1.6.5 Kekasaran (*Roughness*)

Kekasaran dasar laut adalah variabilitas elevasi dalam unit spasial yang menggambarkan komponen bentuk lahan dan menyimpulkan informasi tentang proses geomorfologi. Informasi ini bermanfaat untuk menunjukkan kompleksitas dan heterogenitas sedimen dasar laut. Nilai kekasaran (Gambar 4.12) untuk semua frekuensi di area survei mempunyai nilai sekitar 0,4 – 0,6.

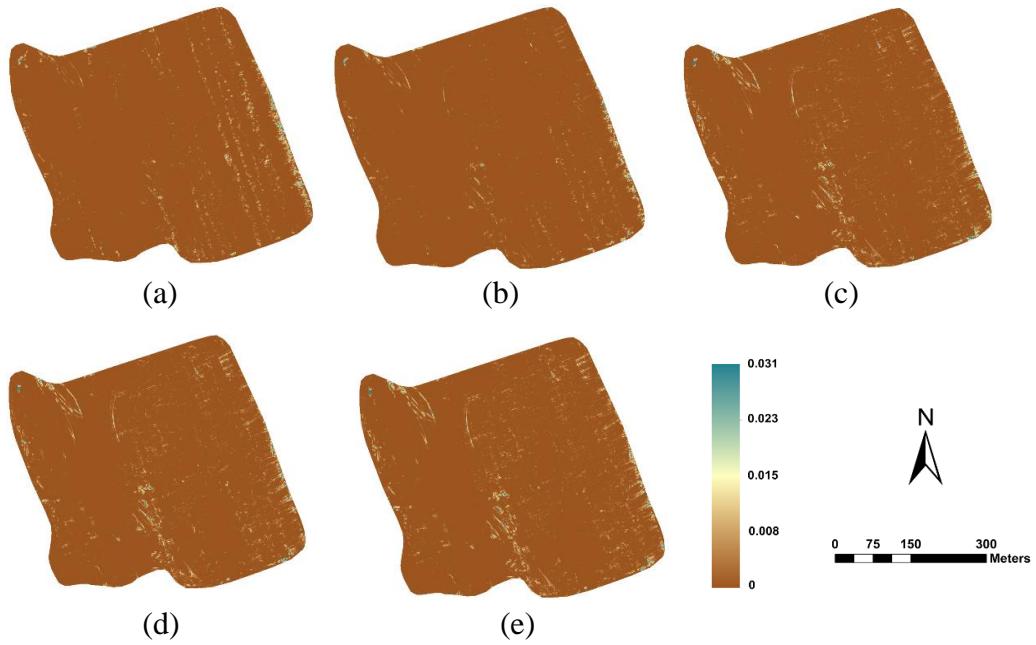


Gambar 4.13 Kekasaran fitur batimetri (a) 200 kHz (b) 250 kHz

(c) 300 kHz (d) 350 kHz (e) 400 kHz

#### 4.1.6.6 Kekerasan (*Ruggedness*)

*Terrain Ruggedness Index* (TRI), atau yang sering disebut *ruggedness*, adalah perbedaan kedalaman antar sel yang saling berdekatan. Nilai kekerasan di area survei (Gambar 4.13) minimal yaitu kurang dari 0,05, sehingga dapat disimpulkan bahwa permukaan area survei adalah mempunyai kekerasan yang sama.

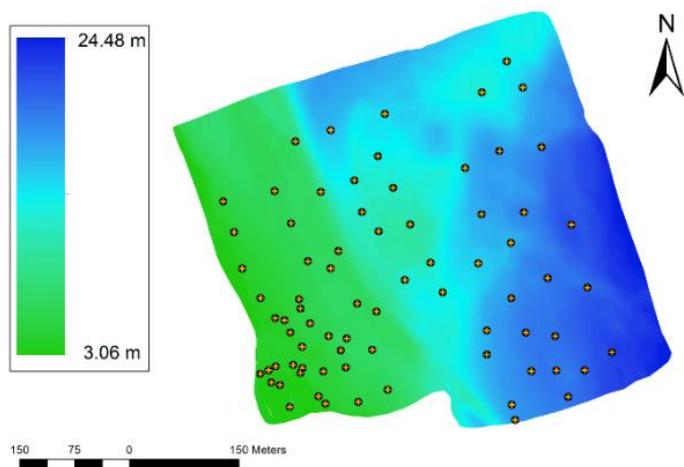


Gambar 4.14 Kekerasan fitur batimetri (a) 200 kHz (b) 250 kHz  
 (c) 300 kHz (d) 350 kHz (e) 400 kHz

## 4.2 Sampel *in Situ* Sedimen Dasar Laut

### 4.2.1 Distribusi Sampel Sedimen Dasar Laut *in Situ*

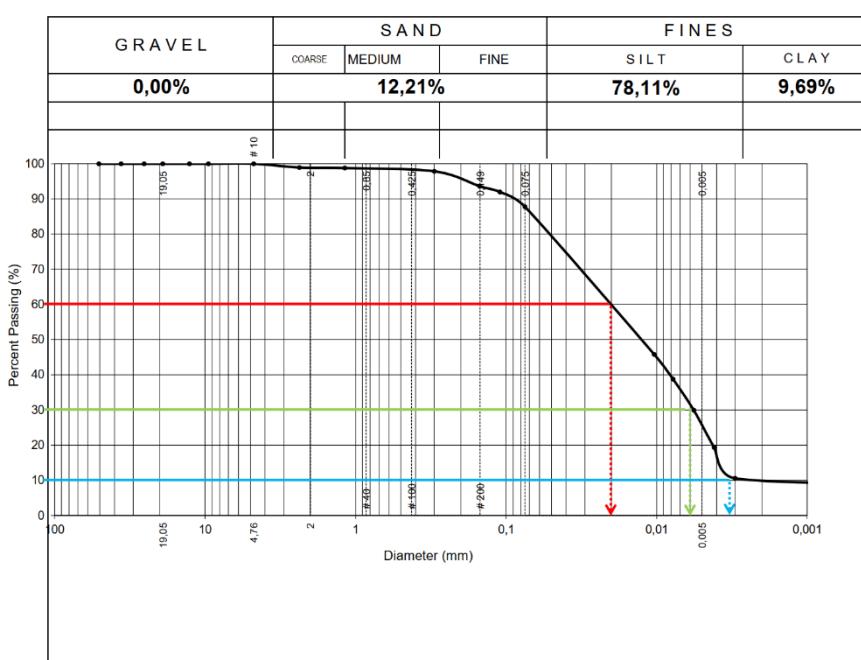
Pengetahuan sebelumnya tentang sedimen dasar laut diperlukan untuk mendapatkan sampel sedimen dasar laut yang representatif di daerah penelitian. Pertama, peta batimetri, pengetahuan arus pasang surut, dan data lainnya dapat memberikan beberapa petunjuk. Survei pendahuluan ini dapat membantu dalam memilih area pengambilan sampel sebelum rencana pengambilan sampel dibuat. Data sedimen akan dikumpulkan dari 74 lokasi sampel yang didistribusikan secara merata di seluruh wilayah penelitian (Gambar 4.14). Untuk penyelidikan biologis, hidrologi, dan lingkungan di perairan dalam dan arus kuat, pengambilan sampel dengan *Grab sampler* Van Veen cocok untuk mendapatkan sampel massal dari berbagai bahan, dari bahan lunak dan berbutir halus hingga berpasir (IAEA. 2003). Posisi titik sampel diukur dengan GNSS RTK dengan akurasi kurang dari 10 cm. Sampel sedimen diuji melalui analisis saringan untuk mendapatkan persentase komposisi sedimen untuk setiap kerikil, pasir, tanah liat, dan lanau.



Gambar 4.15 Distribusi sampel sedimen dasar laut di area survei

#### **4.2.2 Analisis Ukuran Butir Sedimen**

Tujuh puluh empat titik sampel sedimen dasar laut (Gambar 4.14) diuji di laboratorium menggunakan metode analisis saringan (*Sieveig Analysis*). *Analisis Saringan* (Retsch, 2015) adalah proses yang digunakan untuk memeriksa dan mengukur ukuran partikel dalam sampel bahan. Hal ini biasanya melibatkan penyaringan sampel melalui serangkaian saringan, yang masing-masing memiliki ukuran jaring yang berbeda untuk memungkinkan partikel dengan ukuran berbeda untuk melewatinya.

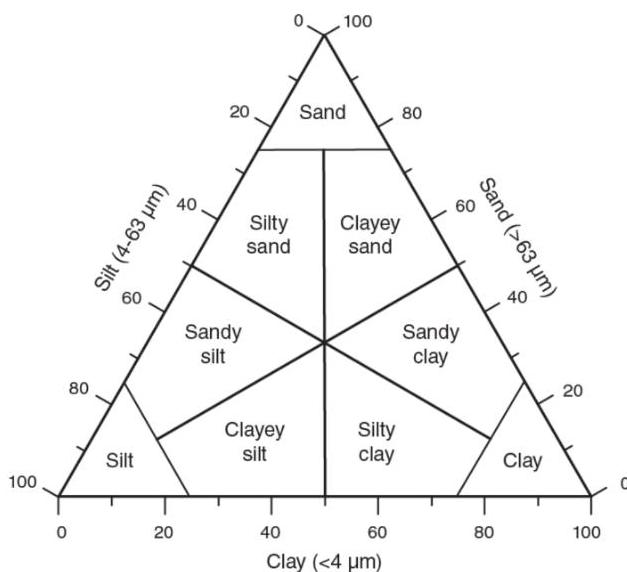


Gambar 4.16 Contoh hasil analisis sieving dengan kurva distribusi ukuran butir

Proporsi partikel yang jatuh ke dalam rentang ukuran yang berbeda kemudian dapat diukur dan dibandingkan, untuk membantu mengevaluasi kualitas sampel sedimen dasar laut. Gambar 4.15 menunjukkan salah satu contoh hasil analisis saringan, dimana di dalam gambar tersebut menunjukkan persentase kerikil (0,0%), pasir (12,21%), dan lumpur (lanau 78,11% dan lempung 9,69%).

#### 4.2.3 Analisis Jenis Sampel Sedimen Dasar Laut

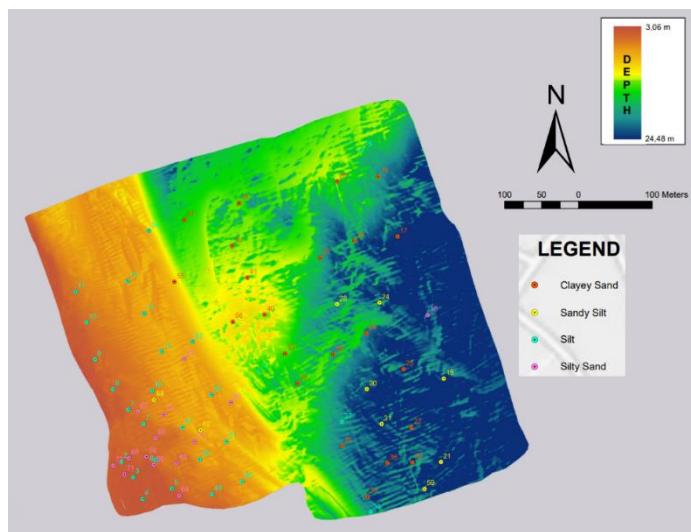
Hasil analisis pengayakan menunjukkan bahwa setiap sampel sedimen memiliki komposisi persentase ukuran sedimen *gravel*, *sand*, *silt* dan *clay*, seperti yang ditunjukkan pada Gambar 4.15, diklasifikasikan menggunakan diagram *Terner* (segitiga *Sheppard*) seperti pada Gambar 4.16 (France-Lanord et.al 2016). Hasil analisis saringan pada Gambar 4.15, diklasifikasikan dengan diagram *Terner*, menunjukkan bahwa hasil klasifikasi sedimen pada titik sampel adalah lumpur berpasir. Cara yang sama digunakan untuk mengklasifikasikan 73 sampel sedimen lainnya.



Gambar 4.17 Diagram segitiga *Sheppard* yang menunjukkan klasifikasi sedimen menurut tekstur butirannya (France-Lanord dkk., 2016)

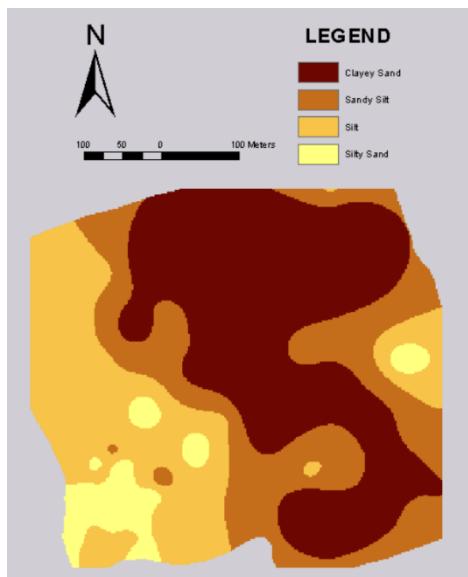
Dari 74 titik sampel sedimen yang tersebar di area survei, terdapat empat kelas sedimen yang didasarkan pada diagram terner: pasir lempung (*clayey sand*), pasir berlanau (*silty sand*), lanau berpasir (*sandy silt*) dan lanau (*silt*). Distribusi jenis sedimen hasil klasifikasi disajikan pada Gambar 4.17. Jenis sedimen *silt*

mendominasi area di tepi pantai (sebelah barat) dengan kedalaman kurang dari 3 m – 7 m, tipe sedimen *silt* di kedalaman 3 – 4 m yang terletak di tepi barat sebelah selatan, tipe *clayey sand* di area tengah dengan kedalaman 13 – 20 m dan tipe sedimen *sandy silt* di sebelah timur (area alur pelayaran barat Surabaya) dengan kedalaman lebih dari 20 m.



Gambar 4.18 Distribusi tipe sedimen dasar laut di area survei

Gambar 4.18 menggambarkan distribusi sedimen dasar laut di wilayah survei. Secara umum area survei didominasi oleh tipe sedimen *clayey sand* yang terletak di tengah area survei (coklat tua), disusul oleh *sandy silt*, *silt* dan *silty sand*.



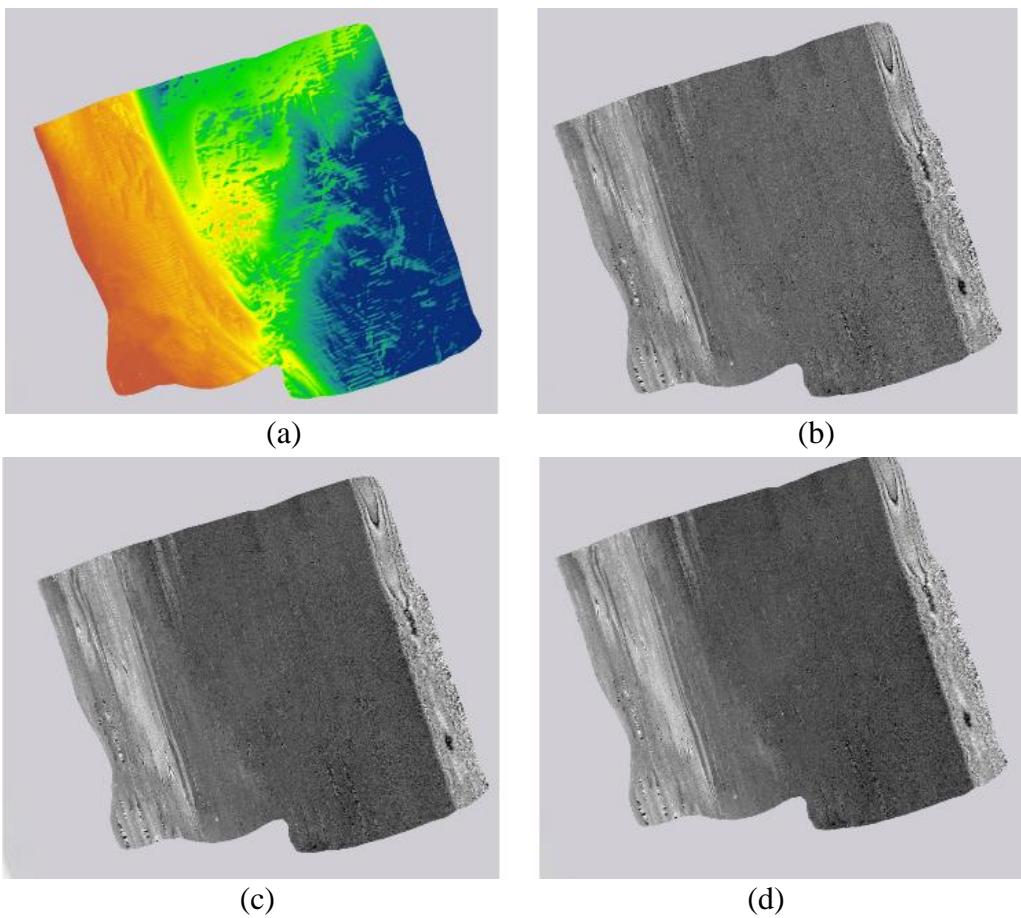
Gambar 4.19 Klasifikasi sedimen dasar hasil interpolasi linear jenis sampel sedimen sampel in situ

## **4.3 Backscatter**

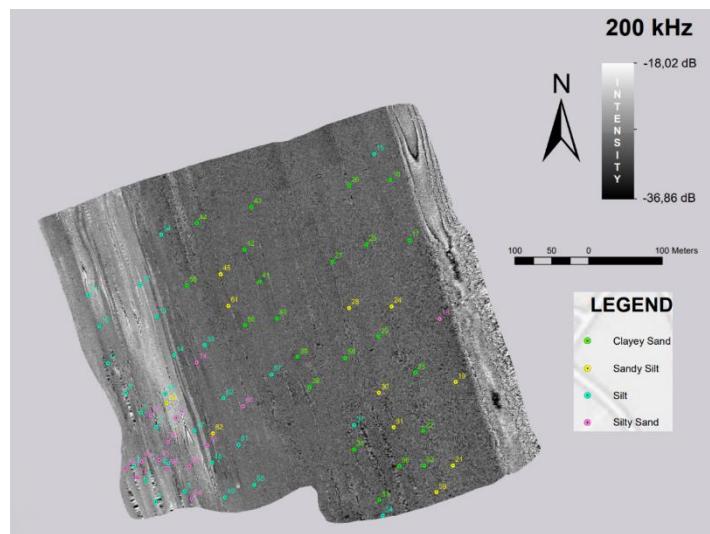
### **4.3.1 Mosaik Backscatter**

Mosaik *backscatter* adalah representasi digital dari dasar laut yang dibuat dari data amplitudo sinyal akustik yang dikumpulkan dari data sonar. Mosaik *backscatter* ini diproduksi dengan menggunakan program perangkat lunak yang menghilangkan faktor-faktor yang mengganggu seperti *Time-Varying Gain* dan menggunakan koreksi radiometrik untuk membuat gambar dasar laut pada resolusi tertentu. Selanjutnya mosaik *backscatter* dapat digunakan untuk analisis lebih lanjut yaitu salah satunya untuk interpretasi sedimen dasar laut. Gambar 4.19 menunjukkan data mosaik batimetri dan hamburan balik untuk frekuensi 200 kHz, 300 kHz, dan 400 kHz. Hasil *backscatter* menunjukkan bahwa kepadatan data sangat penting ketika melakukan analisis *backscatter* multispektral dan bahwa data berbeda dari data yang dikumpulkan dalam satu baris.

Gambar 4.19 (b), (c), dan (d) menunjukkan mosaik hamburan balik untuk setiap frekuensi masing-masing 200 kHz, 300 kHz, dan 400 kHz. Umumnya, permukaan dasar laut daerah studi memiliki intensitas yang hampir sama untuk ketiga frekuensi. Warna terang menunjukkan intensitas yang lebih tinggi -25 dB, dan warna hitam menunjukkan intensitas kurang dari -25 dB. Perbedaan intensitas ini disebabkan oleh kedalaman. Semakin dangkal, semakin besar intensitasnya. Survei wilayah bagian barat menunjukkan intensitas yang lebih tinggi daripada intensitas di tengah. Selain itu, perbedaan intensitas juga bisa disebabkan oleh jenis sedimen yang ada di bagian bawah. Kepadatan material dasar laut mempengaruhi reflektifitas gelombang suara yang digunakan dalam analisis hamburan balik oleh MBES. Jika materialnya lebih padat, seperti kerikil, pasir, atau cangkang, itu akan memantulkan sinyal yang lebih kuat ke sounder. Namun, jika materialnya kurang padat, seperti lumpur, tanah liat, dan lanau, gelombang suara sebagian akan tenggelam ke dalam material berukuran butiran kecil, menghasilkan sinyal yang lebih lemah.



Gambar 4.19 Data (a) batimetri dan mosaik *backscatter* (b) 200 kHz (c) 300 kHz dan (d) 400 kHz



Gambar 4.200 Overlay distribusi jenis sedimen dasar laut in situ dengan backscatter

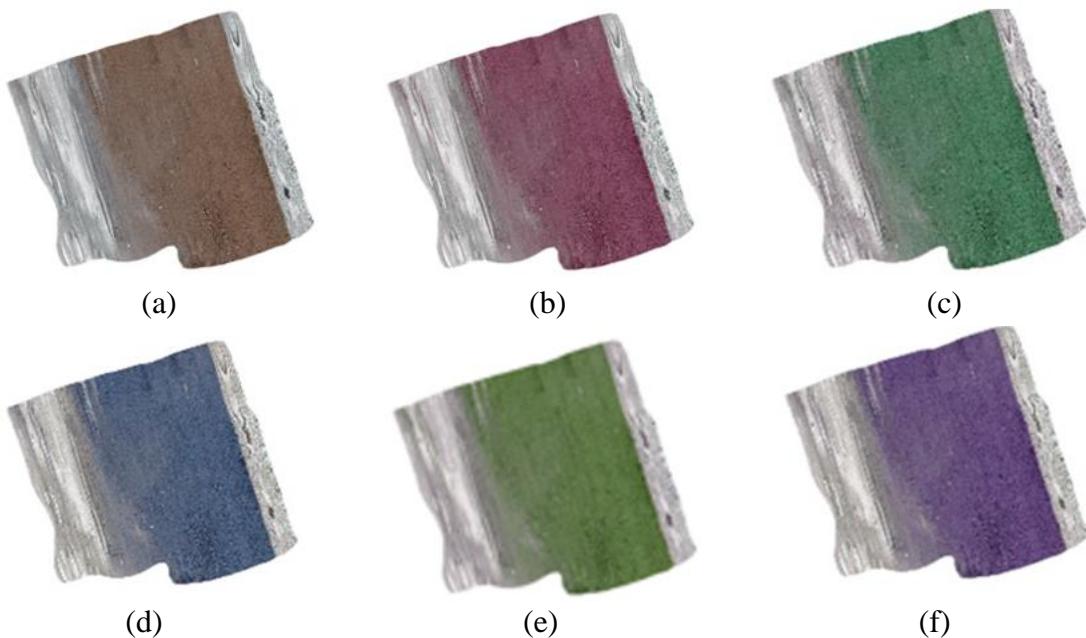
Jenis sedimen dasar laut in situ dioverlaikan dengan mosaik *backscatter* ditunjukkan pada Gambar 4.20. Di area sebelah paling timur mempunyai intensitas tinggi sekitar -18 dB, akan tetapi area ini tidak ada titik sampel sedimen in situ yang mewakilinya. Area sebelah barat dengan intensitas -25 dB sampai dengan -18 dB didominasi tipe sedimen *silt* dan *silty sand*. Sedangkan area tengah dengan intensitas kurang dari -25 dB didominasi oleh tipe sedimen *clayey sand* dan *sandy silt*.

Selanjutnya, masing-masing mosaik *backscatter* pada Gambar 4.19 di atas digabungkan untuk menciptakan *backscatter* multispektral. *Backscatter* multispektral menggunakan lebih dari satu jenis frekuensi atau panjang gelombang saat mengumpulkan data. Penelitian ini menggunakan beberapa frekuensi dengan sistem MBES untuk mengumpulkan data batimetri dan *backscatter*. Data ini kemudian dapat digunakan untuk memeriksa komposisi dasar laut, seperti kekerasan, karakteristik sedimen, ukuran butir sedimen, dan membantu untuk membedakan antara jenis sedimen dengan lebih baik. Mosaik hamburan balik untuk setiap frekuensi pada Gambar 4.21 (b), (c), dan (d) digabungkan satu sama lain untuk membuat citra multispektral. Gambar multispektral ditangkap oleh sensor yang mendeteksi cahaya dalam berbagai spektrum atau frekuensi.

Gambar *backscatter* multispektral dapat digunakan untuk mempelajari dasar laut karena panjang gelombang yang lebih pendek dapat menciptakan resolusi yang lebih tinggi dan memungkinkan deteksi fitur yang lebih kecil. Gambar multispektral dapat memberikan lebih banyak informasi daripada gambar monospektral biasa, yang hanya menangkap cahaya dalam satu spektrum. Gambar 4.21 menunjukkan komposit warna palsu dengan beberapa pita (kombinasi merah, hijau, dan biru) untuk mosaik hamburan balik multispektral seperti RGB234, RGB243, RGB324, RGB342, RGB423, dan RGB432, di mana 2, 3, dan 4 mewakili penamaan untuk frekuensi masing-masing 200 kHz, 300 kHz, dan 400 kHz.

Gambar 4.21 komposit warna palsu adalah gambar yang telah dimodifikasi dengan warna sehingga fitur yang berbeda dapat lebih mudah diidentifikasi. Ini sering digunakan dalam studi penelitian untuk mengidentifikasi berbagai jenis sedimen dasar laut, seperti contoh dari penelitian ini yang digunakan untuk mengidentifikasi sedimen keras dan lunak. Gambar warna palsu mengambil tiga

pita spektral yang berbeda, atau frekuensi, dan menggunakan intensitasnya untuk mengubah warnanya. Ini memudahkan peneliti untuk mengenali fitur dalam gambar dengan cepat. Tiga *band* yang disebutkan dalam teks ini mengacu pada tiga frekuensi berbeda yang digunakan untuk mencoba dan mendapatkan pemahaman yang lebih baik tentang karakteristik geologi dasar laut dan habitat bentik.

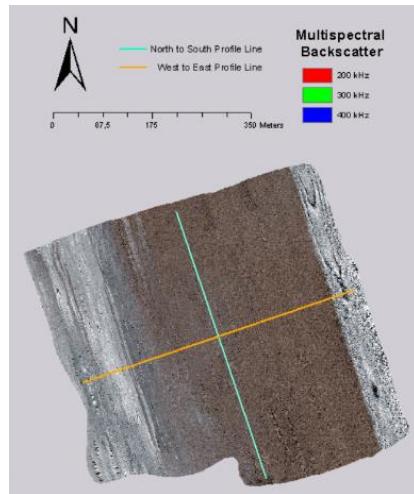


Gambar 4.21 Mosaik *backscatter* multispektral (a) RGB234 (b) RGB243  
(c) RGB324 (d) RGB342 (e) RGB423 (f) RGB432

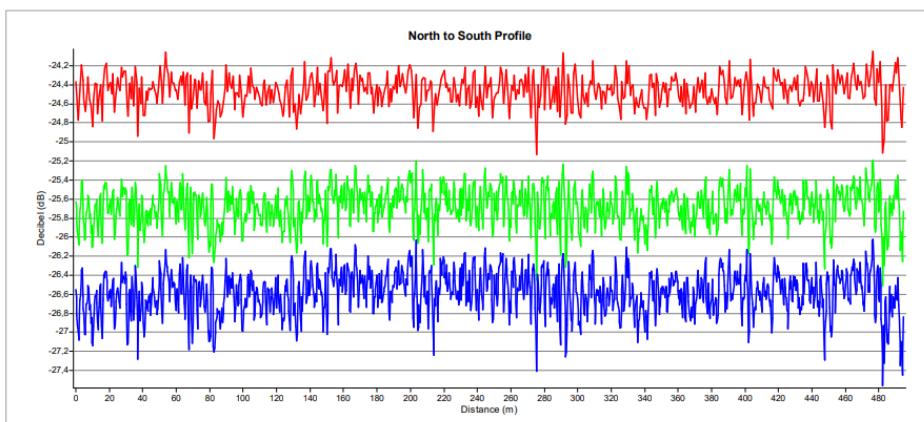
Dengan menggabungkan frekuensi yang berbeda ini, para peneliti berharap dapat membedakan antara lebih banyak jenis substrat dasar laut dan mendapatkan gambaran yang lebih baik tentang pemetaan habitat mereka. Misalnya, ketika ketiga pita frekuensi memiliki intensitas yang sama, gambar yang dihasilkan tampak putih, yang biasanya menunjukkan dasar laut yang keras. Ini biasanya terjadi di tempat-tempat datar dengan lapisan lumpur tebal dan lunak. Warna lain, seperti ungu, dapat dihasilkan oleh variasi intensitas relatif pita frekuensi, dan ini kadang-kadang dapat mengungkapkan informasi tentang jenis substrat dasar laut yang ada di sana.

Gambar 4.22 menunjukkan intensitas hamburan balik di Barat ke Timur (W-E) dan Utara ke Selatan (N-S). Frekuensi 200 kHz memiliki intensitas yang

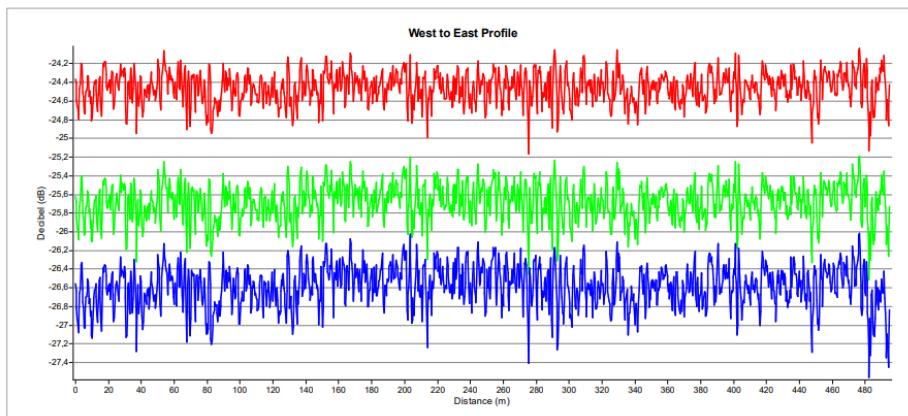
lebih tinggi daripada yang lain, karena pada saat yang sama, kedalaman, dan lokasi, semakin besar frekuensi, semakin besar atenuasi.



(a)



(b)



(c)

Gambar 4.22 Intensitas hamburan balik dari tiga mosaik multispektral di sepanjang transek (a) RGB234 (b) Barat ke Timur (c) Utara ke Selatan

Hubungan antara atenuasi dan frekuensi adalah fenomena di mana kekuatan sinyal menurun ketika frekuensi sinyal meningkat. Sederhananya, ini adalah melemahnya sinyal dengan peningkatan frekuensi — jumlah atenuasi karena hamburan meningkat kira-kira mengikuti hubungan frekuensi-kuadrat. Ketika frekuensi gelombang suara meningkat, jumlah atenuasi juga akan meningkat secara signifikan. Redaman hamburan  $\alpha_s$  sebagai fungsi frekuensi (Wang dkk., 2021)

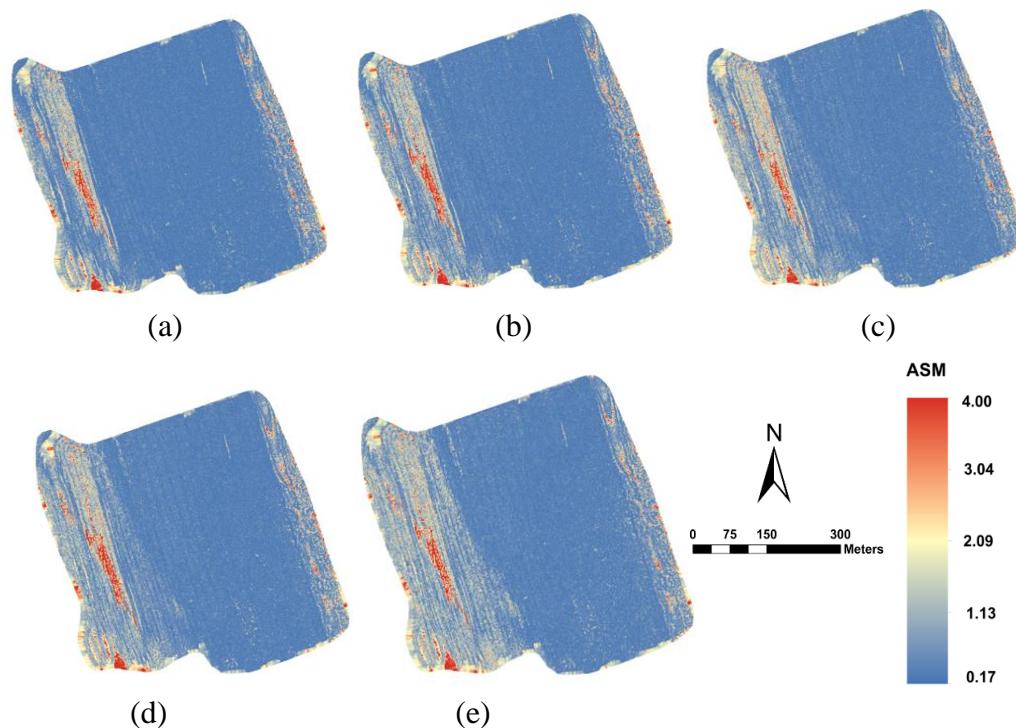
$$\alpha_s = A_s \times 20 \log_{10} e \times f^2 \quad 4.2$$

sedangkan faktor hamburan atenuasi dan satuan frekuensi adalah Hz.

#### 4.3.2 Fitur Backscatter

##### 4.3.2.1 Angular Second Moment (ASM)

*Angular Second Moment* (ASM) adalah pola fitur yang digunakan untuk mengukur keseragaman gambar, yaitu ketika piksel memiliki nilai yang sangat mirip, ASM akan menjadi signifikan.

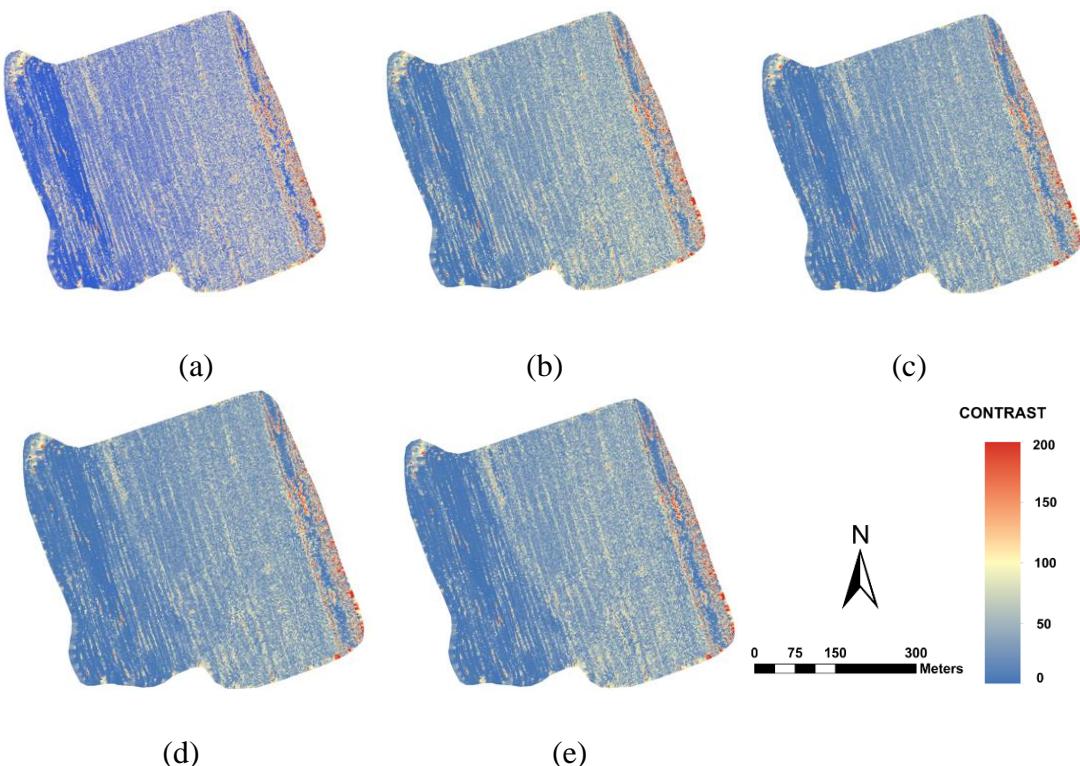


Gambar 4.23 *Angular Second Moment* (ASM) MBES untuk setiap frekuensi:

- (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 400 kHz (e) 450 kHz

#### 4.3.2.2 Contrast

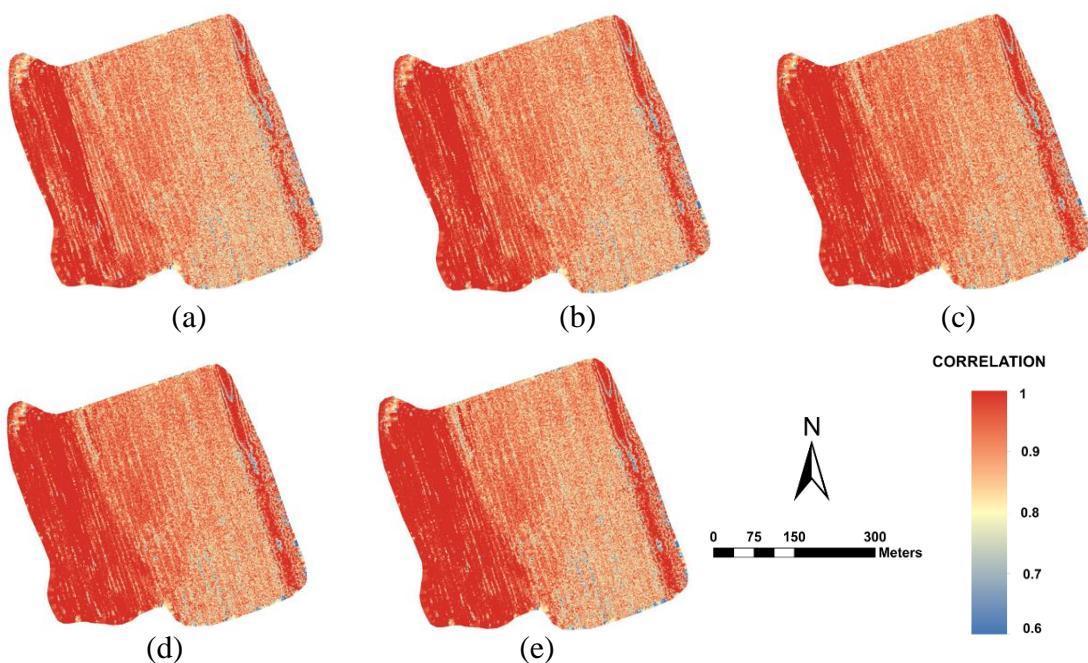
Kontras mengukur intensitas atau variasi tingkat abu-abu antara piksel referensi dan tetangganya. Dalam persepsi visual dunia nyata, kontras ditentukan oleh perbedaan warna dan kecerahan objek dan objek lain dalam bidang pandang yang sama. Kontras adalah ukuran variasi lokal yang ada dalam gambar. Kontras akan tinggi jika ada jumlah variasi yang tinggi. Gambar 4.24 menunjukkan wilayah barat dengan nilai kontras kurang dari 50, wilayah tengah antara 50 – 100, dan wilayah timur sedikit 100 – 150.



Gambar 4.24 Kontras MBES untuk setiap frekuensi: (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 400 kHz (e) 450 kHz

#### 4.3.2.3 Correlation

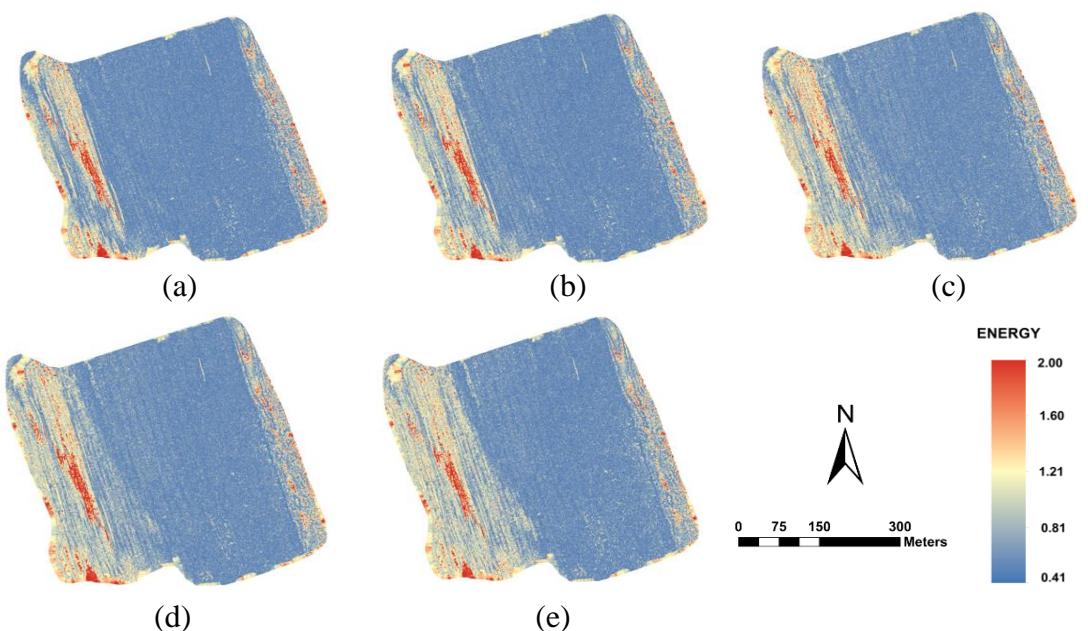
Fitur korelasi menunjukkan ketergantungan linier dari nilai tingkat abu-abu dalam matriks kejadian bersama. Ini menyajikan bagaimana piksel referensi terkait dengan tetangganya: 0 tidak berkorelasi, dan 1 berkorelasi sempurna. Gambar 4.25 menunjukkan nilai korelasi di area survei lebih dari 0,8.



Gambar 4.255 Korelasi untuk setiap frekuensi: (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 400 kHz (e) 450 kHz

#### 4.3.2.4 Energi

Energi juga berarti keseragaman. Semakin homogen gambarnya, semakin besar nilainya. Ketika energi sama dengan 1, gambar diyakini sebagai gambar konstan.

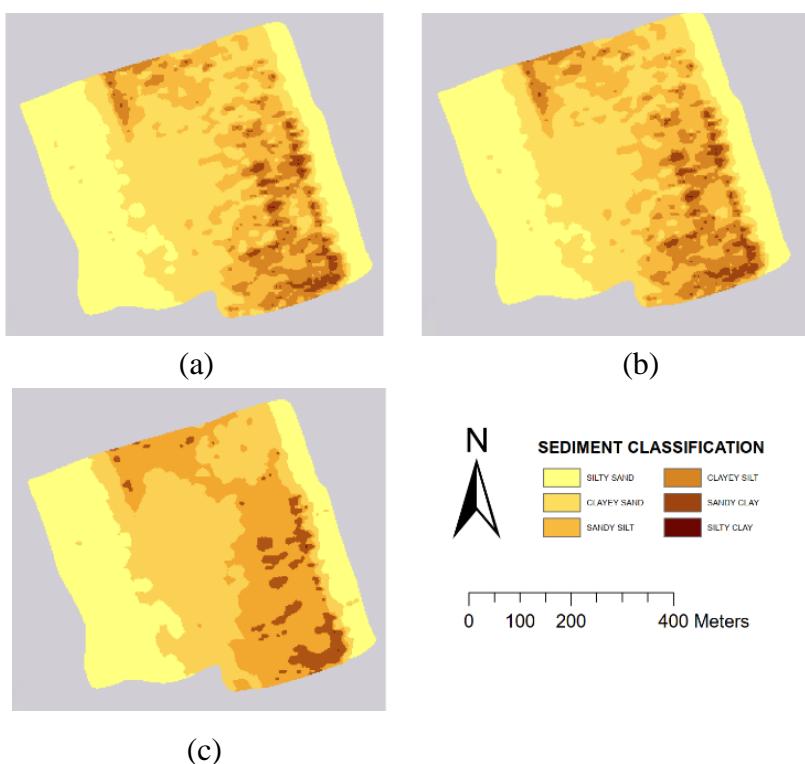


Gambar 4.26 Energy (a) 200 kHz (b) 250 kHz (c) 300 kHz (d) 400 kHz (e) 450 kHz

## 4.4 Klasifikasi Sedimen Dasar Laut

### 4.4.1 Angular Response Analysis

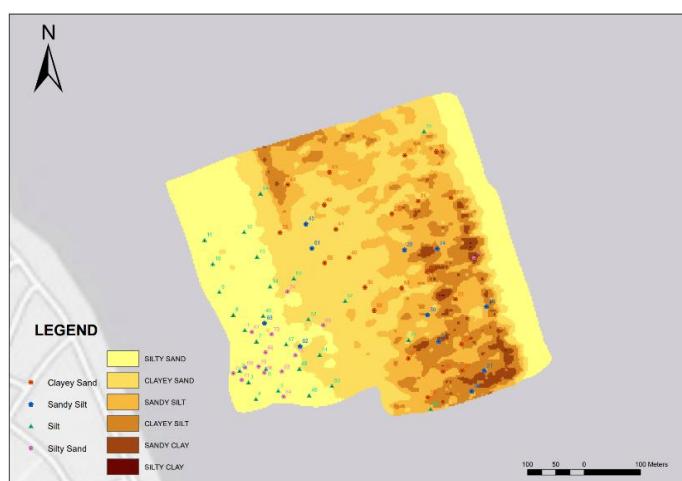
*Angular range analysis* (ARA) adalah teknik yang dapat digunakan untuk menghitung seluruh *angular response curve* (ARC) di setiap setengah petak MBES untuk mengevaluasi atribut substrat. Untuk lebih memahami jenis dasar laut di daerah tersebut (Lurton dan Lamarche, 2015) mengklaim bahwa ARA adalah teknik untuk mengukur dan menganalisis hamburan balik suara dari dasar laut. Informasi dikumpulkan dari berbagai sudut, dan varians dalam hamburan balik dengan alat bantu sudut dalam mengklasifikasikan dan menggambarkan dasar laut. Enam jenis sedimen ditunjukkan pada gambar berdasarkan kurva respons sudut dan analisis respons sudut mosaik hamburan balik untuk frekuensi 200 kHz, 300 kHz, dan 400 kHz, masing-masing: pasir berlumpur (*silty sand*), pasir berlanau (*clayey sand*), lumpur berpasir (*sandy silt*), lumpur berlanau (*clayey silt*), lanau berpasir (*sandy clay*), dan lanau berlumpur (*silty clay*). Jumlah kelas klasifikasi ARA pada Gambar 4.27 berbeda dengan jumlah kelas klasifikasi data sedimen in situ pada Gambar 4.18.



Gambar 4.27 Klasifikasi sedimen dasar dengan metode ARA (a) 200 kHz, (b) 300 kHz, (c) 400 kHz

Secara visual pada Gambar 4.27, klasifikasi sedimen oleh ARA untuk setiap frekuensi ini menghasilkan distribusi sedimen dasar laut yang serupa. Warna kuning di sebelah timur dan barat area survei menunjukkan kelas pasir (pasir sedang – pasir halus – pasir berlumpur). Ini selaras dengan mosaik *backscatter* warna putih pada Gambar 4.19 dan mosaik *backscatter* multispektral pada Gambar 4.21, yang menunjukkan nilai *backscatter* tertinggi di daerah tersebut. Di tengah area survei didominasi oleh sedimen lanau (lanau kasar – lanau berpasir – lanau sedang). Sebagian kecil dari area ini adalah tanah liat berlumpur dan kelas tanah liat yang ditunjukkan dengan warna coklat.

Klasifikasi sedimen dasar laut menggunakan metode ARA kemudian diuji dengan 74 titik sampel sedimen yang tersebar merata di area survei pada Gambar 4.28. Uji yang digunakan adalah uji matriks konfusi (Cunningham, 2009) yaitu dengan menghitung akurasi keseluruhan (*overall accuracy*) dan koefisien kappa (*kappa coefficient*). Akurasi klasifikasi adalah ukuran seberapa akurat model klasifikasi terhadap data lapangan. Akurasi keseluruhan dihitung dengan membandingkan prediksi dari model dengan kelas data yang sebenarnya. Akurasi klasifikasi yang tinggi berarti bahwa model dapat secara akurat memprediksi kelas data. Sedangkan nilai Kappa adalah ukuran seberapa akurat model prediktif, yang bervariasi dari 0 hingga 1, di mana 0 menunjukkan bahwa model sama sekali tidak akurat dan 1 menunjukkan akurasi sempurna.



Gambar 4.28 Overlai 74 titik sampel sedimen di klasifikasi ARA

Tujuh puluh empat sampel sedimen di lokasi survei digunakan untuk uji akurasi keseluruhan dan koefisien kappa hasil klasifikasi sedimen dasar laut dengan menggunakan metode ARA. Hasil perhitungan matriks konfusi menunjukkan akurasi keseluruhan sebesar 51% dan koefisien kappa sebesar 0,37 untuk semua frekuensi. Ini berarti bahwa hanya setengah titik prediksi sama dengan titik sampel yang sebenarnya. Menurut (Landis dan Koch, 1977), nilai koefisien kappa 0,37 termasuk dalam kategori cukup (*fair*).

#### **4.4.2 Deep Neural Network**

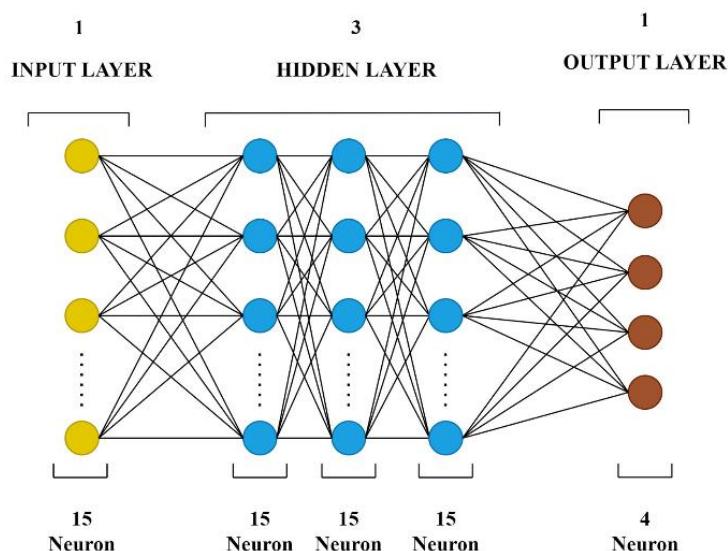
*Deep Neural Network* (DNN) adalah model *Artificial Neural Network* (ANN) pembelajaran mendalam (Deng dan Yu, 2014), yang terdiri dari *perceptron multi-layer* dengan banyak lapisan tersembunyi, bobot yang sepenuhnya terhubung dan sering diinisialisasi menggunakan teknik pra-pelatihan tanpa label atau berlabel. Tujuan utama dari jaringan saraf adalah untuk mengambil satu set input, melakukan perhitungan yang semakin kompleks pada mereka, dan memberikan output untuk memecahkan masalah dunia nyata seperti klasifikasi. Model DNN banyak digunakan dalam pemrosesan sinyal dan gambar karena kelebihannya, seperti strukturnya yang sederhana dan mudah dipahami (Bosse dkk., 2017).

Selain itu, definisi lain berdasarkan (Zhu dkk., 2021) menyatakan bahwa DNN adalah model jaringan dengan struktur lapisan input, lapisan output, dan beberapa lapisan tersembunyi yang terhubung ke setiap lapisan. Pentingnya lapisan dan *neuron* tertentu dalam struktur DNN adalah untuk melakukan ekstraksi fitur, mengidentifikasi dan memisahkan informasi yang relevan dari data input yang diperlukan untuk membuat prediksi dan keputusan.

##### **4.4.2.1 Klasifikasi Sedimen Dasar Laut dengan input Batimetri dan Selisih Batimetri**

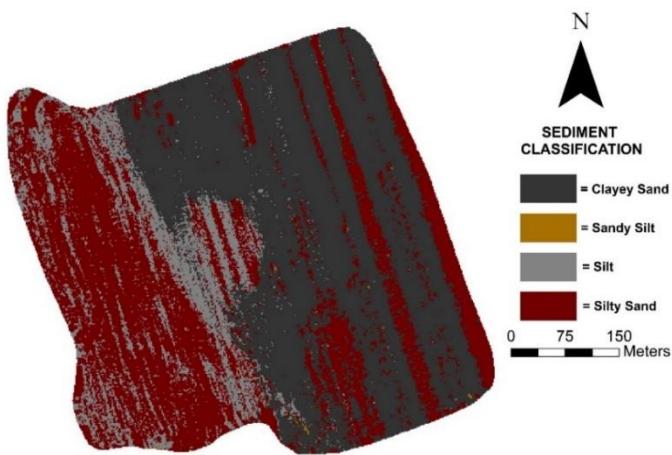
Gambar 4.29 menunjukkan diagram struktur DNN yang digunakan dalam kasus ini dengan lapisan input memiliki 15 *neuron* (lima perbedaan batimetri dan sepuluh batimetri), bobot dan bias yang sesuai dari lapisan tersembunyi, dan empat neuron (empat jenis sedimen) sebagai lapisan output.

Fungsi aktivasi diperlukan untuk menentukan apakah neuron harus aktif atau tidak berdasarkan jumlah input tertimbang. Fungsi aktivasi adalah fungsi yang digunakan untuk memproses informasi dari input dengan perhitungan. Beberapa fungsi aktivasi dapat digunakan dalam jaringan *deep learning*; tetapi dalam kasus ini, fungsi aktivasi *rectified linear unit (ReLU)* digunakan untuk memproses lapisan tersembunyi dan fungsi aktivasi *softmax* digunakan untuk memproses lapisan keluaran. Model *deep neural network* yang dibuat dengan berbagai parameter yang telah ditentukan kemudian dilakukan dalam proses perhitungan menggunakan input data yang telah disiapkan sebelumnya.



Gambar 4.29 Model pengklasifikasi *Deep Neural Network*

Gambar 4.30 menunjukkan hasil klasifikasi sedimen dasar laut menggunakan *deep neural network* (DNN) dengan perbedaan batimetri dan batimetri input data frekuensi. Secara umum, sedimen dasar di daerah penelitian didominasi oleh pasir lempung dan diikuti oleh pasir berlumpur. Pasir Berlumpur menyebar di dekat pantai dan sebagian kecil ke timur (Alur Pelayaran Surabaya Barat). Distribusi klasifikasi pasir berlanau (*clayey sand*) mendominasi area saluran pelabuhan. Sebagian kecil dari daerah ini adalah lumpur (*silt*), dan sangat sedikit adalah lumpur berpasir (*sandy silt*).



Gambar 4.30 Hasil klasifikasi sedimen dasar laut dengan input batimetri dan selisih batimetri multifrekuensi

Tabel 4.3 menyajikan akurasi klasifikasi sedimen menggunakan matriks konfusi, yang digunakan untuk uji klasifikasi prediksi sedimen dasar laut. Matriks konfusi menyajikan kecocokan jumlah titik sampel dengan titik prediksi. Data pada Tabel 4.3 dapat digunakan untuk menghitung *Overall Accuracy* (OA), *Producer's Accuracy* (PA), *User's Accuracy* (UA), dan koefisien *Kappa*. OA menggambarkan proporsi yang dipetakan dengan benar dari semua lokasi referensi. OA sering dinyatakan sebagai persentase, dengan akurasi 100 menjadi tingkat klasifikasi sempurna di mana semua lokasi referensi telah diklasifikasikan dengan benar. Pada saat yang sama, PA adalah akurasi klasifikasi dari perspektif pembuat model prediksi. Sedangkan, UA adalah akurasi dari perspektif pengguna hasil klasifikasi.

Dalam kasus ini dimana batimetri dan selisih batimetri sebagai input model DNN, akurasi klasifikasi sedimen dasar laut yang dihasilkan adalah 41,9%. Landis dan Koch (1997) menganggap 0 - 0,20 (kecil / *slight*), 0,21 - 0,40 (cukup / *fair*), 0,41 - 0,60 (sedang / *moderate*), 0,61 - 0,80 (kuat / *substantial*), dan 0,81 - 1 (hampir sempurna / *almost perfect*). Dengan demikian, klasifikasi sedimen dalam hal ini termasuk dalam kategori sedang (0,41 – 0,60). Akurasi pengguna dan produsen untuk kelas tertentu seringkali berbeda. Dalam hal ini, PA untuk kelas lanau adalah 25,9%, sedangkan UA-nya adalah 46,7%. Ini berarti bahwa meskipun 25,9% dari area lumpur referensi telah diidentifikasi dengan benar sebagai lanau, hanya 47% dari area yang diidentifikasi sebagai lanau dalam klasifikasi adalah lanau.

Tabel 4.3 Matriks konfusi antara data in situ dan DNN dengan input batimetri dan selisih batimetri

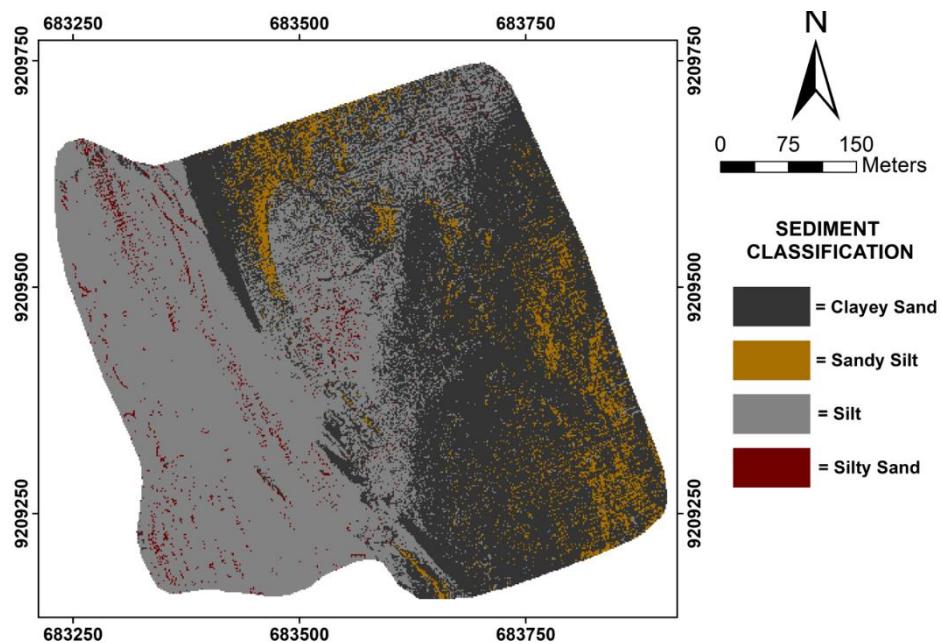
Classified Data	In situ Data				Total	UA
	Silt	Sandy Silt	Clayey Sand	Silty Sand		
<i>Silt</i>	7	1	4	3	15	46,7
<i>Sandy Silt</i>	0	1	0	0	1	100%
<i>Clayey Sand</i>	3	5	13	1	22	59,1%
<i>Silty Sand</i>	17	4	5	10	36	27,8%
Total	27	11	22	14	74	
PA	25,9%	9,1%	59,1%	71,4%		
<i>Overall Accuracy</i>	41,9%					
<i>Kappa Coeficient</i>	0,21					

Pengklasifikasi yang dibangun dan dievaluasi pada kumpulan data dari distribusi kelas yang berbeda dapat dibandingkan dengan lebih andal menggunakan statistik Kappa. Koefisien kappa dihasilkan dari uji statistik untuk mengevaluasi akurasi klasifikasi. Pada survei daerah ini, klasifikasi sedimen dasar laut memiliki kappa hanya 0,21. Menurut Landis dan Koch (1977), hasil ini termasuk dalam kategori *fair* (0,21 – 0,40).

#### 4.4.2.2 Klasifikasi Sedimen Dasar Laut dengan input Batimetri dan Fitur Batimetri Multifrekuensi

Hasil prediksi sebaran sedimen dasar laut di perairan GJT dengan menggunakan *deep neural network* dengan input batimetri dan fitur batimetri multifrekuensi dapat dilihat pada Gambar 4.31. Sedimen *silt* mendominasi hasil prediksi dengan sebaran di sebelah barat area survei dan sedikit menyebar ke tengah dan ke utara. *Clayey sand* menyebar di sebagian wilayah sebelah barat, bercampur dengan *sandy silt*. Sebagian kecil area bercampur dengan sedimen *silt* yaitu *silty sand* di area sebelah barat.

Akurasi dan koefisien Kappa prediksi sedimen dasar laut dengan metode DNN dan input batimetri dan fitur batimetri dapat dilihat matriks konfusi di Tabel 4.4. Nilai akurasi hasil prediksi ini adalah 59,6% dan koefisien kappa sebesar 0,40. Nilai akurasi ini lebih tinggi dibandingkan dengan hasil akurasi yang diperoleh dari input batimetri dan selisih batimetri. Ada peningkatan akurasi sebesar 17,7% dari 41,9% ke 59,6%. Dengan demikian fitur batimetri mempunyai peran penting dalam prediksi klasifikasi sedimen dasar laut.



Gambar 4.281 Hasil prediksi sebaran sedimen dasar dengan input batimetri dan fitur batimetri

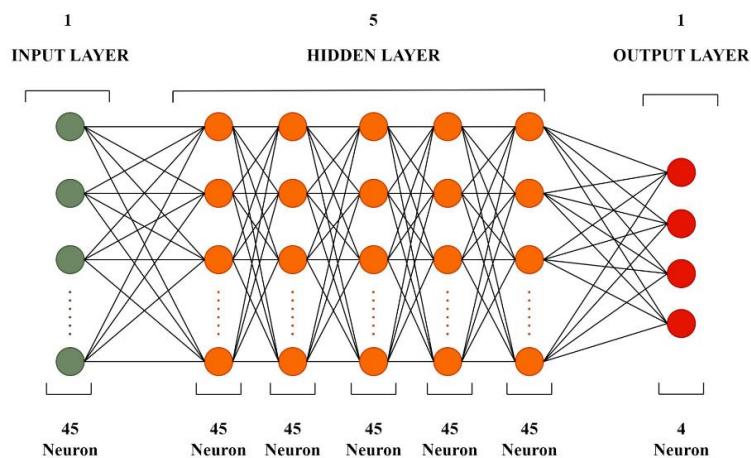
#### 4.4.2.3 Klasifikasi Sedimen Dasar Laut dengan input Batimetri, Selisih Batimetri dan Fitur Batimetri Multifrekuensi

Selanjutnya, klasifikasi sedimen dasar laut dengan input batimetri, selisih batimetri dan fitur batimetri multifrekuensi. Gambar 4.31 menunjukkan diagram *multi-layer perceptron* (MLP) dengan lima lapisan tersembunyi, yang digunakan dalam klasifikasi ini. Setiap lapisan tersembunyi terdiri dari empat puluh lima *neuron*. Fungsi aktivasi yang digunakan adalah *ReLU* untuk layer tersembunyi dan *softmax* untuk layer output. Algoritma nilai properti DNN, seperti bobot dan tingkat pembelajaran, memperkirakan estimasi momen adaptif. Beberapa eksperimen dan model menggunakan kumpulan data untuk melatih 70% populasi dan menguji 30%

untuk mencapai akurasi maksimum. Secara umum, model dengan fungsi aktivasi ReLu (lapisan tersembunyi) dan fungsi aktivasi *softmax* (lapisan *output*) mencapai akurasi pelatihan 98,39% dan akurasi pengujian 75%. Ini dihasilkan menggunakan pengaturan ukuran *batch* 1, pengaturan tingkat pembelajaran 0,0001, dan parameter output sebanyak 74 sampel sedimen dengan empat kelas tipe sedimen.

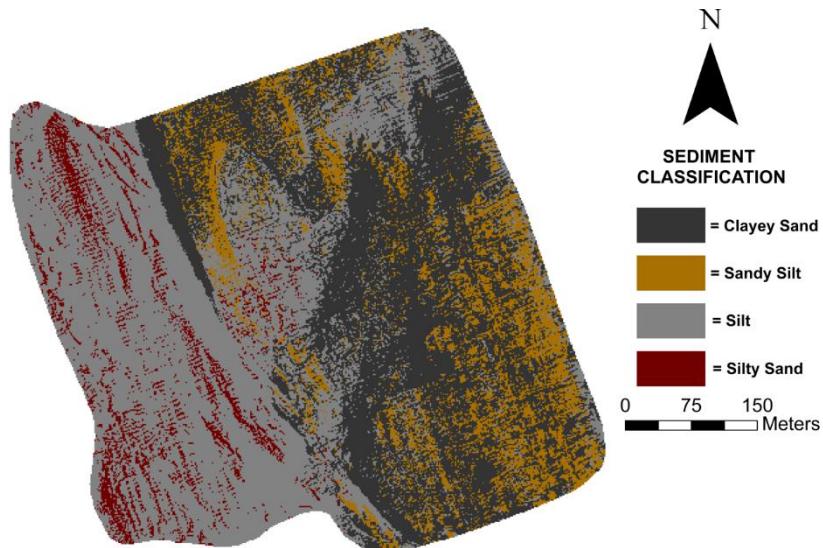
Tabel 4.4 Matriks konfusi prediksi sedimen dasar laut dengan metode DNN dan input batimetri dan fitur batimetri

		Reference (In Situ)					
		Clayey	Sandy	Silt	Silty	Jumlah	UA
		Sand	Silt	Sand	Sand		
Predicted	Clayey	15	6	2	0	23	65,2%
	Sand						
	Sandy Silt	1	3	0	1	5	60,0%
	Silt	6	2	25	12	45	55,6%
	Silty Sand	0	0	0	1	1	100%
Jumlah		22	11	27	14	74	
PA		68,2%	27,3%	92,6%	7,1%		
OA		59,6%					
Kappa		0,40					



Gambar 4.29 Deep Neural Network Model Classifier dengan 45 neuron

Hasil peta prediksi sedimen dasar laut di wilayah survei dengan menggunakan DNN dapat dilihat pada Gambar 4.33. Sedimen dasar laut di pelabuhan GJT didominasi oleh lumpur (*silt*) (41,6%), yang tersebar di sekitar kolam pelabuhan (wilayah barat), dan pasir berlanau (36,6%) dalam ukuran bagian timur (Alur Pelayaran Barat Surabaya). Sebagian kecil dari situs di sekitar pelabuhan dengan pasir berlumpur (7,5%) dan sedimen lumpur berpasir (14,2%) tersebar di sisi timur luar area survei.



Gambar 4.30 Prediksi sedimen dasar laut dengan DNN di area survei

Uji akurasi klasifikasi DNN dengan input batimetri, selisih batimetri dan fitur batimetri ditunjukkan dengan matriks konfusi di Tabel 4.5. Pada penelitian ini, nilai PA yang tinggi adalah kelas lanau (92,6%) dengan 25 jenis *Silt* (*in situ*) yang cocok dengan 27 sampel, sedangkan UA adalah *sandy silt* (100%), dengan hanya lima poin kelas prediksi yang cocok dengan kelas sampel *in-situ*. Akurasi pengguna dan produsen untuk kelas tertentu biasanya berbeda. Dalam hal ini, akurasi produsen untuk kelas *silt* adalah 92,6%, sedangkan akurasi pengguna adalah 64,1%. Ini berarti bahwa meskipun 92,6% dari area lumpur referensi telah diidentifikasi dengan benar sebagai *silt*, hanya 64,1% dari area yang diidentifikasi sebagai *silt* dalam klasifikasi adalah *silt*. Nilai akurasi keseluruhan dalam hal ini adalah 71,6%, dimana terdapat 53 sampel yang cocok untuk semua kelas dengan rincian *clayey sand* 17, *sandy silt* 5, *silt* 25, dan *silty sand* 6, dengan total sampel

74. Pada saat yang sama, nilai koefisien Kappa adalah 0,59. Nilai Kappa sebesar 0,59, menurut Landis dan Koch (1977), termasuk dalam kekuatan kesepakatan sebagai cukup, dan nilai akurasi keseluruhan sebesar 71,6% termasuk dalam kategori *substansial*. Nilai akurasi ini meningkat sebesar 12% dari 59,6% dengan data batimetri dan fitur batimetri ke 71,6% dengan data batimetri, selisih batimetri dan fitur batimetri. Jika dilihat dari input batimetri dan selisih batimetri, terjadi peningkatan akurasi sebesar 29,75 dari 41,9% ke 71,6%. Walaupun selisih batimetri tidak ada korelasi secara langsung dengan jenis sedimen, akan tetapi data selisih batimetri ikut meningkatkan akurasi sebesar 12%.

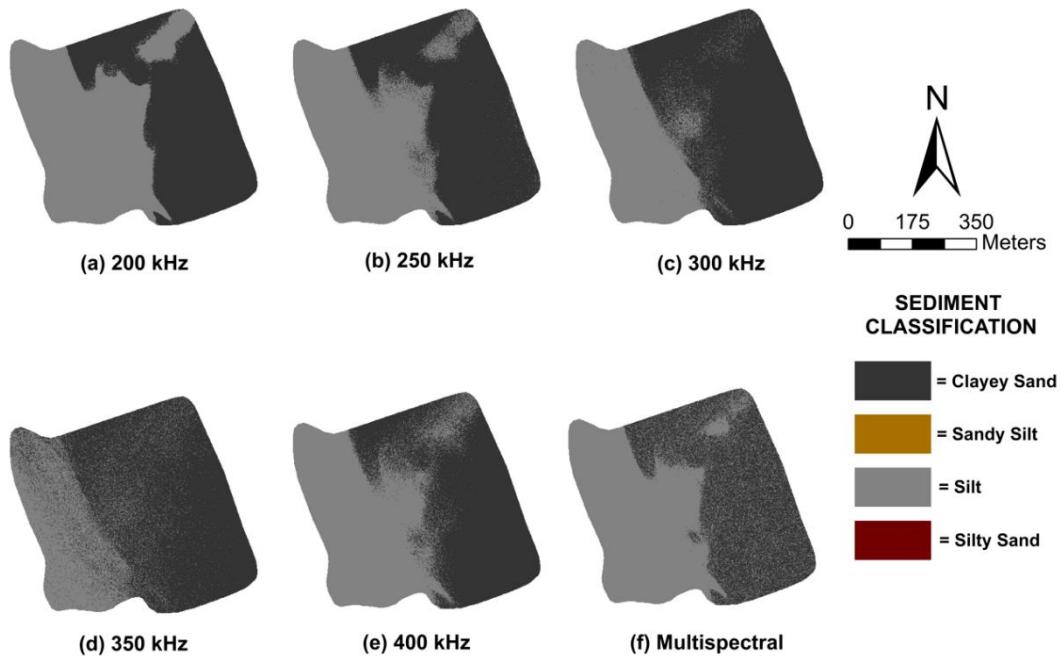
Tabel 4.5 Matriks konfusi klasifikasi sedimen dasar laut dengan DNN input batimetri, selisih batimetri dan fitur batimetri

		Referensi (In Situ)					
Prediksi	Jenis Sedimen	<i>Clayey sand</i>	<i>Sandy silt</i>	<i>Silt</i>	<i>Silty sand</i>	Jumlah	UA
	<i>Clayey sand</i>	17	3	1	1	22	77,3
	<i>Sandy silt</i>	0	5	0	0	5	100
	<i>Silt</i>	5	2	25	7	39	64,1
	<i>Silty sand</i>	0	1	1	6	8	75
	Jumlah	22	11	27	14	74	
	PA	77,3	45,4	92,6	42,9		
	OA	71,6%					
	Kappa	0,59					

#### 4.4.2.4 Klasifikasi Sedimen Dasar Laut dengan input Batimetri, *Backscatter Monospektral* dan *Backscatter Multispectral*

Hasil klasifikasi sedimen dasar laut dengan metode DNN dengan input batimetri, *backscatter* untuk setiap frekuensi dan *backscatter* multispektral dapat dilihat pada Gambar 4.34. Frekuensi 200 kHz, 300 kHz, 350 kHz, dan 400 kHz, ada dua jenis sedimen yang diklasifikasikan: *clayey sand* dan *silt*, sedangkan frekuensi 250 kHz memiliki 3 klasifikasi: *silt*, *sandy silt*, dan *clayey sand*. Wilayah barat dekat

pelabuhan didominasi oleh sedimen *silt* kecuali frekuensi 250 kHz, yang didominasi oleh *sandy silt*. Sementara itu, wilayah timur didominasi oleh jenis



sedimen *clayey sand*. Untuk *backscatter* multispektral, hanya 2 jenis sedimen yang diklasifikasikan, yaitu *sandy silt* dan *silt*, yang memiliki proporsi hampir sama.

Gambar 4.31 Klasifikasi sedimen dasar laut menggunakan DNN untuk setiap frekuensi (a-e) dan multifrekuensi dengan input batimetri dan *backscatter*

Hasil klasifikasi sedimen dasar laut pada Gambar 4.34 kemudian diuji akurasinya dengan menggunakan matriks konfusi (Tabel 4.5 - Tabel 4.11). Berdasarkan Tabel 4.6 - Tabel 4.12, nilai akurasi keseluruhan untuk setiap frekuensi dan multispektral memiliki nilai antara 51,4% untuk multispektral dan 59,5% untuk frekuensi 300 kHz dan koefisien kappa dari 0,26 untuk multispektral hingga 0,39 untuk frekuensi 300 kHz. Namun, kategori untuk semua frekuensi adalah sedang. Dengan kata lain, klasifikasi untuk setiap frekuensi dan frekuensi multispektral menghasilkan kelas klasifikasi dengan akurasi yang relatif sama. Nilai akurasi ini tidak berbeda dengan akurasi yang diperoleh dengan metode ARC yaitu 51%. Penggunaan data *backscatter* frekuensi 300 kHz yang akurasinya naik 8,5% jika dibandingkan dengan ARA dan multispektral. Penggunaan data *backscatter*

multispektral dengan DNN hanya menaikkan akurasi 0,4% dibandingkan dengan metode ARA. Artinya akurasi antara klasifikasi backscatter multitemporal dengan metode ARA maupun dengan metode DNN relatif sama satu sama lain.

Tabel 4.6 Matriks konfusi klasifikasi sedimen dasar laut dengan DNN input batimetri dan *backscatter* 200 kHz

		Reference (In Situ)					
Predicted		Clayey	Sandy	Silt	Silty	Total	UA
		Sand	Silt	Sand	Sand		
Clayey Sand	Clayey	14	7	2	1	24	58,3%
	Sandy Silt	0	0	0	0	0	0
	Silt	8	4	25	13	50	50,0%
	Silty Sand	0	0	0	0	0	0
Sum		22	11	27	14	74	
PA		63,6%	0	92,6%	0		
OA		52,7%					
Kappa		0,28					

Tabel 4.7 Matriks konfusi klasifikasi sedimen dasar laut dengan DNN input batimetri dan *backscatter* 250 kHz

		Reference (In Situ)					
Predicted		Clayey	Sandy	Silt	Silty	Sum	UA
		Sand	Silt	Sand	Sand		
Clayey Sand	Clayey	14	7	2	1	24	58,3%
	Sandy Silt	0	0	0	0	0	0
	Silt	8	4	25	13	50	50,0%
	Silty Sand	0	0	0	0	0	0
Sum		22	11	27	14	74	
PA		63,6%	0	92,6%	0		
OA		52,7%					
Kappa		0,28					

Tabel 4.8 Matriks konfusi klasifikasi sedimen dasar laut dengan DNN input batimetri dan *backscatter* 300 kHz

		Reference (In Situ)					
Predicted		Clayey	Sandy	Silt	Silty	Sum	UA
		Sand	Silt	Sand			
Predicted	Clayey	20	8	3		1	32 62,5%
	Sand						
	Sandy Silt	0	0	0	0	0	0
	Silt	2	3	24	13	42	57,1%
	Silty Sand	0	0	0	0	0	0
Sum		22	11	27	14	74	
PA		90,9%	0	88,9%		0	
OA		59,5%					
Kappa		0,39					

Tabel 4.9 Matriks konfusi klasifikasi sedimen dasar laut dengan DNN input batimetri dan *backscatter* 350 kHz

		Reference (In Situ)					
Predicted		Clayey	Sandy	Silt	Silty	Sum	UA
		Sand	Silt	Sand			
Predicted	Clayey	19	8	3		4	34 55,9%
	Sand						
	Sandy Silt	0	0	1	0	1	0
	Silt	3	3	23	10	39	59,0%
	Silty Sand	0	0	0	0	0	0
Sum		22	11	27	14	74	
PA		86,4%	0	85,2%		71,4%	
OA		56,8%					
Kappa		0,35					

Tabel 4.10 Matriks konfusi klasifikasi sedimen dasar laut dengan DNN input batimetri dan *backscatter* 400 kHz

		Reference (In Situ)				
Predicted	Clayey	Sandy	Silt	Silty	Sum	UA
	Sand	Sand				
	Clayey	14	7	2	1	24 58,3%
	Sand					
	Sandy Silt	0	0	0	0	0
	Silt	8	4	25	13	50 50,0%
	Silty Sand	0	0	0	0	0
	Sum	32	11	27	14	74
	PA	43,8%	0	92,6%	0	
OA	52,7%					
Kappa	0,28					

Tabel 4.11 Matriks konfusi klasifikasi sedimen dasar laut dengan DNN input batimetri dan *backscatter* multispektral (semua frekuensi)

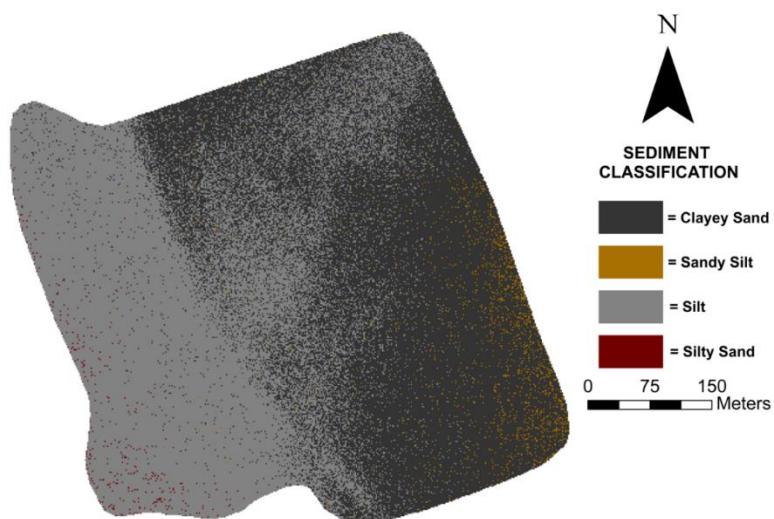
		Reference (In Situ)				
Predicted	Clayey	Sandy	Silt	Silty	Sum	UA
	Sand	Sand				
	Clayey	13	6	2	0	21 61,9%
	Sand					
	Sandy Silt	0	0	0	0	0
	Silt	9	5	25	14	53 4,2%
	Silty Sand	0	0	0	0	0
	Sum	22	11	27	14	74
	PA	59,1%	0	92,6%	0	
OA	51,4%					
Kappa	0,26					

Tabel 4.12 Ringkasan akurasi dan koefisien Kappa klasifikasi sedimen dengan input batimetri dan *backscatter* monospektral dan multispektral

No	Frequency	OA	Koefisien Kappa	Kategori
1	200 kHz	52,7%	0,28	Moderate
2	250 kHz	52,7%	0,28	Moderate
3	300 kHz	59,5%	0,39	Moderate
4	350 kHz	56,8%	0,35	Moderate
5	400 kHz	52,7%	0,28	Moderate
6	Multispectral (semua frekuensi)	51,4%	0,26	Moderate

#### 4.4.2.5 Klasifikasi Sedimen Dasar Laut dengan input Batimetri, *Backscatter*, dan Fitur *Backscatter* Multispektral

Gambar 4.35 menunjukkan hasil klasifikasi sedimen dasar perairan dengan menggunakan metode DNN dengan input batimetri, *backscatter* dan fitur *backscatter* multispektral. Hasil klasifikasi didominasi oleh kelas *silt* (48,6 %) dan *clayey sand* (45,7 %). Kelas *silt* mendominasi di area sebelah barat dan kelas *clayey sand* mendominasi area tengah ke timur. Hanya 4,6 % untuk kelas sedimen *sandy silt* dan 1,1 % untuk sedimen *silty sand*.



Gambar 4.32 Klasifikasi sedimen dengan input batimetri, *backscatter*, dan fitur *backscatter* multispektral

Uji akurasi dengan matriks konfusi (Tabel 4.13) menunjukkan nilai akurasi hasil klasifikasi dengan input batimetri, *backscatter* dan fitur *backscatter* multispektral adalah 52,7 % dan koefisien kappa sebesar 0,28. Nilai akurasi ini hanya naik 1,7 % dari nilai akurasi ARC, artinya fitur *backscatter* multispektral tidak signifikan untuk meningkatkan akurasi klasifikasi sedimen dasar laut.

Tabel 4.13 Ringkasan akurasi dan koefisien Kappa klasifikasi sedimen dengan input batimetri dan *backscatter* monospektral dan multispektral

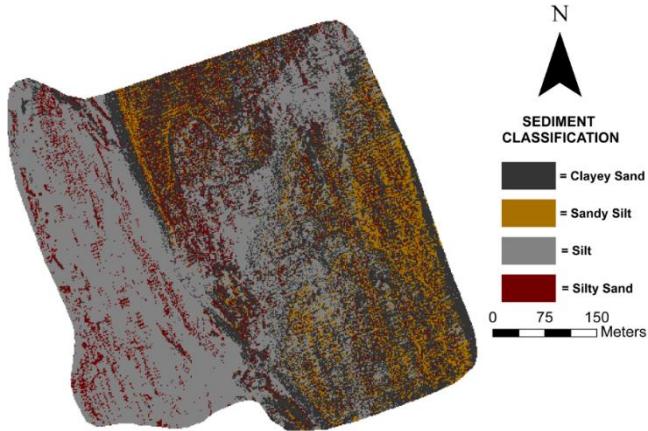
		Reference (In Situ)					
		Clayey sand	Sandy silt	Silt	Silty sand	Jumlah	UA
Predicted	<i>Clayey sand</i>	14	9	2	1	26	53,8%
	<i>Sandy silt</i>	0	0	0	0	0	0
	<i>Silt</i>	8	2	25	13	48	52,1%
	<i>Silty sand</i>	0	0	0	0	0	0
Sum		22	11	27	14	74	
PA		63,6%	0	92,6	0		
OA		52,7%					
Kappa		0,28					

#### 4.4.2.6 Klasifikasi Sedimen Dasar Laut dengan input Batimetri, Selisih Batimetri, Fitur Batimetri, *Backscatter* Multispectral, Fitur *Backscatter*

Hasil klasifikasi sedimen dasar laut di perairan GJT dengan metode DNN dengan input batimetri, selisih batimetri, fitur batimetri, *backscatter*, fitur *backscatter* multispektral dapat dilihat pada Gambar 4.36. Sedimen *silt* (46,4%) dan *clayey sand* (33,9%) mendominasi area sedimen dasar laut, diikuti oleh *sandy silt* (9,9%) dan *silt* (9,8%).

Hasil klasifikasi sedimen pada Gambar 4.35 kemudian diuji akurasinya menggunakan matriks konfusi. Akurasi dan koefisien Kappa dapat ditentukan berdasarkan Tabel 4.14, nilai akurasi keseluruhan adalah 62,2%, dan Kappa adalah 0,45. Nilai akurasinya naik sekitar 9,5% dari klasifikasi ARA, artinya selisih batimetri dan fitur batimetri ikut berperan dalam menaikkan akurasi dari 52,7% ke

62,2%. Akan tetapi nilai akurasi ini lebih kecil dibandingkan dengan input batimetri, selisih batimetri dan fitur batimetri yang mempunyai nilai overall accuracy sebesar 71,9%, artinya nilai ini turun sebesar 9,7%. Artinya input selisih batimetri dan fitur batimetri akan meningkatkan akurasi (dari 51% ke 62,2%) dan input *bakscatter* dan fitur *backscatter* akan menurunkan akurasi (dari 71,9 % ke 62,2%).



Gambar 4.33 Klasifikasi sedimen dengan input batimetri, selisih batimetri, fitur batimetri multifrekuensi, *backscatter*, dan fitur *backscatter* multispektral

Tabel 4.14 Matriks Konfusi Klasifikasi Sedimen dengan input batimetri, selisih batimetri, fitur batimetri multifrekuensi, *backscatter*, dan fitur *backscatter* multispektral

		Reference (In Situ)					
		Clayey sand	Sandy silt	Silt	Silty sand	Jumlah	UA
Predicted	Clayey sand	14	3	2	0	19	73,7%
	Sandy silt	1	3	0	0	4	75,0%
	Silt	6	2	25	10	43	23,3%
	Silty sand	1	3	0	4	8	50,0%
Sum		22	11	27	14	74	
PA		63,6%	27,3%	92,6	28,5%		
OA		62,2%					
Kappa		0.45					

#### **4.5 Analisa Peningkatan Akurasi Klasifikasi Sedimen Dasar Laut**

Peningkatan akurasi hasil prediksi sedimen dasar laut yang ditunjukkan dengan nilai akurasi dan koefisien Kappa dengan input data yang berbeda disajikan dalam Tabel 4.15. Peningkatan akurasi hasil prediksi ini mengacu pada hasil klasifikasi dengan metode *Angular Response Curve*. Metode ARC yang saat ini digunakan di hampir semua *software* komersil seperti Qinsy, Hypack, Eiva dan lainnya. Metode ARC memanfaatkan data *backscatter* sebagai input untuk memprediksi sebaran sedimen berdasarkan nilai intensitas, sudut datang dan frekuensi gelombang suara yang digunakan. Pada kasus penelitian ini, prediksi sedimen dasar di perairan GJT dengan metode ARC yang diuji dengan 74 jenis data sedimen *in situ* mempunyai akurasi 51% dan koefisien kappa 0,37.

Selanjutnya, metode DNN digunakan untuk memprediksi sebaran sedimen dasar di perairan yang sama dengan mengubah-ubah input parameter yaitu batimetri dan *backscatter* MBES multifrekuensi. Yang pertama adalah metode DNN dengan input batimetri dan selisih batimetri. Nilai akurasi prediksi dengan input data ini jika dibandingkan dengan metode ARC turun 9,9%, dari 51% ke 41,9% dan koefisien kappa turun 0,16 dari 0,37 ke 0,21. Batimetri dan fitur batimetri multifrekuensi sebagai input DNN menghasilkan akurasi sebesar 59,6%. Nilai akurasi ini naik sebesar 8,6% dari akurasi ARA 51%. Koefisien kappa dengan input data ini mempunyai nilai sebesar 0,40 yang naik 0,03 dengan nilai kappa ARA (0,37). Metode DNN dengan input batimetri, selisih batimetri dan fitur batimetri menghasilkan nilai akurasi sebesar 71,9%. Nilai akurasi ini lebih tinggi 20,9% dari ARA yang hanya 51% dan lebih tinggi 12,3% dari input batimetri dan fitur batimetri (59,6%). Sedangkan nilai koefisien kappa naik 0,22 dari ARA dan 0,19 dari input batimetri dan fitur batimetri. Dari data akurasi ini, input selisih batimetri walaupun pada saat digabung dengan batimetri menghasilkan nilai akurasi yang lebih rendah dari ARA, akan tetapi data selisih batimetri pada saat digabung dengan batimetri dan fitur batimetri, akurasi meningkat dari 59,6 (batimetri dan fitur batimetri) ke 71,9% (batimetri, selisih batimetri dan fitur batimetri).

Penggunaan batimetri dan data *backscatter* untuk masing-masing frekuensi sebagai input DNN menghasilkan prediksi sedimen dasar laut dengan akurasi 52,7% (200 kHz, 250 kHz dan 400 kHz), 59,5% (300 kHz), 56,8% (350

kHz) dan 51,4 % (multispektral). Penggunaan data *backscatter* multispektral menghasilkan nilai akurasi yang hampir sama dengan metode ARC, bahkan nilai koefisien kappa turun 1,1. Penggunaan *backscatter* frekuensi 300 kHz mempunyai nilai akurasi paling tinggi yaitu 59,5% (naik 8,5% dari ARA) dan frekuensi 350 kHz dengan akurasi 56,8% (naik 5,8% dari ARA). Akan tetapi nilai koefisien kappa lebih kecil dari ARA kecuali frekuensi 300 kHz yang naik hanya 0,2. Data batimetri, *backscatter* dan fitur *backscatter* multispektral sebagai input data DNN untuk klasifikasi sedimen dasar laut menghasilkan akurasi 52,7% dan koefisien kappa 0,28. Nilai akurasi ini naik sedikit dari ARA yaitu 1,7%, akan tetapi koefisien kappa turun 0,9. Penggunaan data *backscatter* dan fitur *backscatter* multispektral tidak meningkatkan akurasi dibandingkan dengan penggunaan *backscatter* pada metode ARA, kecuali pada frekuensi 300 kHz yang naik 8,5% yaitu dari 51% ke 59,5%.

Yang terakhir adalah penggabungan data batimetri, selisih batimetri, fitur batimetri multifrekensi, *backscatter* dan fitur *backscatter* multispektral sebagai input DNN untuk prediksi sedimen dasar laut di perairan GJT. Uji akurasi dengan input semua data menghasilkan akurasi 62,2% yang naik 11,2% dari akurasi yang diperoleh dari metode ARC, akan tetapi nilai koefisien kappa turun 0,9 dari metode ARC. Nilai akurasi dan koefisien dari semua data ini lebih rendah dari input data batimetri, selisih batimetri dan fitur batimetri yang mempunyai akurasi 71,9% dan koefisien kappa sebesar 0,59. Artinya nilai batimetri, selisih batimetri dan fitur batimetri menaikkan nilai akurasi dari data *backscatter* dan fitur *backscatter* (52,7% ke 62,2%) dan sebaliknya data *backscatter* dan fitur *backscatter* menurunkan akurasi (dari 71,9% ke 62,2%).

Tabel 4.15 Peningkatan akurasi dan koefisien *Kappa* dengan input data yang berbeda

No	Metode	Input Data	<i>Overall Accuracy (%)</i>	Koefisien Kappa	
1	ARC	<i>backscatter</i>	51,0	<i>baseline</i>	0,37
2	DNN	batimetri dan selisih batimetri	41,9	- 9,9%	0,21
3	DNN	batimetri dan fitur batimetri	59,6	+8,6%	0,40
4	DNN	batimetri, selisih batimetri dan fitur batimetri	71,9	+20,9%	0,59
5	DNN	Batimetri dan <i>Backscatter</i> 200 kHz	52,7	+1,7%	0,28
6	DNN	Batimetri dan <i>Backscatter</i> 250 kHz	52,7	+1,7%	0,28
7	DNN	batimetri dan <i>backscatter</i> 300 kHz	59,5	+8,5%	0,39
8	DNN	batimetri dan <i>backscatter</i> 350 kHz	56,8	+5,8%	0,35
9	DNN	batimetri dan <i>backscatter</i> 400 kHz	52,7	+1,7	0,28
10	DNN	batimetri dan <i>backscatter</i> multispektral	51,4	+0,4	0,26
11	DNN	batimetri, <i>backscatter</i> dan fitur <i>backscatter</i> multispektral	52,7	+1,7	0,28
12	DNN	batimetri, selisih batimetri, fitur batimetri multifrekuensi, <i>backscatter</i> , fitur <i>backscatter</i> multispektral	62,2	+11,2	0,28

Catatan: tanda + menunjukkan terjadi peningkatan nilai dari *baseline* dan tanda minus menunjukkan penurunan nilai dari *baseline*

Hasil ini sesuai dengan hipotesa awal bahwa penggunaan data MBES multifrekuensi yaitu selisih batimetri dan *backscatter* multispektral akan meningkatkan hasil klasifikasi sedimen dasar laut. Walaupun penggunaan data selisih batimetri dan *bakscatter* multispektral meningkatkan nilai *overall accuracy* sebesar 11,2% dari baseline yaitu dari 51% ke 62,2%, akan tetapi nilai koefisien kappa turun sebesar 0,09. Selain itu peningkatan akurasi ini lebih kecil dibandingkan dengan penggunaan selisih batimetri dan fitur batimetri, dimana akurasinya naik sebesar 20,9% dan koefisien kappa naik +0,22. Hasil penelitian ini menunjukkan bahwa klasifikasi sedimen dengan data batimetri, selisih batimetri dan fitur batimetri multifrekuensi lebih tinggi dibandingkan dengan penggunaan data backscatter dan fitur backscatter multitemporal.

#### **4.6 Analisa Peningkatan Akurasi dengan Peneliti Sebelumnya**

Zhi dkk. (2014) telah melakukan penelitian dengan data MBES *backscatter* dan batimetri untuk memprediksi pemetaan sedimen dasar di lahan kontinen Carnarvon, Australia bagian barat. MBES yang digunakan adalah Kongsberg EM 3002 dengan frekuensi 300 kHz. Area penelitian seluas 281 km<sup>2</sup> dengan variasi kedalaman dari 6 sampai dengan 200 m. Jumlah titik sampel in situ yang digunakan sebanyak 89 sampel sedimen yang digunakan untuk *training* dan validasi. Zhi dkk. melakukan kombinasi data batimetri dan *backscatter* sebagai input untuk metode yang digunakan yaitu *Random Forest Decision Tree* (RFDT). Hasil penelitian Zhi dkk menunjukkan bahwa terjadi peningkatan koefisien determinasi ( $R^2$ ) untuk *gravel* dari 0,42 (ARC *backscatter*) ke 0,55 (batimetri dan ARC *backscatter*), *sand* dari 0,45 (ARC *backscatter*) ke 0,58 dan *mud* 0,37 (*backscatter* ARC) ke 0,73 (batimetri, fitur batimetri, *bakscatter* dan *fitur backscatter*). *Baseline* peningkatan ini adalah akurasi yang diperoleh dari *backscatter* dengan metode ARC.

Xu dkk. (2021) menggunakan data batimetri dan *backscatter single* frekuensi (300 kHz) sebagai input *machine learning Random Forest Decision Tree* (RFDT) untuk memprediksi *mean grain size* dan tipe sedimen. Sebanyak 132 titik sampel in situ yang digunakan sebagai *training* dan validasi yang diklasifikasikan ke dalam tujuh kelas yaitu *sandy Gravel* (sG), *muddy sandy Gravel* (msG), *gravelly*

*Sand* (gS), *gravelly muddy Sand* (gmS), *Sand* (S), *muddy Sand* (mS) dan *sandy Mud* (sM). Sampel ini dibagi kedalam empat area, dengan sampel masing-masing area yaitu area BP\_A sebanyak 54 sampel (luas area  $\pm 900 \text{ km}^2$ ), area BP\_B sebanyak 18 sampel (luas area  $\pm 400 \text{ km}^2$ , BP\_C sebanyak 23 sampel (luas area  $\pm 300 \text{ km}^2$ ), dan area BP\_D sebanyak 37 sampel (luas area  $\pm 255 \text{ km}^2$ ). Kedalaman area survei BP\_A adalah 24 – 174 m, BP\_B adalah 7 – 116 m, BP\_C adalah 37 – 57 m dan BP\_D adalah 37 – 57 m. Hasil dari penelitian Xu dkk. (2021) menunjukkan bahwa terjadi peningkatan akurasi prediksi jenis sedimen mengalami peningkatan akurasi dari 35,18% (*backscatter*) ke 79,63% (*backscatter*, batimetri dan fitur batimetri), naik 44,45 %. Sedangkan koefisien kappa meningkat dari 0,15 (*backscatter*) menjadi 0,70, naik 0,55 (*backscatter*, batimetri dan fitur batimetri).

Hasil penelitian kedua peneliti diatas Zhi dkk. (2014) dan Xu dkk. (2021) menggunakan data MBES *single* frekuensi 300 kHz hampir sama dengan hasil penelitian ini yang menggunakan MBES multifrekuenyi (200 kHz, 250 kHz, 300 kHz, 350 kHz, 400 kHz). Secara umum perbedaan penelitian ini dengan peneliti sebelumnya dapat dilihat pada Tabel 4.16. *Baseline* akurasi yang digunakan untuk peningkatan akurasi adalah penggunaan data *backscatter* dengan metode ARC. Penelitian ini menggunakan *baseline* akurasi sebesar 51% sedangkan Zhi dkk sebesar 42% dan 35% untuk Xu dkk (2021). Peningkatan akurasi tertinggi sebesar 44,45% oleh Xu dkk (2021) dengan penggunaan data batimetri, *backscatter* dan fitur *backscatter*. Penelitian ini hanya menghasilkan peningkatan akurasi sebesar 20,9% dari akurasi *baseline*, akan tetapi peningkatan akurasi ini diperoleh dengan penggunaan data batimetri, selisih batimetri dan fitur batimetri. Penggunaan data *backscatter* monospektral dan multispektral di kasus penelitian ini tidak meningkatkan akurasi dari *baseline* kecuali penggunaan batimetri dan *backscatter* monospektral frekuensi 300 kHz yang naik 8,5% dan frekuensi 350 kHz yang naik 5,8%.

Terjadinya perbedaan peningkatan akurasi hasil prediksi disebabkan oleh kedalaman area survei, frekuensi yang digunakan, jenis sedimen dan jumlah sampel *in situ* yang digunakan untuk uji akurasi. Semakin dalam area survei akan berpengaruh pada intensitas *backscatter* yang diterima kembali oleh *receiver*. Kedalaman laut penelitian ini di laut yang sangat dangkal (*very shallow water*) yaitu

2 – 25 m, Zhi dkk (2014) kedalaman 6 – 200 dan Xu dkk. (2021) kedalaman 7 – 116 m. Frekuensi MBES yang digunakan survei juga berpengaruh pada hasil batimetri dan *backscatter* yang diterima oleh *receiver*. Zhi dkk dan Xu dkk menggunakan MBES *single* frekuensi dengan frekuensi yang sama yaitu 300 kHz, sedangkan penelitian ini menggunakan MBES multifrekuensi dengan frekuensi 200 kHz, 250 kHz, 300 kHz, 350 kHz dan 400 kHz.

Tabel 4.16 Ringkasan perbedaan penelitian ini dengan peneliti sebelumnya

No	Jenis	Peneliti		
		Zhi dkk (2014)	Xu dkk (2021)	Penelitian ini (2024)
1	MBES	300 kHz	300 kHz	Multifrekuensi (200 kHz, 250 kHz, 300 kHz, 350 kHz, 400 kHz)
2	Kedalaman	6 – 200 m	7 – 116	2 – 25 m
3	Metode (Machine Learning)	RFDT	RFDT	DNN
4	Jenis Sedimen	<i>muddy Sand (mS), Sand (S), gravelly muddy Sand (gmS), gravelly Sand (gS), muddy sandy Gravel (msG), sandy Gravel (sG)</i>	<i>muddy Sand (mS), Sand (S), gravelly muddy Sand (gmS), gravelly Sand (gS), muddy sandy Gravel (msG), sandy Gravel (sG), Rock</i>	<i>clayey sand, silty sand, Silt, sandy silt</i>
5	Jumlah sampel	89	132	74
6	Kerapatan sampel	3 km <sup>2</sup> / titik	6 km <sup>2</sup> / titik	0,3 ha / titik
7	Baseline akurasi (ARC)	42	35,18	51
8	Akurasi tertinggi	73	79,63	71,9
9	Peningkatan akurasi	31	44,45	20,9

Jenis sedimen dasar laut juga akan berpengaruh pada data batimetri dan intensitas *backscatter*, semakin keras sedimen maka semakin tinggi intensitasnya dan sebaliknya, semakin lunak sedimennya maka semakin rendah intensitas *backscatter*nya. Jenis sedimen penelitian ini adalah sedimen lunak yaitu *clayey sand*, *silty sand*, *Silt* dan *sandy silt*, sedangkan jenis sedimen dalam penelitian Zhi dkk. dan Xu dkk adalah sedimen keras yaitu *muddy Sand (mS)*, *Sand (S)*, *gravelly muddy Sand (gmS)*, *gravelly Sand (gS)*, *muddy sandy Gravel (msG)*, *sandy Gravel (sG)*. Jumlah sampel *in situ* akan berpengaruh pada hitungan akurasi matriks konfusi. Kerapatan sampel sedimen *in situ* dalam penelitian Zhi dkk adalah 3 km<sup>2</sup> / titik, Xu dkk 6 km<sup>2</sup> / titik dan penelitian ini adalah 0,3 ha / titik. Semakin banyak sampel sedimen in situ dan dengan distribusi merata di area survei akan menghasilkan akurasi yang merepresentasikan kebenaran prediksi sesuai dengan data lapangan yang sebenarnya.

## **BAB 5**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan data, pengolahan data dan analisa data MBES multifrekuensi maka ada beberapa hal yang dapat ditarik kesimpulan dari penelitian ini yaitu:

1. Selisih kedalaman antar frekuensi dari data MBES multifrekuensi, antara frekuensi 200 kHz dengan frekuensi lainnya (250 kHz, 300 kHz, 350 kHz, dan 400 kHz) didominasi oleh 0 – 10 cm. Sedangkan selisih batimetri antara frekuensi 300 kHz dengan frekuensi 350 kHz dan 400 kHz yaitu didominasi 10 – 20 cm.
2. Klasifikasi sedimen dasar laut dengan metode DNN dan input data *bakscatter* multispektral dari MBES multifrekuensi mempunyai akurasi yang hampir sama dengan metode ARA yaitu sebesar 51% dan koefisien kappa 0,37. Data *backscatter* monospektral dengan frekuensi 300 kHz mempunyai akurasi lebih tinggi dibandingkan dengan multispektral yaitu 59,5% dan nilai *kappa* 0,39.
3. Klasifikasi sedimen dasar laut dengan metode DNN dan kombinasi data batimetri, selisih batimetri dan fitur batimetri multifrekuensi mempunyai akurasi (71,9%) yang lebih tinggi dibandingkan dengan data batimetri, backscatter dan fitur *backscatter* multispektral (52,7%) dan kombinasi data batimetri, selisih batimetri, fitur batimetri multifrekuensi, backscatter dan fitur *backscatter* multispektral (62,2%).

#### **5.2 Saran**

Penelitian ini menggunakan MBES multifrekuensi untuk keperluan klasifikasi sedimen dasar laut di daerah pesisir (pantai) dengan kedalaman kurang dari 25 m (perairan sangat dangkal). Walaupun hasil penelitian menunjukkan bahwa terjadi peningkatan akurasi sebesar 20,6% dibandingkan dengan akurasi klasifikasi ARA, untuk peningkatan akurasi yang lebih tinggi lagi maka disarankan untuk penelitian ke depan sebagai berikut:

- a. Area penelitian memiliki jenis sedimen yang bervariasi dari jenis keras (*boulder*, *gravel*), sedang (*sand*) dan lunak (*silt*, *clay*), sehingga area penelitian mewakili variasi *hardness* permukaan dasar permukaan.
- b. Area penelitian memiliki variasi topografi (tingkat kelerengan) yang menyebar merata di area survei, sehingga mempunyai nilai *roughness* yang berbeda yang menyebar di area survei.
- c. Jumlah titik sampel mempunyai kerapatan yang tinggi dan menyebar merata di area survei, sehingga uji akurasi yang dihasilkan bisa mewakili kondisi sebenarnya.
- d. Input parameter untuk model yang digunakan lebih detil lagi untuk melihat korelasi hasil korelasi klasifikasi dengan masing-masing input parameternya.

## DAFTAR PUSTAKA

- Anderson, J.T., Holliday, D.V., Kloser, R., Reid, D.G., and Simard, Y. (2008). Acoustic seabed classification: current practice and future directions. *CES Journal of Marine Science*, Volume 65, Issue 6, September 2008, Pages 1004–1011,
- APL-UW. (1994). High-Frequency Ocean Environmental Acoustic Models Handbook (APL-UW TR 9407). Seattle, WA: Applied Physics Laboratory, University of Washington.
- Arif, N. (2011). Kajian Kemampuan Jaringan Syaraf Tiruan Berbasis Citra ALOS Dalam Identifikasi Lahan Kritis, Tesis Fakultas Geografi, Universitas Gadjah Mada
- Atallah, L., Probert Smith, P. J., & Bates, C. R. (2002). Wavelet analysis of bathymetric sidescan sonar data for the classification of seafloor sediments in Hopvågen Bay - Norway. *Marine Geophysical Researches*, 23(5/6), 431–442. doi:10.1023/b:mari.0000018239.0756
- Barnhardt, W.A., Kelley, J.T., Dickson, S.M. and Belknap, D.F. (1998) Mapping the Gulf of Maine with side-scan sonar: a new bottom-type classification for complex seafloors: *Journal of Coastal Research*, v. 14, p. 646-659
- Berthold, T., Leichter, A., Rosenhahn, B., Berkahn, V., & Valerius, J. (2017). Seabed sediment classification of side-scan sonar data using convolutional neural networks. 2017 IEEE Symposium Series on Computational Intelligence (SSCI).
- Bosse, S., Maniry, D., and Müller, K.R. (2017). Deep neural networks for no-reference and full-reference image quality assessment. *IEEE Trans. Image Process.* 27, 206–219. pp. 206 -219
- Boulay, S.O.C. (2012). Analysis of Multibeam Sonar Data for Benthic Habitat Characterization of the Port of Tauranga, New Zealand. Thesis. The University of Waikato. doi.org/10.13140/RG.2.1.4805.5528

- Brennan, C.W. (2017). *Multibeam Calibration: The Patch Test*. R2Sonic LLC Multibeam Training – The Patch Test.
- Brissette, M. B., Clarke, J. E. H. (1999). Sidescan versus multibeam echosounder object detection a comparative analysis. Ocean Mapping Group, University of New Brunswick,
- Brown, C.J., Beaudoin, J., Brissette, M., Gazzola, V. (2017) Setting the Stage for Multispectral Acoustic Backscatter Research. WHITE PAPER. R2Sonic. doi.org/10.4095/305838
- Brown, C.J., Beaudoin, J., Brissette, M., Gazzola, V. (2019) Multispectral Multibeam Echo Sounder Backscatter as a Tool for Improved Seafloor Characterization. Geosciences. MDPI. doi.org/10.3390/geosciences9030126
- Brown, C.J., Blondel, P. (2009). Developments in the Application of Multibeam Sonar Backscatter for Seafloor Habitat Mapping. Applied Acoustics. 1242–1247
- Brown, C.J., Varma, H. (2018). Multispectral Seafloor Classification: Applying A Multidimensional Hypercube Approach to Unsupervised Seafloor Segmentation.
- Burns, D., Chivers, R.C. and Sisk, H. (1989). Analysis of Echosounder Signals for Seabed classification. in Ultrasonics International - Institute of Acoustics. pp. 423–429.
- Buscombe, D., Grams, P.E. (2018). Probabilistic Substrate Classification with Multispectral Acoustic Backscatter: A Comparison of Discriminative and Generative Models. Geosciences 2018, 8, 395; doi:10.3390/geosciences8110395
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The Matthews correlation coefficient (MCC) is more informative than Cohen's Kappa and Brier score in binary classification assessment. *IEEE Access*.
- Chin, W. W. (1998). The Partial Least Squares Aproach to Structural Equation Modeling. Modern Methods for Business Research, 295, 336

- Clarke, J. E. H. (1994). Towards remote seafloor classification using the angular response of acoustic backscattering: a case study from multiple overlapping GLORIA data. *IEEE J. Oceanic Eng.* 19, 112 – 127
- Clarke, J.E.H. (2015). Multispectral Acoustic Backscatter from Multibeam, Improved Classification Potential. United States Hydrographic Conference 2015 March 16th -19th National Harbor, Maryland, USA
- Cochrane, G.R. and Lafferty, K.D. (2002) Use of acoustic classification of side-scan sonardata for mapping benthic habitat in the Northern Channel Islands, California. *Continental Shelf Research* 22: 683-690.
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales, *Educational and Psychological Measurement*, Volume 20. Issue 1. Page 37 – 46. <https://doi.org/10.1177/001316446002000104>
- Colbo, K., Ross, T., Brown, C., Weber, T. (2014). A review of oceanographic applications of water column data from multibeam echosounders. *Estuarine, Coastal and Shelf Science* Volume 145, 20 May 2014, Pages 41-56. doi.org/10.1016/j.ecss.2014.04.002
- Collier, J.S., Brown, C.J. (2005). Correlation of sidescan backscatter with grain size distribution of surficial seabed sediments. *Marine Geology* 214 (2005) 431 – 449
- Costa, B. (2018). Mapping Marine Habitats Using Machine Learning and Multispectral Multibeam Data. Austin, Texas: R2 Sonic Whitepaper, 24p.
- Costa, B. Multispectral Acoustic Backscatter: How Useful Is it for Marine Habitat Mapping and Management? *Journal of Coastal Research*, 2019. 35(5), 1062–1079. <https://www.jstor.org/stable/26778554>
- Cunningham, M. (2009). More than Just the Kappa Coefficient: A Program to Fully Characterize Inter-Rater Reliability between Two Raters, SAS Global Forum, Statistics and Data Analysis, <https://api.semanticscholar.org/CorpusID:147808631>
- de Jong, C.D., Lachapelle, G., Skone, I., Elema., A. (2010). Hydrography., Vereniging voor Studie- en Studentenbelangen te Delft

- de Moustier, C. (1986). Beyond Bathymetry: Mapping Acoustic Backscattering from the Deep Seafloor with Sea Beam. *J. Acoust. Soc. Amer.*, 79, pp. 316-33
- Deng, L., and Yu, D. (2014). Deep Learning Methods and Applications. USA: Foundations and Trends in Signal Processing, Volume 7, Issue 3. pp. 1-192
- Diesing, M., Thorsnes, T. (2018). Mapping of Cold-Water Coral Carbonate Mounds Based on Geomorphometric Features: An Object-Based Approach. *Geosciences* 8, 34. <https://doi.org/10.3390/geosciences8020034>
- Earle, S. (2015). Physical Geology. Victoria, B.C.: BCcampus. Retrieved from <https://opentextbc.ca/geology/>
- Esposito, C., Kulpa, J. (2018). Seabed Classification Using Multibeam Sonar Backscatter. California Shore and Beach Preservation Association – Conference
- Feldens L, Calder B. (2005). Geocoder: an efficient backscatter map constructor. In: Proceedings of the U.S. Hydrographic Conference San Diego.
- Feldens, P., Schulze, I., Papenmeier, S., Schönke, M., Deimling, J.S.v. (2018). Improved Interpretation of Marine Sedimentary Environments Using Multi-Frequency Multibeam Backscatter Data. MDPI. *Geosciences* 8, 214
- Fonseca, L., Brown, C., Calder, B., Mayer, L., Rzhanov, Y. (2008). Angular range analysis of acoustic themes from Stanton Banks Ireland: A link between visual interpretation and multibeam echosounder angular signatures. *Applied Acoustics* 70, 1298–1304
- Fonseca, L., Mayer, L. (2007). Remote estimation of surficial seafloor properties through the application angular range analysis to multibeam sonar data. *Mar. Geophys. Res.* 28, 119–126. <https://doi.org/10.1007/s11001-007-9019-4>
- France-Lanord, C., Spiess, V., Klaus, A., Schwenk, T., and the Expedition 354 Scientists. (2016). Expedition 354 methods Proceedings of the International Ocean Discovery Program Volume 354 doi:10.14379/iodp.proc.354.106.2016

- Galparsoro, I; Agrafojo, X; Roche, M.; Degrendele, K. (2015). Comparison of supervised and unsupervised automatic classification methods for sediment types mapping using multibeam echosounder and grab sampling. *Ital. J. Geosci.* 134(1): 41-49. <https://dx.doi.org/10.3301/IJG.2014.19>
- Gaida, T.C., Ali, T.A.T., Snellen, M., Simkooei, A.A., van Dijk, T.A.G.P., Simons, D.G. (2018). A Multispectral Bayesian Classification Method for Increased Acoustic Discrimination of Seabed Sediments Using Multi-Frequency Multibeam Backscatter Data. *Geosciences*, 8(12), 455; <https://doi.org/10.3390/geosciences8120455>
- Gaida, T.C., Mohammadloo, T.H., Snellen, M., Simons, D.G. (2020). Mapping the Seabed and Shallow Subsurface with Multi-Frequency Multibeam Echosounders. *Remote Sens.* 12, 52. <https://doi.org/10.3390/rs12010052>
- Gaida, T.C., Snellen, M., van Dijk, T.A.G.P., Simons, D. G. (2019). Geostatistical modelling of multibeam backscatter for fullcoverage seabed sediment maps. *Hydrobiologia*, 845:55–79
- Garlan, T., Gabeltaud, I., Lucas, S., Marchès, E. (2018). A World Map of Seabed Sediment Based on 50 Years Knowledge. New York USA Jun 03-04, 2018, 20 (6) Part I.
- Guillon, L., Lurton, X. (2001). Backscattering From Buried Sediment Layers: The Equivalent Input Backscattering Strength Model. *The Journal of The Acoustical Society of America*. January
- Haris, K., Chakraborty, B., Ingole, B., Menezes, A., & Srivastava, R. (2012). Seabed habitat mapping employing single and multi-beam backscatter data: A case study from the western continental shelf of India. *Continental Shelf Research*, 48, 40–49. doi:10.1016/j.csr.2012.08.010
- Hossin, M., Sulaiman, M.N. (2015). A Review on Evaluation Metrics for Data Classification Evaluations. *International Journal of Data Mining & Knowledge Management Process*, 5, 1–11. <https://doi.org/10.5121/ijdkp.2015.5201>
- Hutabarat, S., Evans, S.M. (2000). Pengantar Oseanografi. Jakarta, UI Press
- IAEA. (2003). Collection and Preparation of Bottom Sediment Samples for Analysis of Radionuclides and Trace Elements. IAEA-TECDOC-1360.

Nutritional and Health-Related Environmental Studies Section International  
Atomic Energy Agency. Austria

- Ierodiaconou, D., Schimel, A.C., Kennedy, D., Monk, J., Gaylard, G., Young, M., Diesing, M., Rattray, A. (2018). Combining pixel and object-based image analysis of ultra-high resolution multibeam bathymetry and backscatter for habitat mapping in shallow marine waters. *Mar. Geophys. Res.* 39, 271–288.  
[10.1007/s11001-017-9338-z](https://doi.org/10.1007/s11001-017-9338-z)
- IHO. (2005). *Manual on Hydrography Publication M-13 1st Edition*. Monaco: International Hydrographic Bureau
- IHO. (2008). IHO Standards for Hydrographic Surveys 5<sup>th</sup> Edition, Special Publication No. 44 Published by The International Hydrographic Bureau Monaco
- IHO. (2020). S-44 6<sup>th</sup> Edition IHO Standards for Hydrographic Surveys. Published by the International Hydrographic Organization 4b quai Antoine 1er Principauté de Monaco.
- Ivakin, A. N. (2004). Scattering from Discrete Inclusions in Marine Sediments. Proceedings of the Seventh European Conference on Underwater Acoustics, ECUA 2004 Delft, The Netherlands 5-8 July
- Ivakin, A.N. (2000). High frequency scattering from heterogeneous seabeds, Proceedings of the Fifth European Conference on Underwater Acoustics, ECUA 2000
- Jackson, D., and Richardson, M. (2007). High Frequency Seafloor Acoustic. Springer, N.Y.: 616 pp.
- Janowski, L., Tęgowski, J., Jarosław N.J. (2018). Seafloor mapping based on multibeam echosounder bathymetry and backscatter data using Object-Based Image Analysis: a casestudy from the Rewal site, the Southern Baltic. *Oceanological and Hydrobiological Studies*. Volume 47 - Issue 3.  
<https://doi.org/10.1515/ohs-2018-0024>
- Ji, X., Yang, B., Tang, Q. (2020). Seabed sediment classification using multibeam backscatter data based on the selecting optimal random forest model Elsevier: Applied Acoustics  
<https://doi.org/10.1016/j.apacoust.2020.107387>

- Kågesten, G. (2008) Geological seafloor mapping with backscatter data from a multibeam echo sounder. Institutionen för Geovetenskaper, Göteborgs Universitet Box 460, SE-405 30, Göteborg ISSN 1401-5765
- Kanevski, M., Pozdnoukhov, A., Timonin, V. (2008) Machine Learning Algorithms for GeoSpatialData. Applications and Software Tools. International Congress on Environmental Modelling and SoftwareIntegrating Sciences and Information Technology for Environmental Assessment and Decision Making4th Biennial Meeting of iEMSs.
- Kay, R. and Alder, J. (2005). Coastal Planning and Management. Second Edition. Taylor & Francis. New York. pp. 1 – 376
- Kearns, T.A. dan Breman, J. (2010) Bathymetry: the art and science of seafloor modeling for modern applications. Ocean Globe, ESRI Press, Redlands ISBN 978-1-58948-219-7. 274
- Koop, L.; Snellen, M.; Simons, D.G. (2021). An Object-Based Image Analysis Approach Using Bathymetry and Bathymetric Derivatives to Classify the Seafloor. *Geosciences*, 11, 45. <https://doi.org/10.3390/geosciences11020045>
- Kusumadewi, S. (2004). Artificial Intelligence, Penerbit Graha Ilmu, Yogyakarta
- Landis, R.J. and Koch, G.G. (1977). The Measurement of Observer Agreement for Categorical Data, *Biometrics*. Vol 33. No. 1 page 159 – 174. <https://doi.org/10.2307/2529310>
- Lanuru, M., Suwarni. (2011). Pengantar Oseanografi. Program Studi Ilmu Kelautan Jurusan Ilmu Kelautan Fakultas Ilmu Kelautan Dan Perikanan Universitas Hasanuddin 2011
- Leitao, F.J., Neto, A.A., Vieira, R. (2016). Morphological And Sedimentary Characterization Through Analysis of Multibeam Data at Deception Island, Antarctic. Brazilian Journal of Geophysic Vol. 34(2)
- Lekkerkerk, H. J. (2020). State of the Art in Multibeam Echosounders. *The Evolution of a Bathymetric Workhorse. Article*. Hydro International.
- Lied, T.T, Walday, M., Olsgard, F., Ellingsen, K.E., Holm, S. (2004). SEABEC - a Single Beam Echo Sounder Seabed Classification System. IEEE Xplore

- Lubis, M. Z., Anurogo, W., Khoirunnisa, H., Irawan, S., Gustin, O., & Roziqin, A. (2017). Using Side-Scan Sonar instrument to Characterize and map of seabed identification target in Punggur Sea of the Riau Islands, Indonesia. *Journal of Geoscience, Engineering, Environment, and Technology*, 2(1), 1-8.
- Lurton, X., Lamarche, G. (2015). Backscatter measurements by seafloor-mapping sonars. Guidelines and Recommendations. 200p. A collective report by members of the GeoHab Backscatter Working Group. <http://geohab.org/wp-content/uploads/2014/05/BSWG-MAY2015.pdf>
- Marsh, I., Brown, C. (2009). Neural network classification of multibeam backscatter and bathymetry data from Stanton Bank (Area IV). *Appl. Acoust.* 70, 1269–1276. <https://doi.org/10.1016/j.apacoust.2008.07.012>
- McCoy, R. M. (2005). Field Methods in Remote Sensing, The Guilford Press, New York
- McRea, J. E., Greene, H. G., O'Connell, V. M., & Wakefield, W. W. (1999). Mapping marine habitats with high resolution sidescan sonar. *Oceanologica Acta*, 22(6), 679–686. doi:10.1016/s0399-1784(00)88958-6
- Medialdea, T., Somoza, L., León, R., Farrán, M., Ercilla, G., Maestro, A., Casas, D., E. Llave, E., Hernández-Molina, F.J., Fernández-Puga, M.C., Alonso, B. (2007). Multibeam backscatter as a tool for sea-floor characterization and identification of oil spills in the Galicia Bank. *Marine Geology* 249 (2008) 93–107
- Menandro PS, Bastos AC, Misiuk B and Brown CJ. (2022). Applying a MultiMethod Framework to Analyze the Multispectral Acoustic Response of the Seafloor. *Front. Remote Sens.* 3:860282. doi: 10.3389/frsen.2022.860282
- Mertikas, P., Karantzalos, K. (2020). Seafloor Mapping from Multispectral Multibeam Acoustic Data at the European Open Science Cloud. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLIII-B2-2020, XXIV ISPRS Congress

(2020 edition). <https://doi.org/10.5194/isprs-archives-XLIII-B2-2020-985-2020>

Misiuk, B., Lecours, V., Bell, T. (2018). A Multiscale Approach to Mapping Seabed Sediments. *PLOS ONE*. doi.org/10.1371/journal.pone.0193647

Nguyen, T.K. (2018). Seafloor classification with a Multi-swath Multi-beam Echo Sounder. Thèse de Doctorat. STIC – Sciences et Technologies de l’Information et des Communications

NOAA. (1997). Nautical Chart User’s Manual. U.S. Department of Commerce National Oceanic and Atmospheric Administration (NOAA) National Ocean Service. United States of America.

Pace, N. and Gao, H. (1988). Swathe Seabed Classification, *IEEE J. Oceanic Engin.* 13(2), 83–90.

Penrose, J.D., Siwabessy, P.J.W., Gavrilov, A., Parnum, I., Hamilton, L.J., Bickers, A., Brooke, B., Ryan, D.A., Kennedy, P. (2005). Acoustic Techniques for Seabed Classification. Cooperative Research Centre for Coastal Zone Estuary and Waterway Management. Technical Report 32.

R2Sonic. (2022). Multispectral Backscatter Technical Mode - R2Sonic. <http://www.r2sonic.com/products/technical-modes/multispectral-backscatter>

Retsch. (2015). Sieve Analysis Taking a close look at quality. An expert guide to particle size analysis. Retsch GmbH Haan

Runya, R. M., McGonigle, C., Quinn, R., Howe, J., Collier, J., Fox, C., Dooley, J., O’Loughlin, R., Calvert, J., Scott, L., Abernethy, C., Evans, W. (2021). Examining the Links between Multi-Frequency Multibeam Backscatter Data and Sediment Grain Size. *Remote Sens.* 2021, 13, 1539. <https://doi.org/10.3390/rs13081539>

Samsudin, S. A., and Che Hasan, R. (2017). Assessment of Multibeam Backscatter Texture Analysis for Seafloor Sediment Classification. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-4/W5, GGT 2017, 4 October 2017, Kuala Lumpur, Malaysia. <https://doi.org/10.5194/isprs-archives-XLII-4-W5-177-2017>.

- SeaBeam. (2000). Multibeam Sonar Theory of Operation. L-3 Communications  
SeaBeam Instruments 141 Washington Street East Walpole, MA 02032-  
1155
- Simeone, O. (2018) A Brief Introduction to Machine Learning for Engineers,  
Foundations and Trends® in Signal Processing: Vol. 12: No. 3-4, pp 200-  
431. <http://dx.doi.org/10.1561/2000000102>
- Simkooei, A.A., Koop, L., van der Reijden, K.J., Snellen, M., Simons, D. G. (2019).  
Seafloor Characterization Using Multibeam Echosounder Backscatter Data:  
Methodology and Results in the North Sea. *Geosciences*, 9, 292.
- Simkooei, A.A., Snellen, M., and Simons, D. G. (2009). Riverbed sediment  
classification using multibeam echosounder backscatter data. *Journal  
Acoustical Society of America*. pp. 1724–1738
- Snellen, M., Gaida, T.C., Koop, L., Alevizos, E., Simons, D.G. (2018).  
Performance of Multibeam Echosounder Backscatter-Based Classification  
for Monitoring Sediment Distributions Using Multitemporal Large-Scale  
Ocean Data Sets. *IEEE J. Ocean. Eng.* 1–14.  
<https://doi.org/10.1109/JOE.2018.2791878>
- Solikin, S., Manik, H.M., Pujiyati, S., and Susilohadi, S. (2018). Seafloor  
Classification Using Multibeam Backscatter in G-Island, North Jakarta.  
*International Journal of Advanced Science and Technology* Vol.119,  
pp.135-144
- Sugiyono. (2009). Metode Penelitian Kuantitatif, Kualitatif dan R&D. Bandung:  
Alfabeta.
- Tamsett, D. (1993) Sea-Bed Characterisation and Classification from the Power  
Spectra of Sidescan Sonar Data, *Mar. Geophys. Res.* 15, 43–64.
- Tang, Q., Lei, N., Li, J., Wu, Y., Zhou, X. (2015). Seabed Mixed Sediment  
Classification with Multi-beam Echo Sounder Backscatter Data in Jiaozhou  
Bay. *Marine Georesources & Geotechnology* 33:1, 1-11
- Tegowskia, J., Nowaka, J., Moskalikc, M., Szefflera, K. (2011). Seabed  
Classification from Multibeam Echosounder Backscatter Data Using  
Wavelet Transformation and Neural Network Approach. Conference Paper

- Ukrainski, P. (2016). Classification Accuracy Assessment. Confusion Matrix Method. SCGIS, Remote Sensing
- Venteris, E.R, May CJ (2014) Cost-Effective Mapping of Benthic Habitats in Inland Reservoirs through Split-Beam Sonar, Indicator Kriging, and Historical Geologic Data. PLoS ONE 9(4): e95940. <https://doi.org/10.1371/journal.pone.0095940>
- Vondervoort, D. V, Lekkerkerk, H.J. (2021). Multispectral Multibeam Echo Sounder Data: Multispectral Backscatter Data to Improve Seafloor Characterization. Article. Hydro International.
- Wan, J., Qin, Z., Cui, X., Yang, F., Yasir, M., Ma, B., and Liu, X. (2022). MBES Seabed Sediment Classification Based on a Decision Fusion Method Using Deep Learning Model, *Remote Sens.* 14, 3708. <https://doi.org/10.3390/rs14153708>
- Wang, J., Li, G., Kan, G., Hou, Z., Meng, X., Liu, B., Liu, C., and Lei, S. (2021). High frequency dependence of sound speed and attenuation in coral sand sediments. *Ocean Engineering*, 2021 234. <https://doi.org/10.1016/j.oceaneng.2021.109215>
- Wentworth, C. (1922). A scale of grade and class terms for classic sediments, *J. Geol.* 30, 377–392.
- Winarno. (2013). Metodologi Penelitian dalam Pendidikan Jasmani. Malang: UM Press.
- Wu, Z., Yang, F., Tang, Y. (2021). *Multi-beam Bathymetric Technology*. In: High-resolution Seafloor Survey and Applications. Springer, Singapore. Xu, W., Cheng, H.; Zheng, S., Hu, H. (2021). Predicted Mapping of Seabed Sediments Based on MBES Backscatter and Bathymetric Data: A Case Study in Joseph Bonaparte Gulf, Australia, Using Random Forest Decision Tree. *J. Mar. Sci. Eng.* 9, 947. <https://doi.org/10.3390/jmse9090947>
- Zakariya, R., Abdullah, M. A., Hasan, R.C., Khalil, I. (2018). Automatic classification techniques for the type of sediment map from multibeam sonar data. IOP Conf. Series: Earth and Environmental Science 117 012047
- Zakariya, R., Abdullah, M.A., Hasan, R.C., Khalil, I. (2018). The Use of Backscatter Classification and Bathymetry Derivatives from Multibeam

Data for Seabed Sediment Characterization. In: Öchsner, A. (eds) Engineering Applications for New Materials and Technologies. *Advanced Structured Materials*, vol 85. Springer, Cham. [https://doi.org/10.1007/978-3-319-72697-7\\_47](https://doi.org/10.1007/978-3-319-72697-7_47)

Zhang, Q.; Zhao, J.; Li, S.; Zhang, H. (2022). Seabed Sediment Classification Using Spatial Statistical Characteristics. *J. Mar. Sci. Eng.*, 10, 691. <https://doi.org/10.3390/jmse10050691>

Zhao, T.; Montereale Gavazzi, G.; Lazendić, S.; Zhao, Y.; Pižurica, A. (2021). Acoustic Seafloor Classification Using the Weyl Transform of Multibeam Echosounder Backscatter Mosaic. *Remote Sens.*, 13, 1760. <https://doi.org/10.3390/rs1309176>

Zhi, H., Siwabessy, J., Nichol, S.L., Brooke, B. P. (2014). Predictive mapping of seabed substrata using high-resolution multibeam sonar data: A case study from a shelf with complex geomorphology. *Marine Geology*, 357(), 37–52. <https://doi.org/10.1016/j.margeo.2014.07.012>

Zhou, X., Chen, Y. (2005). Seafloor Classification of Multibeam Sonar Data Using Neural Network Approach *Marine Geodesy*, 28: 201–206

Zhu, Z., Cui, X., Zhang, K., Ai, B., Shi, B., Yang, F. (2021). DNN-based seabed classification using differently weighted MBES multifeatures. *Marine Geology*. Vol. 438, p. 106519 <https://doi.org/10.1016/j.margeo.2021.106519>

## **LAMPIRAN**

- |            |  |
|------------|--|
| LAMPIRAN A | Hasil Test Sedimen Grain Size                  |
| LAMPIRAN B | Klasifikasi Sedimen in Situ                    |
| LAMPIRAN C | Data Klasifikasi Sedimen dan Kedalaman         |
| LAMPIRAN D | Data Klasifikasi Sedimen dan Backscatter       |
| LAMPIRAN E | Data Klasifikasi Sedimen dan Selisih Kedalaman |

*“Halaman ini sengaja dikosongkan”*

## LAMPIRAN A : GRAIN SIZE DISTRIBUTION CURVE



**PT. GEOMARINE SURVEY DINAMIKA**  
 Jl. Wisma Tirta Agung Asri I Kav. 6, Perum Manhattan, Gunung Anyar, Surabaya, 60294  
 Telp: (+62) 813-1928-0143, Email: [admin@gmsdinamika.co.id](mailto:admin@gmsdinamika.co.id), Laman: [gmsdinamika.co.id](http://gmsdinamika.co.id)

### GRAIN SIZE DISTRIBUTION CURVE

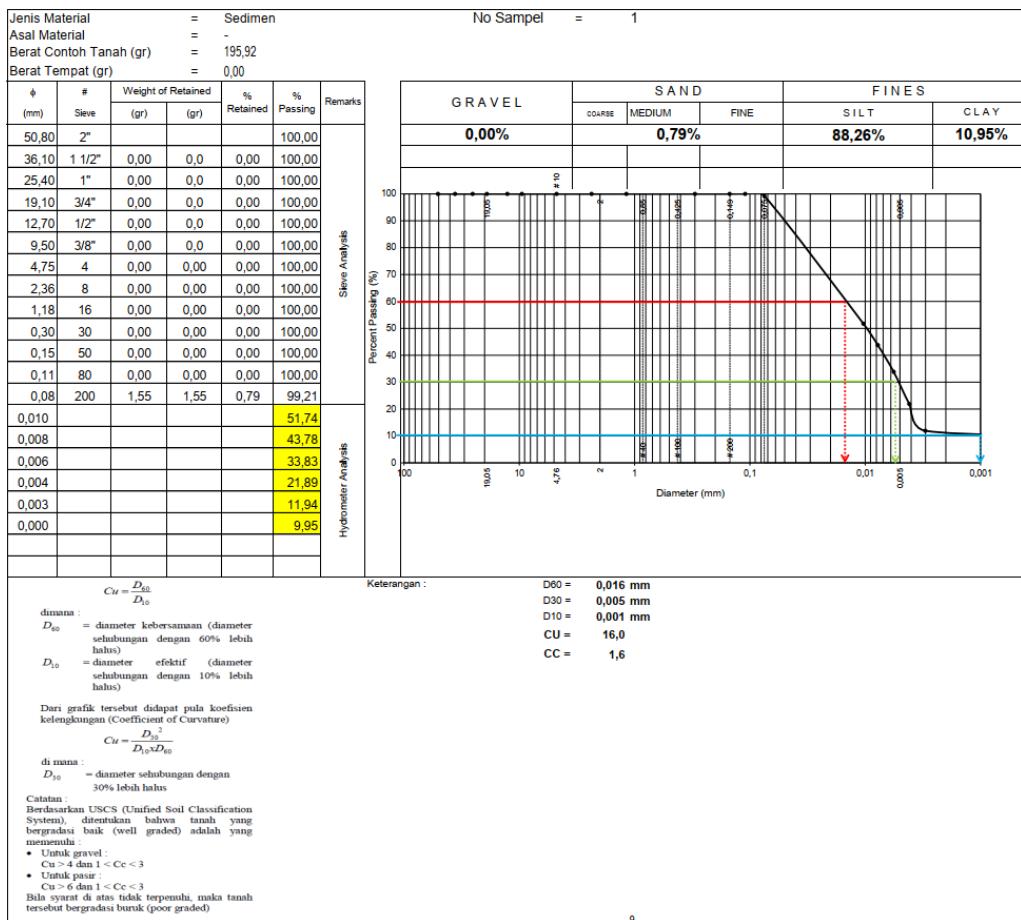
SNI 03-1968-1990

Pekerjaan  
Lokasi

: Penyelidikan Tanah  
: Dermaga Gresik Jasatama

di Uji  
Tanggal

: Dyan Wahyu  
: 6 Februari 2023



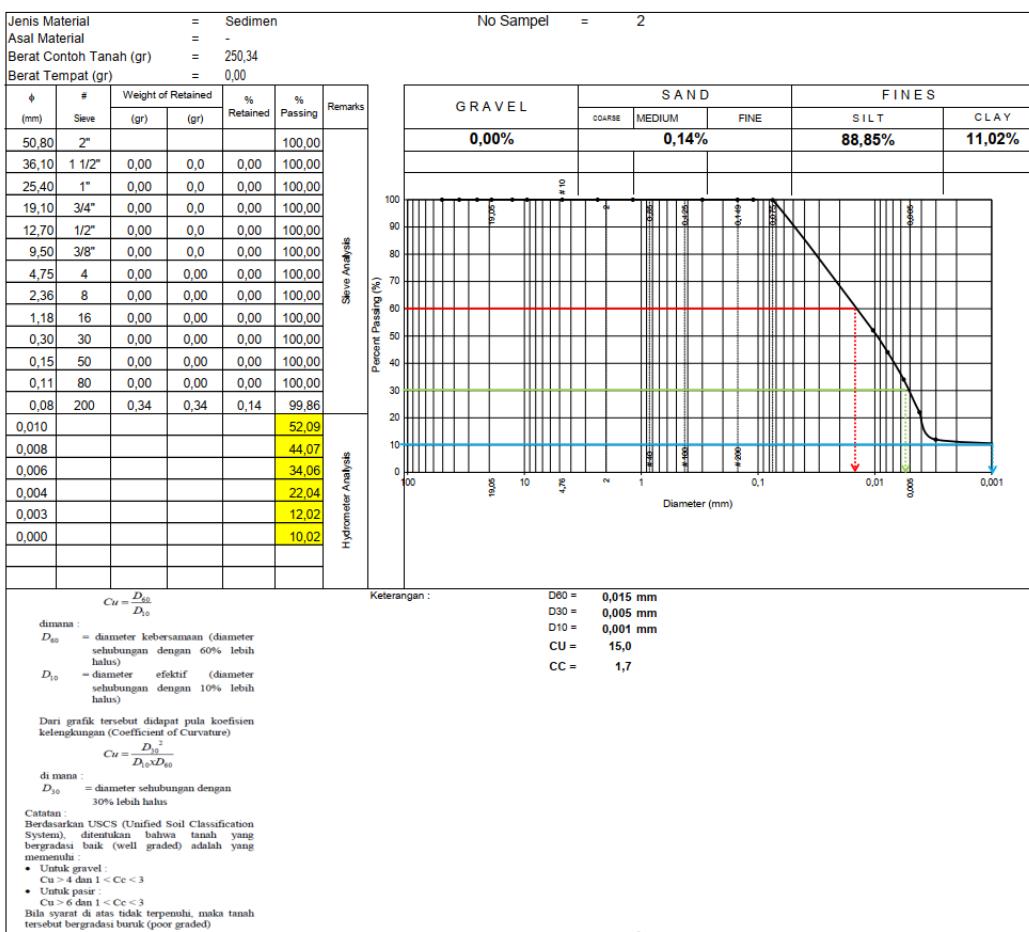


**GRAIN SIZE DISTRIBUTION CURVE**

Pekerjaan : Penyelidikan Tanah  
 Lokasi : Dermaga Gresik Jasatama

SNI 03-1968-1990

di Uji : Dyan Wahyu  
 Tanggal : 6 Februari 2023





**PT. GEOMARINE SURVEY DINAMIKA**  
**Jl. Wisma Tirta Agung Asri I Kav. 6, Perum Manhattan, Gunung Anyar, Surabaya, 60294**  
**Telp: (+62) 813-1928-0143, Email: [admin@gmsdinamika.co.id](mailto:admin@gmsdinamika.co.id), Laman: [gmsdinamika.co.id](http://gmsdinamika.co.id)**

### GRAIN SIZE DISTRIBUTION CURVE

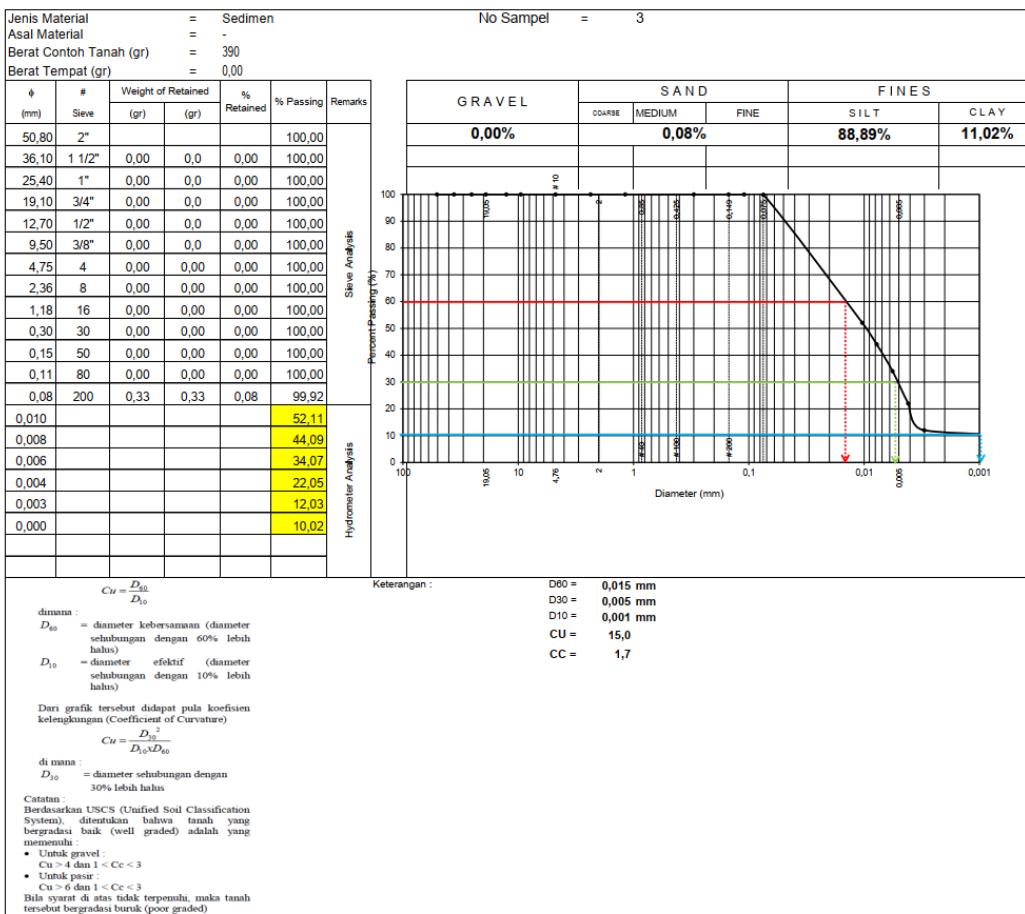
SNI 03-1968-1990

Pekerjaan  
Lokasi

: Penyelidikan Tanah  
: Dermaga Gresik Jasatama

di Uji  
Tanggal

: Dyan Wahyu  
: 6 Februari 2023





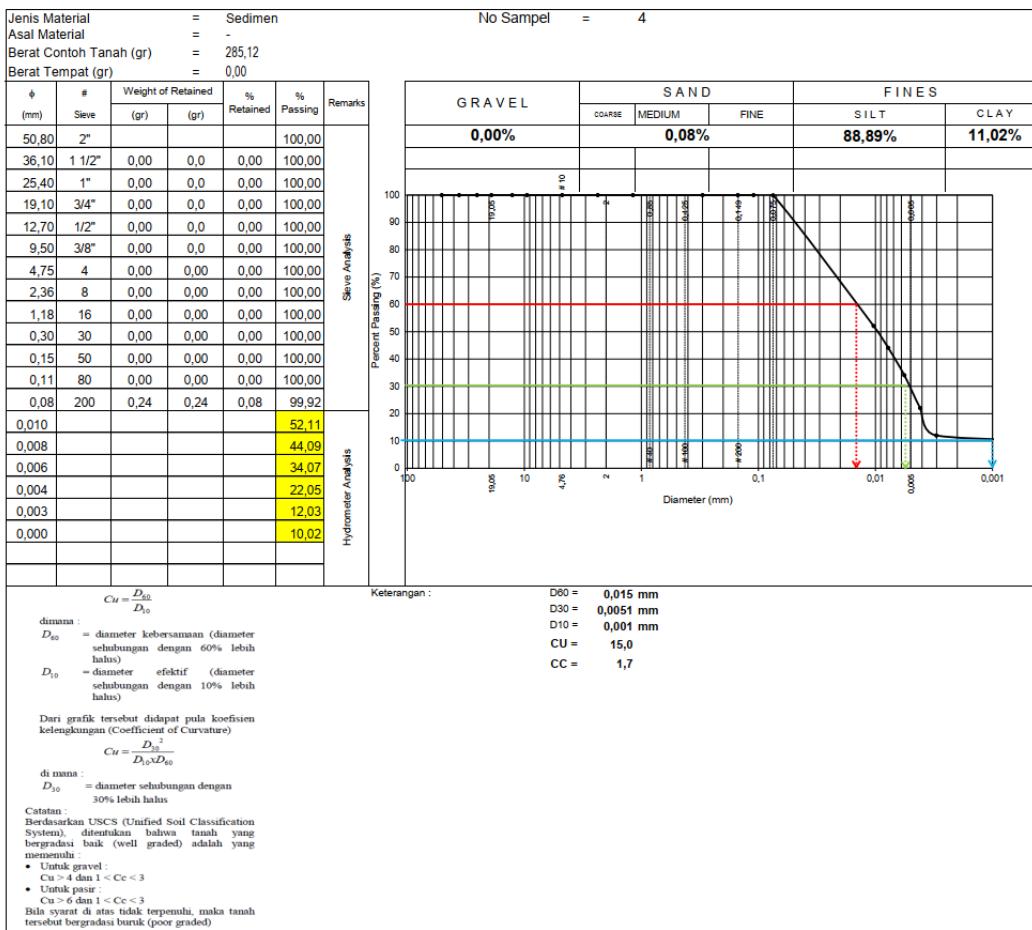
**PT. GEOMARINE SURVEY DINAMIKA**  
Jl. Wisma Tirta Agung Asri I Kav. 6, Perum Manhattan, Gunung Anyar, Surabaya, 60294  
Telp: (+62) 813-1928-0143, Email: [admin@gmsdinamika.co.id](mailto:admin@gmsdinamika.co.id), Laman: [gmsdinamika.co.id](http://gmsdinamika.co.id)

### GRAIN SIZE DISTRIBUTION CURVE

SNI 03-1968-1990

Pekerjaan : Penyelidikan Tanah  
Lokasi : Dermaga Gresik Jasatama

di Uji : Dyan Wahyu  
Tanggal : 6 Februari 2023

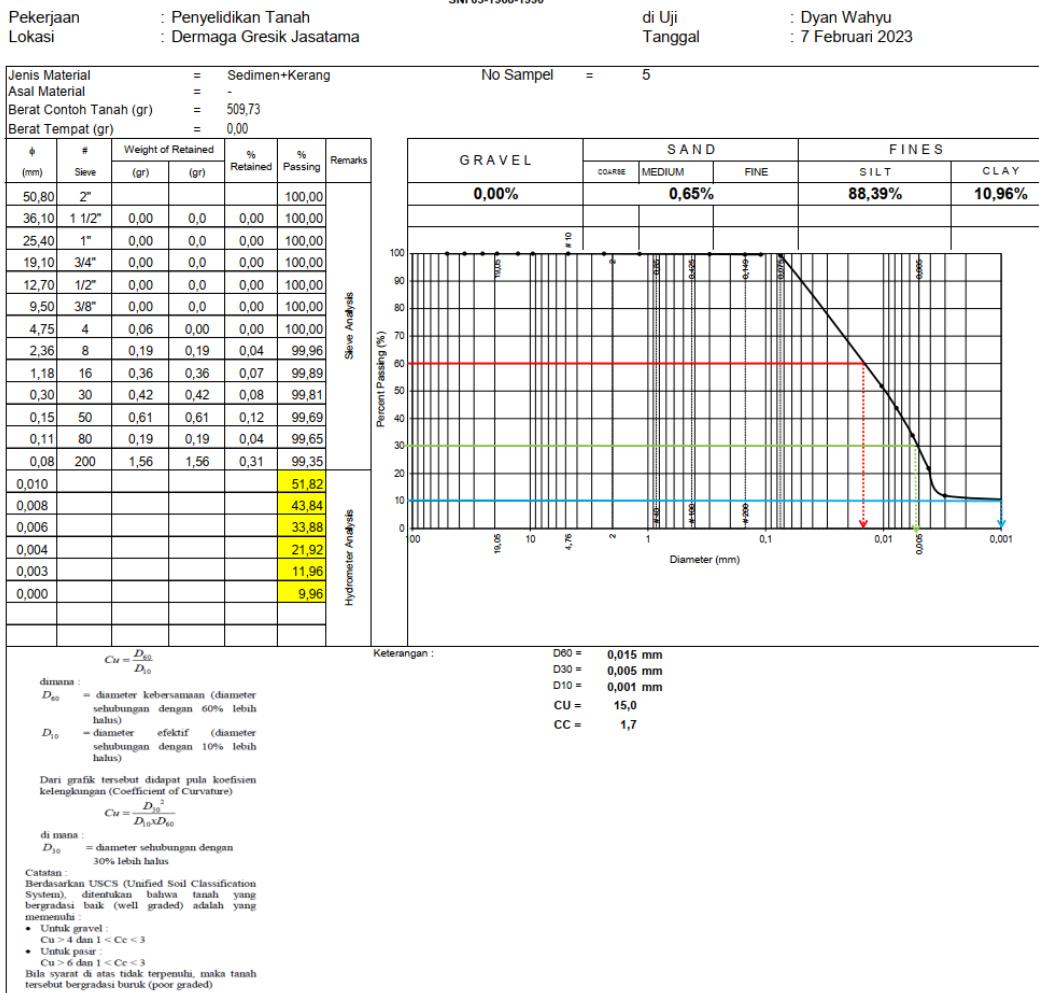




**PT. GEOMARINE SURVEY DINAMIKA**  
**Jl. Wisma Tirta Agung Asri I Kav. 6, Perum Manhattan, Gunung Anyar, Surabaya, 60294**  
**Telp: (+62) 813-1928-0143, Email: [admin@gmsdinamika.co.id](mailto:admin@gmsdinamika.co.id), Laman: [gmsdinamika.co.id](http://gmsdinamika.co.id)**

### GRAIN SIZE DISTRIBUTION CURVE

SNI 03-1968-1990



*“Halaman ini sengaja dikosongkan”*

## LAMPIRAN B

Tabel B. Hasil Klasifikasi Sedimen Sampel in Situ

ID	NORTHING (M)	EASTING (M)	SEDIMENT
			IN SITU
1	9209322.041	683362.218	silt
2	9209250.658	683353.081	silt
3	9209230.360	683368.846	silt
4	9209200.681	683382.026	silt
5	9209214.955	683421.584	silt
6	9209253.436	683399.638	silt
7	9209302.449	683383.100	silt
8	9209349.261	683342.079	silt
9	9209389.659	683317.433	silt
10	9209439.604	683305.922	silt
11	9209481.663	683291.125	silt
12	9209495.717	683361.346	silt
13	9209451.810	683383.924	silt
14	9209399.870	683407.114	silt
15	9209673.219	683679.070	silt
16	9209637.436	683700.993	clayey sand
17	9209556.032	683726.971	clayey sand
18	9209449.563	683767.783	silty sand
19	9209363.831	683789.634	sandy silt

ID	NORTHING (M)	EASTING (M)	SEDIMENT
			IN SITU
20	9209250.612	683785.794	sandy silt
21	9209297.300	683745.603	clayey sand
22	9209376.611	683735.066	clayey sand
23	9209466.676	683702.542	sandy silt
24	9209550.498	683668.968	clayey sand
25	9209630.739	683645.155	clayey sand
26	9209527.330	683622.402	clayey sand
27	9209464.199	683644.676	sandy silt
28	9209425.032	683684.691	clayey sand
29	9209349.285	683685.335	sandy silt
30	9209302.256	683705.140	sandy silt
31	9209250.386	683746.901	clayey sand
32	9209203.563	683685.947	clayey sand
33	9209182.845	683690.811	silt
34	9209272.371	683651.949	clayey sand
35	9209249.329	683713.056	clayey sand
36	9209304.951	683651.794	silt
37	9209357.153	683591.451	clayey sand
38	9209397.749	683575.017	clayey sand
39	9209450.204	683547.034	clayey sand

ID	NORTHING (M)	EASTING (M)	SEDIMENT
			IN SITU
40	9209500.339	683523.641	clayey sand
41	9209543.387	683503.020	clayey sand
42	9209601.122	683512.421	clayey sand
43	9209578.960	683438.468	clayey sand
44	9209510.187	683470.568	sandy silt
45	9209347.780	683394.894	silt
46	9209297.284	683435.388	silt
47	9209254.364	683458.717	silt
48	9209207.251	683476.137	silt
49	9209224.029	683516.340	silt
50	9209278.667	683494.866	silt
51	9209341.757	683474.586	silt
52	9209413.710	683448.918	silt
53	9209563.674	683390.017	silt
54	9209494.625	683424.707	clayey sand
55	9209440.592	683503.809	clayey sand
56	9209374.025	683539.602	silt
57	9209396.803	683640.063	clayey sand
58	9209214.320	683763.326	sandy silt
59	9209331.000	683501.000	silty sand

ID	NORTHING (M)	EASTING (M)	SEDIMENT
			IN SITU
60	9209467.000	683481.000	sandy silt
61	9209294.000	683460.000	sandy silt
62	9209249.000	683428.000	silty sand
63	9209205.000	683431.000	silty sand
64	9209283.000	683399.000	silty sand
65	9209247.000	683397.000	silty sand
66	9209319.000	683375.000	silty sand
67	9209335.000	683397.000	sandy silt
68	9209256.000	683363.000	silty sand
69	9209258.000	683387.000	silty sand
70	9209234.000	683357.000	silty sand
71	9209246.000	683342.000	silty sand
72	9209315.000	683410.000	silty sand
73	9209390.000	683438.000	silty sand
74	9209278.000	683452.000	silty sand

## LAMPIRAN C

Tabel C. Klasifikasi Sedimen Sampel in Situ vs Kedalaman

ID	SEDIMENT	KEDALAMAN (M)				
		IN-SITU	200kHz	250kHz	300kHz	350kHz
1	silt	-4.501	-4.483	-4.465	-4.459	-4.449
2	silt	-4.066	-4.025	-4.005	-3.995	-3.980
3	silt	-3.706	-3.666	-3.648	-3.636	-3.623
4	silt	-3.697	-3.647	-3.621	-3.603	-3.587
5	silt	-4.214	-4.186	-4.174	-4.162	-4.149
6	silt	-4.597	-4.560	-4.541	-4.532	-4.519
7	silt	-4.889	-4.850	-4.837	-4.829	-4.817
8	silt	-4.492	-4.415	-4.392	-4.382	-4.371
9	silt	-4.395	-4.363	-4.355	-4.342	-4.334
10	silt	-4.943	-4.909	-4.900	-4.890	-4.885
11	silt	-5.390	-5.362	-5.349	-5.344	-5.335
12	silt	-6.614	-6.588	-6.575	-6.571	-6.562
13	silt	-6.748	-6.717	-6.708	-6.700	-6.696
14	silt	-6.714	-6.687	-6.675	-6.667	-6.659
15	silt	-13.385	-13.357	-13.329	-13.317	-13.292
16	clayey sand	-15.211	-15.205	-15.195	-15.192	-15.183
17	clayey sand	-18.135	-18.132	-18.127	-18.115	-18.107
18	silty sand	-20.991	-20.967	-20.961	-20.949	-20.948
19	sandy silt	-19.739	-19.850	-19.721	-19.711	-19.708

ID	SEDIMEN	KEDALAMAN (M)				
		IN-SITU	200kHz	250kHz	300kHz	350kHz
20	sandy silt	-19.975	-19.964	-19.948	-19.936	-19.935
21	clayey sand	-19.360	-19.309	-19.271	-19.268	-19.259
22	clayey sand	-19.108	-19.054	-19.039	-19.041	-19.027
23	sandy silt	-18.300	-18.247	-18.224	-18.229	-18.214
24	clayey sand	-17.242	-17.115	-17.069	-17.070	-17.066
25	clayey sand	-12.643	-12.544	-12.502	-12.516	-12.501
26	clayey sand	-15.014	-15.067	-15.041	-15.016	-15.009
27	sandy silt	-16.576	-16.542	-16.520	-16.497	-16.482
28	clayey sand	-16.168	-16.162	-16.155	-16.144	-16.151
29	sandy silt	-17.557	-17.475	-17.425	-17.376	-17.377
30	sandy silt	-18.949	-18.824	-18.762	-18.742	-18.678
31	clayey sand	-19.029	-19.016	-19.006	-19.000	-18.992
32	clayey sand	-17.445	-17.383	-17.352	-17.342	-17.328
33	silt	-17.322	-17.281	-17.262	-17.245	-17.230
34	clayey sand	-16.406	-16.339	-16.310	-16.286	-16.269
35	clayey sand	-18.752	-18.716	-18.683	-18.661	-18.651
36	silt	-16.467	-16.372	-16.352	-16.325	-16.314
37	clayey sand	-13.118	-13.052	-13.044	-13.044	-13.037
38	clayey sand	-11.654	-11.660	-11.662	-11.662	-11.651
39	clayey sand	-10.411	-10.384	-10.379	-10.372	-10.366

ID	SEDIMEN	KEDALAMAN (M)				
		IN-SITU	200kHz	250kHz	300kHz	350kHz
40	clayey sand	-11.715	-11.691	-11.681	-11.680	-11.671
41	clayey sand	-13.210	-13.174	-13.160	-13.157	-13.152
42	clayey sand	-14.455	-14.412	-14.406	-14.408	-14.405
43	clayey sand	-15.688	-15.647	-15.643	-15.629	-15.622
44	sandy silt	-12.604	-12.565	-12.587	-12.573	-12.560
45	silt	-5.662	-5.643	-5.617	-5.611	-5.602
46	silt	-6.464	-6.435	-6.420	-6.411	-6.404
47	silt	-6.382	-6.357	-6.340	-6.337	-6.323
48	silt	-5.474	-5.448	-5.432	-5.422	-5.412
49	silt	-6.698	-6.673	-6.662	-6.655	-6.649
50	silt	-7.227	-7.199	-7.182	-7.177	-7.168
51	silt	-6.927	-6.906	-6.895	-6.887	-6.878
52	silt	-7.377	-7.350	-7.339	-7.317	-7.318
53	silt	-8.498	-8.417	-8.416	-8.384	-8.371
54	clayey sand	-9.042	-9.006	-9.015	-9.010	-8.991
55	clayey sand	-10.565	-10.555	-10.535	-10.525	-10.520
56	silt	-12.018	-11.953	-11.963	-11.952	-11.938
57	clayey sand	-15.113	-15.088	-15.073	-15.063	-15.055
58	sandy silt	-19.236	-19.204	-19.196	-19.192	-19.180
59	silty sand	-7.338	-7.314	-7.304	-7.294	-7.286

ID	SEDIMEN	KEDALAMAN (M)				
		IN-SITU	200kHz	250kHz	300kHz	350kHz
60	sandy silt	-11.687	-11.655	-11.660	-11.643	-11.634
61	sandy silt	-6.972	-6.942	-6.929	-6.921	-6.914
62	silty sand	-5.258	-5.234	-5.220	-5.212	-5.203
63	silty sand	-3.999	-3.970	-3.945	-3.938	-3.930
64	silty sand	-4.772	-4.752	-4.738	-4.732	-4.726
65	silty sand	-4.316	-4.286	-4.267	-4.256	-4.246
66	silty sand	-4.996	-4.969	-4.955	-4.943	-4.938
67	sandy silt	-5.690	-5.666	-5.633	-5.625	-5.617
68	silty sand	-4.225	-4.172	-4.149	-4.142	-4.130
69	silty sand	-4.464	-4.425	-4.406	-4.399	-4.382
70	silty sand	-3.821	-3.777	-3.753	-3.732	-3.723
71	silty sand	-4.023	-3.989	-3.965	-3.949	-3.937
72	silty sand	-5.924	-5.902	-5.884	-5.875	-5.867
73	silty sand	-6.942	-6.920	-6.906	-6.896	-6.886
74	silty sand	-6.531	-6.508	-6.490	-6.472	-6.470

## LAMPIRAN D

Tabel D. Klasifikasi Sedimen Sampel in Situ vs Backscatter

ID	SEDIMENT	BACKSCATTER (DB)				
		IN-SITU	200 kHz	250 kHz	300 kHz	350 kHz
1	silt	-24.707	-26.724	-25.718	-25.997	-26.429
2	silt	-24.942	-26.974	-26.039	-26.338	-26.672
3	silt	-24.325	-26.292	-25.204	-25.475	-25.877
4	silt	-23.436	-25.332	-24.138	-24.324	-24.724
5	silt	-25.035	-27.003	-26.021	-26.318	-26.754
6	silt	-24.680	-26.607	-25.612	-25.885	-26.305
7	silt	-24.895	-26.837	-25.877	-26.173	-26.654
8	silt	-25.482	-27.535	-26.595	-26.936	-27.350
9	silt	-25.193	-27.148	-26.205	-26.517	-26.946
10	silt	-25.156	-27.174	-26.224	-26.533	-26.936
11	silt	-24.366	-26.348	-25.355	-25.679	-26.135
12	silt	-23.977	-25.910	-24.884	-25.119	-25.410
13	silt	-24.101	-26.005	-24.957	-25.205	-25.567
14	silt	-24.559	-26.553	-25.520	-25.819	-26.237
15	silt	-25.940	-28.452	-27.984	-28.618	-29.434
16	clayey sand	-25.827	-28.407	-27.853	-28.631	-29.395
17	clayey sand	-25.630	-28.194	-27.766	-28.507	-29.310
18	silty sand	-25.820	-28.322	-27.859	-28.764	-29.620
19	sandy silt	-25.719	-28.257	-27.839	-28.582	-29.428

ID	SEDIMENT	BACKSCATTER (DB)				
		200 kHz	250 kHz	300 kHz	350 kHz	400 kHz
20	sandy silt	-25.468	-27.959	-27.475	-28.241	-29.069
21	clayey sand	-27.609	-30.411	-30.100	-31.020	-31.989
22	clayey sand	-25.507	-28.031	-27.550	-28.216	-29.066
23	sandy silt	-25.592	-28.187	-27.707	-28.488	-29.347
24	clayey sand	-25.784	-28.299	-27.827	-28.610	-29.444
25	clayey sand	-26.071	-28.616	-28.120	-28.829	-29.655
26	clayey sand	-25.212	-27.622	-27.065	-27.720	-28.497
27	sandy silt	-25.791	-28.340	-27.869	-28.651	-29.436
28	clayey sand	-25.071	-27.587	-27.107	-27.823	-28.611
29	sandy silt	-25.743	-28.283	-27.804	-28.563	-29.394
30	sandy silt	-25.793	-28.292	-27.818	-28.597	-29.439
31	clayey sand	-26.038	-28.675	-28.242	-29.054	-29.922
32	clayey sand	-25.790	-28.321	-27.849	-28.641	-29.490
33	silt	-25.587	-28.099	-27.630	-28.372	-29.206
34	clayey sand	-27.181	-29.845	-29.460	-30.327	-31.246
35	clayey sand	-25.838	-28.387	-27.923	-28.693	-29.518
36	silt	-25.327	-27.799	-27.281	-28.032	-28.689
37	clayey sand	-25.976	-28.477	-28.015	-28.795	-29.485
38	clayey sand	-25.479	-27.966	-27.368	-28.014	-28.803
39	clayey sand	-25.768	-28.249	-27.654	-28.350	-29.054

ID	SEDIMENT	BACKSCATTER (DB)				
		IN-SITU	200 kHz	250 kHz	300 kHz	350 kHz
40	clayey sand	-26.157	-28.665	-28.172	-28.860	-29.637
41	clayey sand	-25.116	-27.634	-27.090	-27.781	-28.510
42	clayey sand	-25.685	-28.271	-27.795	-28.460	-29.299
43	clayey sand	-26.139	-28.611	-28.145	-28.845	-29.668
44	sandy silt	-25.471	-27.877	-27.231	-27.779	-28.448
45	silt	-23.157	-24.986	-23.814	-23.981	-24.319
46	silt	-24.088	-26.070	-25.061	-25.306	-25.762
47	silt	-24.657	-26.689	-25.732	-26.050	-26.384
48	silt	-25.285	-27.513	-26.721	-27.112	-27.618
49	silt	-25.432	-27.722	-27.024	-27.525	-28.116
50	silt	-25.432	-27.580	-26.707	-27.094	-27.632
51	silt	-25.381	-27.661	-26.883	-27.371	-27.924
52	silt	-25.895	-28.212	-27.477	-27.941	-28.537
53	silt	-25.741	-27.936	-27.065	-27.442	-27.923
54	clayey sand	-25.579	-27.906	-27.171	-27.673	-28.222
55	clayey sand	-25.776	-28.236	-27.650	-28.288	-29.019
56	silt	-25.716	-28.231	-27.724	-28.359	-29.115
57	clayey sand	-25.517	-28.008	-27.493	-28.233	-29.054
58	sandy silt	-26.507	-29.122	-28.713	-29.548	-30.442
59	silty sand	-25.354	-27.692	-27.010	-27.504	-28.124

ID	SEDIMENT	BACKSCATTER (DB)				
		200 kHz	250 kHz	300 kHz	350 kHz	400 kHz
60	sandy silt	-26.017	-28.540	-27.969	-28.705	-29.474
61	sandy silt	-25.336	-27.502	-26.565	-26.882	-27.286
62	silty sand	-24.146	-26.116	-24.969	-25.280	-25.657
63	silty sand	-25.081	-27.048	-26.075	-26.378	-26.786
64	silty sand	-25.259	-27.216	-26.290	-26.603	-26.972
65	silty sand	-24.371	-26.339	-25.282	-25.578	-25.941
66	silty sand	-24.285	-26.217	-25.174	-25.421	-25.813
67	sandy silt	-23.223	-25.018	-23.879	-24.055	-24.349
68	silty sand	-24.933	-26.895	-25.910	-26.201	-26.675
69	silty sand	-24.696	-26.668	-25.675	-25.952	-26.333
70	silty sand	-23.521	-25.387	-24.272	-24.466	-24.792
71	silty sand	-24.868	-27.000	-26.095	-26.430	-26.923
72	silty sand	-23.318	-25.137	-24.022	-24.200	-24.490
73	silty sand	-25.233	-27.507	-26.676	-27.096	-27.595
74	silty sand	-24.735	-26.754	-25.795	-26.093	-26.616

## LAMPIRAN E

Tabel E. Klasifikasi Sedimen Sampel in Situ vs Selisih Kedalaman

ID	SEDIMENT	SELISIH KEDALAMAN (M)				
		IN-SITU	dh_200-250	dh_200-300	dh_200-350	dh_200-400
1	silt		0.000	-0.003	0.000	-0.016
2	silt		-0.047	-0.094	-0.100	-0.101
3	silt		-0.022	-0.093	-0.098	-0.100
4	im		-0.022	-0.085	-0.097	-0.100
5	silt		0.000	-0.018	-0.007	-0.092
6	silt		0.000	-0.030	-0.004	-0.061
7	silt		0.000	-0.009	-0.001	-0.017
8	silt		0.000	-0.078	-0.065	-0.081
9	silt		0.000	-0.047	-0.013	-0.024
10	silt		0.000	0.000	0.000	0.000
11	silt		0.000	0.000	0.000	0.000
12	silt		-0.006	0.000	-0.038	-0.078
13	silt		0.000	0.000	0.000	-0.003
14	silt		0.000	0.000	0.000	0.000
15	silt		-0.252	-0.191	-0.203	-0.270
16	clayey sand		-0.002	0.000	0.000	-0.008
17	clayey sand		-0.020	-0.006	-0.001	-0.078
18	silty sand		-0.179	-0.138	-0.187	-0.147

ID	SEDIMEN	SELISIH KEDALAMAN (M)					
		IN-SITU	dh_200-250	dh_200-300	dh_200-350	dh_200-400	dh_250-300
19	sandy silt		-0.013	-0.023	-0.009	-0.029	-0.097
20	sandy silt		0.000	0.000	0.000	0.000	-0.133
21	clayey sand		0.000	0.000	0.000	0.000	-0.100
22	clayey sand		0.000	0.000	-0.001	-0.001	-0.066
23	sandy silt		-0.090	-0.068	-0.059	-0.073	-0.017
24	clayey sand		-0.362	-0.284	-0.323	-0.326	0.000
25	clayey sand		-0.106	-0.141	-0.125	-0.157	-0.016
26	clayey sand		0.000	0.000	0.000	0.000	-0.204
27	sandy silt		0.000	0.000	0.000	0.000	-0.100
28	clayey sand		-0.002	-0.004	-0.004	-0.002	-0.096
29	sandy silt		0.000	0.000	0.000	-0.004	-0.104
30	sandy silt		0.000	-0.033	-0.017	-0.096	-0.100
31	clayey sand		-0.058	-0.049	-0.101	-0.093	-0.008
32	clayey sand		0.000	0.000	0.000	-0.001	-0.103
33	silt		0.000	0.000	0.000	-0.004	-0.124
34	clayey sand		0.000	0.000	0.000	0.000	-0.098
35	clayey sand		-0.001	-0.005	-0.005	-0.024	-0.101
36	silt		0.000	0.000	0.000	0.000	-0.102
37	clayey sand		-0.013	-0.027	-0.012	-0.033	-0.061
38	clayey sand		0.000	0.000	0.000	-0.001	-0.093

ID	SEDIMENT IN-SITU	SELISIH KEDALAMAN (M)				
		dh_200-250	dh_200-300	dh_200-350	dh_200-400	dh_250-300
39	clayey sand	0.000	0.000	0.000	0.000	-0.063
40	clayey sand	0.000	0.000	0.000	0.000	-0.100
41	clayey sand	0.000	0.000	0.000	0.000	-0.100
42	clayey sand	0.000	0.000	0.000	0.000	-0.128
43	clayey sand	0.000	0.000	-0.005	0.000	-0.041
44	sandy silt	-0.150	-0.102	-0.236	-0.168	-0.004
45	silt	0.000	0.000	0.000	0.000	-0.038
46	silt	0.000	0.000	0.000	0.000	-0.078
47	silt	0.000	0.000	0.000	-0.003	-0.087
48	silt	-0.016	-0.093	-0.103	-0.110	-0.095
49	silt	0.000	0.000	0.000	-0.007	-0.097
50	silt	-0.002	-0.001	-0.001	-0.004	-0.001
51	silt	-0.015	-0.001	-0.076	-0.049	-0.018
52	silt	0.000	0.000	0.000	0.000	-0.202
53	silt	0.000	0.000	0.000	0.000	-0.356
54	clayey sand	0.000	0.000	0.000	0.000	-0.401
55	clayey sand	-0.064	-0.083	-0.115	-0.102	0.000
56	silt	-0.012	-0.005	-0.004	-0.017	-0.037
57	clayey sand	0.000	0.000	0.000	0.000	-0.100
58	sandy silt	0.000	0.000	0.000	0.000	-0.071

ID	SEDIMENT IN-SITU	SELISIH KEDALAMAN (M)				
		dh_200-250	dh_200-300	dh_200-350	dh_200-400	dh_250-300
59	silty sand	0.000	0.000	0.000	0.000	-0.170
60	sandy silt	-0.058	-0.046	-0.125	-0.064	-0.004
61	sandy silt	-0.001	0.000	-0.003	-0.016	-0.001
62	silty sand	0.000	-0.001	-0.001	-0.012	-0.068
63	silty sand	-0.001	-0.012	-0.005	-0.085	-0.100
64	silty sand	0.000	-0.011	-0.010	-0.015	-0.075
65	silty sand	0.000	-0.053	-0.011	-0.079	-0.085
66	silty sand	0.000	-0.001	0.000	-0.009	-0.045
67	sandy silt	0.000	0.000	0.000	0.000	-0.047
68	silty sand	-0.032	-0.098	-0.100	-0.100	-0.052
69	silty sand	-0.004	-0.068	-0.069	-0.091	-0.052
70	silty sand	-0.038	-0.089	-0.100	-0.100	-0.064
71	silty sand	-0.069	-0.086	-0.102	-0.107	-0.061
72	silty sand	0.000	0.000	0.000	0.000	-0.074
73	silty sand	-0.001	-0.001	-0.006	-0.008	-0.004
74	silty sand	0.000	0.000	0.000	0.000	-0.096

ID	SEDIMEN	SELISIH KEDALAMAN (M)					
		IN-SITU	dh 250-350	dh 250-400	dh 300-350	dh 300-400	dh 350-400
1	silt		-0.001	-0.074	0.000	0.000	0.000
2	silt		-0.064	-0.090	0.000	-0.050	0.000
3	silt		-0.056	-0.095	-0.003	-0.043	0.000
4	silt		-0.065	-0.097	-0.003	-0.057	0.000
5	silt		-0.025	-0.100	0.000	-0.015	-0.005
6	silt		-0.008	-0.099	0.000	0.000	0.000
7	silt		-0.028	-0.084	0.000	0.000	0.000
8	silt		-0.015	-0.103	0.000	0.000	0.000
9	silt		-0.011	-0.095	0.000	0.000	0.000
10	silt		-0.051	-0.093	0.000	0.000	0.000
11	silt		-0.039	-0.087	0.000	0.000	0.000
12	silt		0.000	-0.037	0.000	0.000	0.000
13	silt		-0.023	-0.053	0.000	0.000	0.000
14	silt		-0.008	-0.059	0.000	0.000	-0.028
15	silt		-0.001	-0.008	-0.001	-0.030	-0.071
16	clayey sand		0.000	-0.084	0.000	-0.040	-0.200
17	clayey sand		0.000	-0.067	0.000	-0.091	-0.244
18	silty sand		0.000	-0.006	0.000	-0.002	-0.003
19	sandy silt		-0.032	-0.118	0.000	0.000	-0.100
20	sandy silt		0.000	-0.178	0.000	0.000	-0.176

ID	SEDIMENT IN-SITU	SELISIH KEDALAMAN (M)				
		dh 250-350	dh 250-400	dh 300-350	dh 300-400	dh 350-400
21	clayey sand	-0.021	-0.100	0.000	-0.010	-0.094
22	clayey sand	-0.001	-0.094	0.000	0.000	-0.074
23	sandy silt	0.000	-0.021	0.000	-0.013	-0.092
24	clayey sand	0.000	0.000	-0.015	-0.051	-0.011
25	clayey sand	-0.002	-0.029	0.000	-0.011	-0.042
26	clayey sand	0.000	-0.213	0.000	0.000	-0.260
27	sandy silt	-0.076	-0.113	0.000	0.000	-0.072
28	clayey sand	-0.004	-0.100	0.000	0.000	-0.126
29	sandy silt	0.000	-0.189	0.000	-0.057	-0.193
30	sandy silt	-0.079	-0.159	0.000	-0.049	-0.099
31	clayey sand	-0.025	-0.039	0.000	-0.005	-0.001
32	clayey sand	-0.011	-0.108	0.000	-0.004	-0.101
33	silt	-0.014	-0.136	0.000	0.000	-0.107
34	clayey sand	0.000	-0.140	0.000	-0.009	-0.140
35	clayey sand	-0.062	-0.116	0.000	-0.013	-0.095
36	silt	0.000	-0.156	0.000	-0.025	-0.154
37	clayey sand	0.000	-0.061	0.000	0.000	-0.042
38	clayey sand	0.000	-0.090	0.000	0.000	-0.177
39	clayey sand	-0.062	-0.015	0.000	0.000	0.000
40	clayey sand	-0.100	-0.096	0.000	0.000	0.000

ID	SEDIMENT IN-SITU	SELISIH KEDALAMAN (M)				
		dh 250-350	dh 250-400	dh 300-350	dh 300-400	dh 350-400
41	clayey sand	-0.101	-0.062	0.000	0.000	0.000
42	clayey sand	-0.091	-0.092	0.000	0.000	0.000
43	clayey sand	-0.100	-0.023	-0.028	0.000	0.000
44	sandy silt	-0.100	-0.008	-0.100	0.000	0.000
45	silt	-0.002	-0.095	0.000	0.000	-0.005
46	silt	-0.043	-0.086	0.000	0.000	0.000
47	silt	-0.006	-0.095	0.000	0.000	0.000
48	silt	-0.050	-0.100	0.000	-0.011	-0.006
49	silt	-0.011	-0.099	0.000	-0.012	-0.055
50	silt	-0.001	-0.012	0.000	0.000	0.000
51	silt	-0.016	-0.050	0.000	0.000	-0.006
52	silt	-0.036	-0.111	0.000	0.000	-0.100
53	silt	-0.100	-0.208	0.000	0.000	-0.100
54	clayey sand	-0.099	-0.218	0.000	0.000	-0.117
55	clayey sand	-0.073	0.000	-0.046	0.000	0.000
56	silt	0.000	-0.055	0.000	0.000	-0.100
57	clayey sand	-0.031	-0.100	0.000	0.000	-0.039
58	sandy silt	-0.003	-0.079	0.000	-0.003	-0.062
59	silty sand	-0.045	-0.158	0.000	0.000	-0.078
60	sandy silt	-0.101	-0.004	-0.082	0.000	0.000

ID	SEDIMENT IN-SITU	SELISIH KEDALAMAN (M)				
		dh 250-350	dh 250-400	dh 300-350	dh 300-400	dh 350-400
61	sandy silt	0.000	-0.005	0.000	0.000	0.000
62	silty sand	-0.006	-0.102	0.000	0.000	0.000
63	silty sand	-0.026	-0.100	0.000	-0.017	-0.011
64	silty sand	-0.058	-0.096	0.000	0.000	0.000
65	silty sand	-0.014	-0.100	0.000	0.000	0.000
66	silty sand	-0.002	-0.079	0.000	0.000	0.000
67	sandy silt	-0.007	-0.092	0.000	0.000	-0.002
68	silty sand	-0.046	-0.092	0.000	-0.032	0.000
69	silty sand	-0.022	-0.097	0.000	-0.001	0.000
70	silty sand	-0.070	-0.090	-0.001	-0.058	0.000
71	silty sand	-0.080	-0.086	0.000	-0.070	0.000
72	silty sand	-0.046	-0.090	0.000	0.000	0.000
73	silty sand	-0.006	-0.075	0.000	0.000	-0.062
74	silty sand	-0.003	-0.096	0.000	0.000	0.000

## LAMPIRAN F

### LIST CODING

```
import numpy as np
import pandas as pd
from keras.utils import to_categorical
from sklearn.preprocessing import StandardScaler
from google.colab import drive
drive.mount('/content/drive')

dt_train = pd.read_csv(r"/content/drive/MyDrive/TUGAS
AKHIR/BSFITURBSHDHFITURH.csv")
# Index data
test_indices = [0, 3, 5, 9, 13, 16, 20, 24, 28, 31, 34, 38,
42, 46, 49, 52, 55, 58, 61, 65, 68, 72]
train_indices = [i for i in range(74) if i not in
test_indices]
#0, 1, 5, 20, 23, 26, 28, 30, 33, 37, 38, 47, 60, 63, 64, 68
#0, 1, 5, 23, 32, 33, 37, 38, 47, 63, 64, 68
#0, 1, 5, 23, 26, 28, 33, 37, 38, 60, 63, 64
#testing 30% = 0, 3, 5, 9, 13, 16, 20, 24, 28, 31, 34, 38, 42,
46, 49, 52, 55, 58, 61, 65, 68, 72
# Split data
train_data = dt_train.iloc[train_indices]
test_data = dt_train.iloc[test_indices]

# Split label
x_train1 = train_data.drop('JENIS', axis=1)
y_train1 = train_data['JENIS']

# Split test
x_test1 = test_data.drop('JENIS', axis=1)
y_test1 = test_data['JENIS']

# split y
y_train = to_categorical(y_train1, num_classes=4)
y_test = to_categorical(y_test1, num_classes=4)

#Normalizing
sc = StandardScaler()
x_train=sc.fit_transform(x_train1)
x_test=sc.fit_transform(x_test1)
```

```

import keras
import tensorflow as tf
from keras.models import Sequential
from keras.layers import Dense, Dropout, BatchNormalization
from keras.callbacks import EarlyStopping, ModelCheckpoint
from keras.regularizers import l2
from keras.optimizers import Adam
from keras.losses import binary_crossentropy,
categorical_crossentropy

# create model
model = Sequential()

# input layer
model.add(Dense(units=70, input_dim=70))

# hidden layer
for _ in range(5):
    model.add(Dense(units=75, activation='relu',
kernel_regularizer=l2(0.01)))

#model.add(BatchNormalization())
#model.add(Dropout(0.01))
#kernel_regularizer=l2(0.01)
# output layer
model.add(Dense(units=4, activation='softmax'))

#model checkpointer
checkpoint_train =
ModelCheckpoint(filepath='model_train.hdf5',
monitor='accuracy', verbose=2, save_best_only=True,
mode='max')
checkpoint_test = ModelCheckpoint(filepath='model_test.hdf5',
monitor='val_accuracy', verbose=2, save_best_only=True,
mode='max')
# Variasi Hyperparameter
learning_rate = 0.0001
batch_size = 4
epochs = 300
optimizer = Adam(learning_rate=learning_rate)

# Mengkompilasi dan melatih model
model.compile(loss='categorical_crossentropy',
optimizer=optimizer, metrics=['accuracy'])

#validation data

```

```

print('The validation data')
training2 = model.fit(x_train, y_train,
validation_data=(x_test, y_test), epochs=epochs,
batch_size=batch_size,
callbacks=[checkpoint_train,checkpoint_test])

```

The validation data

Epoch 1/300

- 1/13 [=>.....] - ETA: 16s - loss: 4.9714 - accuracy: 0.5000

Epoch 1: accuracy improved from -inf to 0.19231, saving model to model\_train.hdf5

Epoch 1: val\_accuracy improved from -inf to 0.18182, saving model to model\_test.hdf5

- 13/13 [=====] - 2s 30ms/step - loss: 5.0903 - accuracy: 0.1923 - val\_loss: 5.0749 - val\_accuracy: 0.1818

Epoch 2/300

- 1/13 [=>.....] - ETA: 0s - loss: 5.0247 - accuracy: 0.5000

Epoch 2: accuracy improved from 0.19231 to 0.44231, saving model to model\_train.hdf5

Epoch 2: val\_accuracy improved from 0.18182 to 0.27273, saving model to model\_test.hdf5

- 13/13 [=====] - 0s 12ms/step - loss: 5.0161 - accuracy: 0.4423 - val\_loss: 5.0239 - val\_accuracy: 0.2727

Epoch 3/300

- 1/13 [=>.....] - ETA: 0s - loss: 4.8903 - accuracy: 1.0000

Epoch 3: accuracy improved from 0.44231 to 0.48077, saving model to model\_train.hdf5

Epoch 3: val\_accuracy improved from 0.27273 to 0.31818, saving model to model\_test.hdf5

- 13/13 [=====] - 0s 13ms/step - loss: 4.9548 - accuracy: 0.4808 - val\_loss: 4.9745 - val\_accuracy: 0.3182

Epoch 4/300

- 1/13 [=>.....] - ETA: 0s - loss: 5.0276 - accuracy: 0.2500

Epoch 4: accuracy improved from 0.48077 to 0.51923, saving model to model\_train.hdf5

Epoch 4: val\_accuracy did not improve from 0.31818

- 13/13 [=====] - 0s 10ms/step - loss: 4.8936 - accuracy: 0.5192 - val\_loss: 4.9275 - val\_accuracy: 0.3182

Epoch 5/300

- 1/13 [=>.....] - ETA: 0s - loss: 4.9141 - accuracy: 0.7500

```
Epoch 5: accuracy improved from 0.51923 to 0.57692, saving
model to model_train.hdf5

Epoch 5: val_accuracy improved from 0.31818 to 0.40909, saving
model to model_test.hdf5
13/13 [=====] - 0s 12ms/step - loss:
4.8320 - accuracy: 0.5769 - val_loss: 4.8820 - val_accuracy:
0.4091
Epoch 6/300
1/13 [=>.....] - ETA: 0s - loss:
4.7666 - accuracy: 0.7500
Epoch 6: accuracy improved from 0.57692 to 0.63462, saving
model to model_train.hdf5

Epoch 6: val_accuracy did not improve from 0.40909
13/13 [=====] - 0s 9ms/step - loss:
4.7757 - accuracy: 0.6346 - val_loss: 4.8357 - val_accuracy:
0.4091
Epoch 7/300
1/13 [=>.....] - ETA: 0s - loss:
4.7908 - accuracy: 1.0000
Epoch 7: accuracy did not improve from 0.63462

Epoch 7: val_accuracy did not improve from 0.40909
13/13 [=====] - 0s 7ms/step - loss:
4.7153 - accuracy: 0.6154 - val_loss: 4.7928 - val_accuracy:
0.4091
Epoch 8/300
1/13 [=>.....] - ETA: 0s - loss:
4.8984 - accuracy: 0.2500
Epoch 8: accuracy did not improve from 0.63462

Epoch 8: val_accuracy did not improve from 0.40909
13/13 [=====] - 0s 7ms/step - loss:
4.6583 - accuracy: 0.6154 - val_loss: 4.7533 - val_accuracy:
0.4091
Epoch 9/300
1/13 [=>.....] - ETA: 0s - loss:
4.7408 - accuracy: 0.7500
Epoch 9: accuracy improved from 0.63462 to 0.65385, saving
model to model_train.hdf5

Epoch 9: val_accuracy improved from 0.40909 to 0.50000, saving
model to model_test.hdf5
13/13 [=====] - 0s 12ms/step - loss:
4.6011 - accuracy: 0.6538 - val_loss: 4.7080 - val_accuracy:
0.5000
Epoch 10/300
1/13 [=>.....] - ETA: 0s - loss:
4.4186 - accuracy: 0.7500
Epoch 10: accuracy improved from 0.65385 to 0.69231, saving
model to model_train.hdf5

Epoch 10: val_accuracy improved from 0.50000 to 0.59091,
saving model to model_test.hdf5
```

```

13/13 [=====] - 0s 12ms/step - loss:
4.5436 - accuracy: 0.6923 - val_loss: 4.6691 - val_accuracy:
0.5909
Epoch 11/300
1/13 [=>.....] - ETA: 0s - loss:
4.4283 - accuracy: 0.7500
Epoch 11: accuracy did not improve from 0.69231

Epoch 11: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 6ms/step - loss:
4.4875 - accuracy: 0.6731 - val_loss: 4.6319 - val_accuracy:
0.5000
Epoch 12/300
1/13 [=>.....] - ETA: 0s - loss:
4.4809 - accuracy: 0.7500
Epoch 12: accuracy did not improve from 0.69231

Epoch 12: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 7ms/step - loss:
4.4274 - accuracy: 0.6923 - val_loss: 4.5947 - val_accuracy:
0.5000
Epoch 13/300
1/13 [=>.....] - ETA: 0s - loss:
4.2301 - accuracy: 1.0000
Epoch 13: accuracy did not improve from 0.69231

Epoch 13: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 7ms/step - loss:
4.3722 - accuracy: 0.6923 - val_loss: 4.5569 - val_accuracy:
0.5000
Epoch 14/300
1/13 [=>.....] - ETA: 0s - loss:
4.3182 - accuracy: 0.7500
Epoch 14: accuracy improved from 0.69231 to 0.71154, saving
model to model_train.hdf5

Epoch 14: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
4.3145 - accuracy: 0.7115 - val_loss: 4.5265 - val_accuracy:
0.5455
Epoch 15/300
1/13 [=>.....] - ETA: 0s - loss:
4.2847 - accuracy: 0.7500
Epoch 15: accuracy did not improve from 0.71154

Epoch 15: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 7ms/step - loss:
4.2596 - accuracy: 0.7115 - val_loss: 4.4914 - val_accuracy:
0.5455
Epoch 16/300
1/13 [=>.....] - ETA: 0s - loss:
4.4259 - accuracy: 0.2500
Epoch 16: accuracy improved from 0.71154 to 0.73077, saving
model to model_train.hdf5

```

```
Epoch 16: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss:
4.2023 - accuracy: 0.7308 - val_loss: 4.4636 - val_accuracy:
0.5000
Epoch 17/300
1/13 [=>.....] - ETA: 0s - loss:
4.1707 - accuracy: 0.2500
Epoch 17: accuracy improved from 0.73077 to 0.75000, saving
model to model_train.hdf5

Epoch 17: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
4.1454 - accuracy: 0.7500 - val_loss: 4.4364 - val_accuracy:
0.5000
Epoch 18/300
1/13 [=>.....] - ETA: 0s - loss:
3.8596 - accuracy: 1.0000
Epoch 18: accuracy improved from 0.75000 to 0.76923, saving
model to model_train.hdf5

Epoch 18: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss:
4.0909 - accuracy: 0.7692 - val_loss: 4.4069 - val_accuracy:
0.5000
Epoch 19/300
1/13 [=>.....] - ETA: 0s - loss:
3.9197 - accuracy: 1.0000
Epoch 19: accuracy did not improve from 0.76923

Epoch 19: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 6ms/step - loss:
4.0398 - accuracy: 0.7692 - val_loss: 4.3785 - val_accuracy:
0.5000
Epoch 20/300
1/13 [=>.....] - ETA: 0s - loss:
3.8260 - accuracy: 0.7500
Epoch 20: accuracy did not improve from 0.76923

Epoch 20: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 7ms/step - loss:
3.9877 - accuracy: 0.7692 - val_loss: 4.3634 - val_accuracy:
0.5000
Epoch 21/300
1/13 [=>.....] - ETA: 0s - loss:
4.0985 - accuracy: 0.7500
Epoch 21: accuracy did not improve from 0.76923

Epoch 21: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
3.9384 - accuracy: 0.7692 - val_loss: 4.3463 - val_accuracy:
0.5000
Epoch 22/300
12/13 [=====>...] - ETA: 0s - loss:
3.9008 - accuracy: 0.7500
Epoch 22: accuracy did not improve from 0.76923
```

```
Epoch 22: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 11ms/step - loss: 3.8856 - accuracy: 0.7500 - val_loss: 4.3241 - val_accuracy: 0.5000
Epoch 23/300
1/13 [=>.....] - ETA: 0s - loss: 3.7993 - accuracy: 0.7500
Epoch 23: accuracy did not improve from 0.76923

Epoch 23: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss: 3.8407 - accuracy: 0.7500 - val_loss: 4.3095 - val_accuracy: 0.5000
Epoch 24/300
1/13 [=>.....] - ETA: 0s - loss: 3.8010 - accuracy: 0.7500
Epoch 24: accuracy did not improve from 0.76923

Epoch 24: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss: 3.7926 - accuracy: 0.7692 - val_loss: 4.2960 - val_accuracy: 0.5000
Epoch 25/300
1/13 [=>.....] - ETA: 0s - loss: 3.6801 - accuracy: 0.7500
Epoch 25: accuracy improved from 0.76923 to 0.78846, saving model to model_train.hdf5

Epoch 25: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 14ms/step - loss: 3.7515 - accuracy: 0.7885 - val_loss: 4.2806 - val_accuracy: 0.5000
Epoch 26/300
13/13 [=====] - ETA: 0s - loss: 3.7014 - accuracy: 0.7885
Epoch 26: accuracy did not improve from 0.78846

Epoch 26: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss: 3.7014 - accuracy: 0.7885 - val_loss: 4.2735 - val_accuracy: 0.5000
Epoch 27/300
13/13 [=====] - ETA: 0s - loss: 3.6608 - accuracy: 0.7885
Epoch 27: accuracy did not improve from 0.78846

Epoch 27: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss: 3.6608 - accuracy: 0.7885 - val_loss: 4.2670 - val_accuracy: 0.5000
Epoch 28/300
1/13 [=>.....] - ETA: 0s - loss: 3.8091 - accuracy: 0.7500
```

```
Epoch 28: accuracy improved from 0.78846 to 0.80769, saving
model to model_train.hdf5

Epoch 28: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 12ms/step - loss:
3.6167 - accuracy: 0.8077 - val_loss: 4.2625 - val_accuracy:
0.5000
Epoch 29/300
13/13 [=====] - ETA: 0s - loss:
3.5775 - accuracy: 0.8077
Epoch 29: accuracy did not improve from 0.80769

Epoch 29: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss:
3.5775 - accuracy: 0.8077 - val_loss: 4.2544 - val_accuracy:
0.5000
Epoch 30/300
1/13 [=>.....] - ETA: 0s - loss:
3.3527 - accuracy: 1.0000
Epoch 30: accuracy improved from 0.80769 to 0.82692, saving
model to model_train.hdf5

Epoch 30: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 12ms/step - loss:
3.5313 - accuracy: 0.8269 - val_loss: 4.2464 - val_accuracy:
0.4091
Epoch 31/300
1/13 [=>.....] - ETA: 0s - loss:
3.3237 - accuracy: 1.0000
Epoch 31: accuracy improved from 0.82692 to 0.86538, saving
model to model_train.hdf5

Epoch 31: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 12ms/step - loss:
3.4947 - accuracy: 0.8654 - val_loss: 4.2456 - val_accuracy:
0.4091
Epoch 32/300
1/13 [=>.....] - ETA: 0s - loss:
3.2519 - accuracy: 0.7500
Epoch 32: accuracy did not improve from 0.86538

Epoch 32: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 11ms/step - loss:
3.4563 - accuracy: 0.8654 - val_loss: 4.2422 - val_accuracy:
0.4091
Epoch 33/300
1/13 [=>.....] - ETA: 0s - loss:
3.4019 - accuracy: 1.0000
Epoch 33: accuracy did not improve from 0.86538

Epoch 33: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
3.4187 - accuracy: 0.8654 - val_loss: 4.2368 - val_accuracy:
0.4091
Epoch 34/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
3.4211 - accuracy: 1.0000  
Epoch 34: accuracy did not improve from 0.86538  
  
Epoch 34: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
3.3844 - accuracy: 0.8654 - val_loss: 4.2434 - val_accuracy:  
0.3636  
Epoch 35/300  
1/13 [=>.....] - ETA: 0s - loss:  
3.3961 - accuracy: 1.0000  
Epoch 35: accuracy did not improve from 0.86538  
  
Epoch 35: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
3.3453 - accuracy: 0.8654 - val_loss: 4.2447 - val_accuracy:  
0.3636  
Epoch 36/300  
1/13 [=>.....] - ETA: 0s - loss:  
3.1898 - accuracy: 1.0000  
Epoch 36: accuracy improved from 0.86538 to 0.88462, saving  
model to model_train.hdf5  
  
Epoch 36: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
3.3110 - accuracy: 0.8846 - val_loss: 4.2396 - val_accuracy:  
0.3636  
Epoch 37/300  
1/13 [=>.....] - ETA: 0s - loss:  
3.3203 - accuracy: 0.7500  
Epoch 37: accuracy did not improve from 0.88462  
  
Epoch 37: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
3.2764 - accuracy: 0.8846 - val_loss: 4.2414 - val_accuracy:  
0.3636  
Epoch 38/300  
1/13 [=>.....] - ETA: 0s - loss:  
3.3190 - accuracy: 0.7500  
Epoch 38: accuracy did not improve from 0.88462  
  
Epoch 38: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
3.2434 - accuracy: 0.8846 - val_loss: 4.2548 - val_accuracy:  
0.3636  
Epoch 39/300  
1/13 [=>.....] - ETA: 0s - loss:  
3.2813 - accuracy: 1.0000  
Epoch 39: accuracy improved from 0.88462 to 0.92308, saving  
model to model_train.hdf5  
  
Epoch 39: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 13ms/step - loss:  
3.2110 - accuracy: 0.9231 - val_loss: 4.2674 - val_accuracy:  
0.3636
```

```

Epoch 40/300
 1/13 [=>.....] - ETA: 0s - loss:
3.2775 - accuracy: 1.0000
Epoch 40: accuracy did not improve from 0.92308

Epoch 40: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
3.1781 - accuracy: 0.9231 - val_loss: 4.2736 - val_accuracy:
0.3636
Epoch 41/300
13/13 [=====] - ETA: 0s - loss:
3.1444 - accuracy: 0.9231
Epoch 41: accuracy did not improve from 0.92308

Epoch 41: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss:
3.1444 - accuracy: 0.9231 - val_loss: 4.2675 - val_accuracy:
0.3636
Epoch 42/300
11/13 [=====>....] - ETA: 0s - loss:
3.1498 - accuracy: 0.9318
Epoch 42: accuracy improved from 0.92308 to 0.94231, saving
model to model_train.hdf5

Epoch 42: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 15ms/step - loss:
3.1135 - accuracy: 0.9423 - val_loss: 4.2853 - val_accuracy:
0.3636
Epoch 43/300
12/13 [=====>...] - ETA: 0s - loss:
3.0615 - accuracy: 0.9583
Epoch 43: accuracy did not improve from 0.94231

Epoch 43: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss:
3.0826 - accuracy: 0.9423 - val_loss: 4.2938 - val_accuracy:
0.3636
Epoch 44/300
 1/13 [=>.....] - ETA: 0s - loss:
3.2394 - accuracy: 0.7500
Epoch 44: accuracy did not improve from 0.94231

Epoch 44: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 8ms/step - loss:
3.0529 - accuracy: 0.9423 - val_loss: 4.2957 - val_accuracy:
0.3182
Epoch 45/300
 1/13 [=>.....] - ETA: 0s - loss:
2.8055 - accuracy: 1.0000
Epoch 45: accuracy did not improve from 0.94231

Epoch 45: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
3.0241 - accuracy: 0.9231 - val_loss: 4.3060 - val_accuracy:
0.3182

```

```
Epoch 46/300
 1/13 [=>.....] - ETA: 0s - loss:
 3.2313 - accuracy: 0.7500
Epoch 46: accuracy did not improve from 0.94231

Epoch 46: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
 2.9983 - accuracy: 0.9423 - val_loss: 4.3142 - val_accuracy:
 0.3182
Epoch 47/300
 1/13 [=>.....] - ETA: 0s - loss:
 3.3746 - accuracy: 0.7500
Epoch 47: accuracy did not improve from 0.94231

Epoch 47: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
 2.9699 - accuracy: 0.9423 - val_loss: 4.3246 - val_accuracy:
 0.3182
Epoch 48/300
 1/13 [=>.....] - ETA: 0s - loss:
 2.9675 - accuracy: 1.0000
Epoch 48: accuracy did not improve from 0.94231

Epoch 48: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
 2.9399 - accuracy: 0.9423 - val_loss: 4.3387 - val_accuracy:
 0.3182
Epoch 49/300
 13/13 [=====] - ETA: 0s - loss:
 2.9138 - accuracy: 0.9423
Epoch 49: accuracy did not improve from 0.94231

Epoch 49: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss:
 2.9138 - accuracy: 0.9423 - val_loss: 4.3500 - val_accuracy:
 0.3182
Epoch 50/300
 13/13 [=====] - ETA: 0s - loss:
 2.8887 - accuracy: 0.9423
Epoch 50: accuracy did not improve from 0.94231

Epoch 50: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss:
 2.8887 - accuracy: 0.9423 - val_loss: 4.3554 - val_accuracy:
 0.3182
Epoch 51/300
 1/13 [=>.....] - ETA: 0s - loss:
 2.7930 - accuracy: 1.0000
Epoch 51: accuracy did not improve from 0.94231

Epoch 51: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
 2.8622 - accuracy: 0.9423 - val_loss: 4.3711 - val_accuracy:
 0.3182
Epoch 52/300
```

```

12/13 [=====>...] - ETA: 0s - loss:
2.8228 - accuracy: 0.9583
Epoch 52: accuracy did not improve from 0.94231

Epoch 52: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 11ms/step - loss:
2.8387 - accuracy: 0.9423 - val_loss: 4.3925 - val_accuracy:
0.3182
Epoch 53/300
1/13 [=>.....] - ETA: 0s - loss:
2.8880 - accuracy: 0.7500
Epoch 53: accuracy did not improve from 0.94231

Epoch 53: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 8ms/step - loss:
2.8136 - accuracy: 0.9423 - val_loss: 4.3813 - val_accuracy:
0.3182
Epoch 54/300
1/13 [=>.....] - ETA: 0s - loss:
2.6848 - accuracy: 1.0000
Epoch 54: accuracy did not improve from 0.94231

Epoch 54: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
2.7893 - accuracy: 0.9423 - val_loss: 4.3948 - val_accuracy:
0.3182
Epoch 55/300
1/13 [=>.....] - ETA: 0s - loss:
2.7938 - accuracy: 1.0000
Epoch 55: accuracy did not improve from 0.94231

Epoch 55: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
2.7659 - accuracy: 0.9423 - val_loss: 4.4027 - val_accuracy:
0.3182
Epoch 56/300
1/13 [=>.....] - ETA: 0s - loss:
2.6649 - accuracy: 1.0000
Epoch 56: accuracy improved from 0.94231 to 0.96154, saving
model to model_train.hdf5

Epoch 56: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 14ms/step - loss:
2.7413 - accuracy: 0.9615 - val_loss: 4.4146 - val_accuracy:
0.3182
Epoch 57/300
1/13 [=>.....] - ETA: 0s - loss:
2.6060 - accuracy: 1.0000
Epoch 57: accuracy did not improve from 0.96154

Epoch 57: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
2.7203 - accuracy: 0.9615 - val_loss: 4.4225 - val_accuracy:
0.3182
Epoch 58/300

```

```
13/13 [=====] - ETA: 0s - loss:  
2.6978 - accuracy: 0.9615  
Epoch 58: accuracy did not improve from 0.96154  
  
Epoch 58: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
2.6978 - accuracy: 0.9615 - val_loss: 4.4367 - val_accuracy:  
0.3182  
Epoch 59/300  
11/13 [=====>.....] - ETA: 0s - loss:  
2.6869 - accuracy: 0.9545  
Epoch 59: accuracy did not improve from 0.96154  
  
Epoch 59: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
2.6764 - accuracy: 0.9615 - val_loss: 4.4383 - val_accuracy:  
0.3182  
Epoch 60/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.6478 - accuracy: 1.0000  
Epoch 60: accuracy did not improve from 0.96154  
  
Epoch 60: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
2.6578 - accuracy: 0.9615 - val_loss: 4.4489 - val_accuracy:  
0.3182  
Epoch 61/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.8525 - accuracy: 0.7500  
Epoch 61: accuracy did not improve from 0.96154  
  
Epoch 61: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
2.6378 - accuracy: 0.9615 - val_loss: 4.4535 - val_accuracy:  
0.3182  
Epoch 62/300  
10/13 [=====>.....] - ETA: 0s - loss:  
2.6192 - accuracy: 0.9750  
Epoch 62: accuracy did not improve from 0.96154  
  
Epoch 62: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
2.6186 - accuracy: 0.9615 - val_loss: 4.4633 - val_accuracy:  
0.3182  
Epoch 63/300  
11/13 [=====>.....] - ETA: 0s - loss:  
2.6074 - accuracy: 0.9545  
Epoch 63: accuracy did not improve from 0.96154  
  
Epoch 63: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
2.5947 - accuracy: 0.9615 - val_loss: 4.4693 - val_accuracy:  
0.3182  
Epoch 64/300
```

```

13/13 [=====] - ETA: 0s - loss:
2.5771 - accuracy: 0.9615
Epoch 64: accuracy did not improve from 0.96154

Epoch 64: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss:
2.5771 - accuracy: 0.9615 - val_loss: 4.4856 - val_accuracy:
0.3182
Epoch 65/300
9/13 [=====>.....] - ETA: 0s - loss:
2.5680 - accuracy: 0.9722
Epoch 65: accuracy did not improve from 0.96154

Epoch 65: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 11ms/step - loss:
2.5567 - accuracy: 0.9615 - val_loss: 4.4788 - val_accuracy:
0.3182
Epoch 66/300
12/13 [=====>...] - ETA: 0s - loss:
2.5363 - accuracy: 0.9583
Epoch 66: accuracy did not improve from 0.96154

Epoch 66: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss:
2.5386 - accuracy: 0.9615 - val_loss: 4.4798 - val_accuracy:
0.3182
Epoch 67/300
1/13 [=>.....] - ETA: 0s - loss:
2.6042 - accuracy: 1.0000
Epoch 67: accuracy improved from 0.96154 to 0.98077, saving
model to model_train.hdf5

Epoch 67: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 13ms/step - loss:
2.5195 - accuracy: 0.9808 - val_loss: 4.4823 - val_accuracy:
0.3182
Epoch 68/300
1/13 [=>.....] - ETA: 0s - loss:
2.5759 - accuracy: 1.0000
Epoch 68: accuracy did not improve from 0.98077

Epoch 68: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
2.5012 - accuracy: 0.9808 - val_loss: 4.4989 - val_accuracy:
0.3182
Epoch 69/300
1/13 [=>.....] - ETA: 0s - loss:
2.4224 - accuracy: 1.0000
Epoch 69: accuracy did not improve from 0.98077

Epoch 69: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 6ms/step - loss:
2.4837 - accuracy: 0.9808 - val_loss: 4.4956 - val_accuracy:
0.3182
Epoch 70/300

```

```
1/13 [=>.....] - ETA: 0s - loss:  
2.4564 - accuracy: 1.0000  
Epoch 70: accuracy did not improve from 0.98077  
  
Epoch 70: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.4659 - accuracy: 0.9808 - val_loss: 4.5011 - val_accuracy:  
0.3182  
Epoch 71/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.4158 - accuracy: 1.0000  
Epoch 71: accuracy did not improve from 0.98077  
  
Epoch 71: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.4488 - accuracy: 0.9808 - val_loss: 4.5054 - val_accuracy:  
0.3182  
Epoch 72/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.4877 - accuracy: 1.0000  
Epoch 72: accuracy did not improve from 0.98077  
  
Epoch 72: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.4321 - accuracy: 0.9808 - val_loss: 4.5107 - val_accuracy:  
0.3182  
Epoch 73/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.4177 - accuracy: 1.0000  
Epoch 73: accuracy did not improve from 0.98077  
  
Epoch 73: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 5ms/step - loss:  
2.4156 - accuracy: 0.9808 - val_loss: 4.5076 - val_accuracy:  
0.3636  
Epoch 74/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.3704 - accuracy: 1.0000  
Epoch 74: accuracy did not improve from 0.98077  
  
Epoch 74: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.3988 - accuracy: 0.9808 - val_loss: 4.5087 - val_accuracy:  
0.3182  
Epoch 75/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.4340 - accuracy: 1.0000  
Epoch 75: accuracy did not improve from 0.98077  
  
Epoch 75: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
2.3818 - accuracy: 0.9808 - val_loss: 4.5222 - val_accuracy:  
0.3182  
Epoch 76/300
```

```

1/13 [=>.....] - ETA: 0s - loss:
2.4500 - accuracy: 1.0000
Epoch 76: accuracy did not improve from 0.98077

Epoch 76: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 6ms/step - loss:
2.3673 - accuracy: 0.9808 - val_loss: 4.5106 - val_accuracy:
0.3636
Epoch 77/300
1/13 [=>.....] - ETA: 0s - loss:
2.2918 - accuracy: 1.0000
Epoch 77: accuracy did not improve from 0.98077

Epoch 77: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 6ms/step - loss:
2.3498 - accuracy: 0.9808 - val_loss: 4.5199 - val_accuracy:
0.3182
Epoch 78/300
1/13 [=>.....] - ETA: 0s - loss:
2.3186 - accuracy: 1.0000
Epoch 78: accuracy did not improve from 0.98077

Epoch 78: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 6ms/step - loss:
2.3346 - accuracy: 0.9808 - val_loss: 4.5327 - val_accuracy:
0.3636
Epoch 79/300
1/13 [=>.....] - ETA: 0s - loss:
2.3146 - accuracy: 1.0000
Epoch 79: accuracy did not improve from 0.98077

Epoch 79: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 6ms/step - loss:
2.3190 - accuracy: 0.9808 - val_loss: 4.5165 - val_accuracy:
0.3636
Epoch 80/300
1/13 [=>.....] - ETA: 0s - loss:
2.2687 - accuracy: 1.0000
Epoch 80: accuracy improved from 0.98077 to 1.00000, saving
model to model_train.hdf5

Epoch 80: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
2.3021 - accuracy: 1.0000 - val_loss: 4.5218 - val_accuracy:
0.3636
Epoch 81/300
1/13 [=>.....] - ETA: 0s - loss:
2.3216 - accuracy: 1.0000
Epoch 81: accuracy did not improve from 1.00000

Epoch 81: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 6ms/step - loss:
2.2866 - accuracy: 0.9808 - val_loss: 4.5332 - val_accuracy:
0.3182
Epoch 82/300

```

```
1/13 [=>.....] - ETA: 0s - loss:  
2.2215 - accuracy: 1.0000  
Epoch 82: accuracy did not improve from 1.00000  
  
Epoch 82: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
2.2709 - accuracy: 1.0000 - val_loss: 4.5326 - val_accuracy:  
0.3636  
Epoch 83/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.2409 - accuracy: 1.0000  
Epoch 83: accuracy did not improve from 1.00000  
  
Epoch 83: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
2.2571 - accuracy: 1.0000 - val_loss: 4.5322 - val_accuracy:  
0.3182  
Epoch 84/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.2143 - accuracy: 1.0000  
Epoch 84: accuracy did not improve from 1.00000  
  
Epoch 84: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.2410 - accuracy: 1.0000 - val_loss: 4.5272 - val_accuracy:  
0.3636  
Epoch 85/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.1771 - accuracy: 1.0000  
Epoch 85: accuracy did not improve from 1.00000  
  
Epoch 85: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.2264 - accuracy: 1.0000 - val_loss: 4.5330 - val_accuracy:  
0.3636  
Epoch 86/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.2643 - accuracy: 1.0000  
Epoch 86: accuracy did not improve from 1.00000  
  
Epoch 86: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
2.2116 - accuracy: 1.0000 - val_loss: 4.5259 - val_accuracy:  
0.3636  
Epoch 87/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.2201 - accuracy: 1.0000  
Epoch 87: accuracy did not improve from 1.00000  
  
Epoch 87: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.1969 - accuracy: 1.0000 - val_loss: 4.5228 - val_accuracy:  
0.3636  
Epoch 88/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
2.2292 - accuracy: 1.0000  
Epoch 88: accuracy did not improve from 1.00000  
  
Epoch 88: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.1826 - accuracy: 1.0000 - val_loss: 4.5203 - val_accuracy:  
0.3636  
Epoch 89/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.1347 - accuracy: 1.0000  
Epoch 89: accuracy did not improve from 1.00000  
  
Epoch 89: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.1678 - accuracy: 1.0000 - val_loss: 4.5160 - val_accuracy:  
0.3636  
Epoch 90/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.2438 - accuracy: 1.0000  
Epoch 90: accuracy did not improve from 1.00000  
  
Epoch 90: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.1548 - accuracy: 1.0000 - val_loss: 4.5169 - val_accuracy:  
0.3636  
Epoch 91/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.1518 - accuracy: 1.0000  
Epoch 91: accuracy did not improve from 1.00000  
  
Epoch 91: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
2.1395 - accuracy: 1.0000 - val_loss: 4.5074 - val_accuracy:  
0.3636  
Epoch 92/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.1736 - accuracy: 1.0000  
Epoch 92: accuracy did not improve from 1.00000  
  
Epoch 92: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.1270 - accuracy: 1.0000 - val_loss: 4.5112 - val_accuracy:  
0.3636  
Epoch 93/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.0953 - accuracy: 1.0000  
Epoch 93: accuracy did not improve from 1.00000  
  
Epoch 93: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.1117 - accuracy: 1.0000 - val_loss: 4.5076 - val_accuracy:  
0.3636  
Epoch 94/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
2.0654 - accuracy: 1.0000  
Epoch 94: accuracy did not improve from 1.00000  
  
Epoch 94: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
2.0984 - accuracy: 1.0000 - val_loss: 4.5097 - val_accuracy:  
0.3636  
Epoch 95/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.1051 - accuracy: 1.0000  
Epoch 95: accuracy did not improve from 1.00000  
  
Epoch 95: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
2.0844 - accuracy: 1.0000 - val_loss: 4.5037 - val_accuracy:  
0.3636  
Epoch 96/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.0507 - accuracy: 1.0000  
Epoch 96: accuracy did not improve from 1.00000  
  
Epoch 96: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.0706 - accuracy: 1.0000 - val_loss: 4.5008 - val_accuracy:  
0.3636  
Epoch 97/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.0353 - accuracy: 1.0000  
Epoch 97: accuracy did not improve from 1.00000  
  
Epoch 97: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
2.0574 - accuracy: 1.0000 - val_loss: 4.5021 - val_accuracy:  
0.3636  
Epoch 98/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.0228 - accuracy: 1.0000  
Epoch 98: accuracy did not improve from 1.00000  
  
Epoch 98: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
2.0439 - accuracy: 1.0000 - val_loss: 4.4933 - val_accuracy:  
0.3636  
Epoch 99/300  
1/13 [=>.....] - ETA: 0s - loss:  
2.0525 - accuracy: 1.0000  
Epoch 99: accuracy did not improve from 1.00000  
  
Epoch 99: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
2.0302 - accuracy: 1.0000 - val_loss: 4.4928 - val_accuracy:  
0.3636  
Epoch 100/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
2.0483 - accuracy: 1.0000  
Epoch 100: accuracy did not improve from 1.00000  
  
Epoch 100: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
2.0179 - accuracy: 1.0000 - val_loss: 4.4933 - val_accuracy:  
0.3636  
Epoch 101/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.9843 - accuracy: 1.0000  
Epoch 101: accuracy did not improve from 1.00000  
  
Epoch 101: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
2.0039 - accuracy: 1.0000 - val_loss: 4.4854 - val_accuracy:  
0.3636  
Epoch 102/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.9792 - accuracy: 1.0000  
Epoch 102: accuracy did not improve from 1.00000  
  
Epoch 102: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.9912 - accuracy: 1.0000 - val_loss: 4.4767 - val_accuracy:  
0.3636  
Epoch 103/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.9486 - accuracy: 1.0000  
Epoch 103: accuracy did not improve from 1.00000  
  
Epoch 103: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.9782 - accuracy: 1.0000 - val_loss: 4.4819 - val_accuracy:  
0.3636  
Epoch 104/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.9532 - accuracy: 1.0000  
Epoch 104: accuracy did not improve from 1.00000  
  
Epoch 104: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.9657 - accuracy: 1.0000 - val_loss: 4.4631 - val_accuracy:  
0.3636  
Epoch 105/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.9755 - accuracy: 1.0000  
Epoch 105: accuracy did not improve from 1.00000  
  
Epoch 105: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.9526 - accuracy: 1.0000 - val_loss: 4.4646 - val_accuracy:  
0.3636  
Epoch 106/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.9226 - accuracy: 1.0000  
Epoch 106: accuracy did not improve from 1.00000  
  
Epoch 106: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.9397 - accuracy: 1.0000 - val_loss: 4.4647 - val_accuracy:  
0.3636  
Epoch 107/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.9760 - accuracy: 1.0000  
Epoch 107: accuracy did not improve from 1.00000  
  
Epoch 107: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.9271 - accuracy: 1.0000 - val_loss: 4.4564 - val_accuracy:  
0.3636  
Epoch 108/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.9140 - accuracy: 1.0000  
Epoch 108: accuracy did not improve from 1.00000  
  
Epoch 108: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.9144 - accuracy: 1.0000 - val_loss: 4.4517 - val_accuracy:  
0.3636  
Epoch 109/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.8996 - accuracy: 1.0000  
Epoch 109: accuracy did not improve from 1.00000  
  
Epoch 109: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.9020 - accuracy: 1.0000 - val_loss: 4.4480 - val_accuracy:  
0.3636  
Epoch 110/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.8732 - accuracy: 1.0000  
Epoch 110: accuracy did not improve from 1.00000  
  
Epoch 110: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.8895 - accuracy: 1.0000 - val_loss: 4.4373 - val_accuracy:  
0.3636  
Epoch 111/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.8950 - accuracy: 1.0000  
Epoch 111: accuracy did not improve from 1.00000  
  
Epoch 111: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.8771 - accuracy: 1.0000 - val_loss: 4.4333 - val_accuracy:  
0.3636  
Epoch 112/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.8726 - accuracy: 1.0000  
Epoch 112: accuracy did not improve from 1.00000  
  
Epoch 112: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.8647 - accuracy: 1.0000 - val_loss: 4.4270 - val_accuracy:  
0.3636  
Epoch 113/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.8331 - accuracy: 1.0000  
Epoch 113: accuracy did not improve from 1.00000  
  
Epoch 113: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.8523 - accuracy: 1.0000 - val_loss: 4.4145 - val_accuracy:  
0.3636  
Epoch 114/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.8539 - accuracy: 1.0000  
Epoch 114: accuracy did not improve from 1.00000  
  
Epoch 114: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.8405 - accuracy: 1.0000 - val_loss: 4.4066 - val_accuracy:  
0.3636  
Epoch 115/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.8106 - accuracy: 1.0000  
Epoch 115: accuracy did not improve from 1.00000  
  
Epoch 115: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.8284 - accuracy: 1.0000 - val_loss: 4.3982 - val_accuracy:  
0.3636  
Epoch 116/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.8631 - accuracy: 1.0000  
Epoch 116: accuracy did not improve from 1.00000  
  
Epoch 116: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.8169 - accuracy: 1.0000 - val_loss: 4.3957 - val_accuracy:  
0.3636  
Epoch 117/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.8071 - accuracy: 1.0000  
Epoch 117: accuracy did not improve from 1.00000  
  
Epoch 117: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.8049 - accuracy: 1.0000 - val_loss: 4.3827 - val_accuracy:  
0.3636  
Epoch 118/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.7947 - accuracy: 1.0000  
Epoch 118: accuracy did not improve from 1.00000  
  
Epoch 118: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.7935 - accuracy: 1.0000 - val_loss: 4.3787 - val_accuracy:  
0.3636  
Epoch 119/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.7840 - accuracy: 1.0000  
Epoch 119: accuracy did not improve from 1.00000  
  
Epoch 119: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.7815 - accuracy: 1.0000 - val_loss: 4.3787 - val_accuracy:  
0.3636  
Epoch 120/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.7908 - accuracy: 1.0000  
Epoch 120: accuracy did not improve from 1.00000  
  
Epoch 120: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.7699 - accuracy: 1.0000 - val_loss: 4.3602 - val_accuracy:  
0.3636  
Epoch 121/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.7493 - accuracy: 1.0000  
Epoch 121: accuracy did not improve from 1.00000  
  
Epoch 121: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.7583 - accuracy: 1.0000 - val_loss: 4.3530 - val_accuracy:  
0.3636  
Epoch 122/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.7352 - accuracy: 1.0000  
Epoch 122: accuracy did not improve from 1.00000  
  
Epoch 122: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.7467 - accuracy: 1.0000 - val_loss: 4.3536 - val_accuracy:  
0.3636  
Epoch 123/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.7162 - accuracy: 1.0000  
Epoch 123: accuracy did not improve from 1.00000  
  
Epoch 123: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.7354 - accuracy: 1.0000 - val_loss: 4.3438 - val_accuracy:  
0.3636  
Epoch 124/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.7157 - accuracy: 1.0000  
Epoch 124: accuracy did not improve from 1.00000  
  
Epoch 124: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.7249 - accuracy: 1.0000 - val_loss: 4.3220 - val_accuracy:  
0.3636  
Epoch 125/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.6930 - accuracy: 1.0000  
Epoch 125: accuracy did not improve from 1.00000  
  
Epoch 125: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.7128 - accuracy: 1.0000 - val_loss: 4.3251 - val_accuracy:  
0.3636  
Epoch 126/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.6938 - accuracy: 1.0000  
Epoch 126: accuracy did not improve from 1.00000  
  
Epoch 126: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.7016 - accuracy: 1.0000 - val_loss: 4.3160 - val_accuracy:  
0.3636  
Epoch 127/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.7082 - accuracy: 1.0000  
Epoch 127: accuracy did not improve from 1.00000  
  
Epoch 127: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.6907 - accuracy: 1.0000 - val_loss: 4.3102 - val_accuracy:  
0.3636  
Epoch 128/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.6830 - accuracy: 1.0000  
Epoch 128: accuracy did not improve from 1.00000  
  
Epoch 128: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.6795 - accuracy: 1.0000 - val_loss: 4.2981 - val_accuracy:  
0.3636  
Epoch 129/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.6684 - accuracy: 1.0000  
Epoch 129: accuracy did not improve from 1.00000  
  
Epoch 129: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.6691 - accuracy: 1.0000 - val_loss: 4.2874 - val_accuracy:  
0.3636  
Epoch 130/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.6404 - accuracy: 1.0000  
Epoch 130: accuracy did not improve from 1.00000  
  
Epoch 130: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.6592 - accuracy: 1.0000 - val_loss: 4.2897 - val_accuracy:  
0.3636  
Epoch 131/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.6357 - accuracy: 1.0000  
Epoch 131: accuracy did not improve from 1.00000  
  
Epoch 131: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.6464 - accuracy: 1.0000 - val_loss: 4.2709 - val_accuracy:  
0.3636  
Epoch 132/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.6433 - accuracy: 1.0000  
Epoch 132: accuracy did not improve from 1.00000  
  
Epoch 132: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.6361 - accuracy: 1.0000 - val_loss: 4.2693 - val_accuracy:  
0.3182  
Epoch 133/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.6283 - accuracy: 1.0000  
Epoch 133: accuracy did not improve from 1.00000  
  
Epoch 133: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.6256 - accuracy: 1.0000 - val_loss: 4.2626 - val_accuracy:  
0.3636  
Epoch 134/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.6013 - accuracy: 1.0000  
Epoch 134: accuracy did not improve from 1.00000  
  
Epoch 134: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.6146 - accuracy: 1.0000 - val_loss: 4.2490 - val_accuracy:  
0.3636  
Epoch 135/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.6022 - accuracy: 1.0000  
Epoch 135: accuracy did not improve from 1.00000  
  
Epoch 135: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.6042 - accuracy: 1.0000 - val_loss: 4.2392 - val_accuracy:  
0.3636  
Epoch 136/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.5840 - accuracy: 1.0000  
Epoch 136: accuracy did not improve from 1.00000  
  
Epoch 136: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.5936 - accuracy: 1.0000 - val_loss: 4.2375 - val_accuracy:  
0.3636  
Epoch 137/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.6070 - accuracy: 1.0000  
Epoch 137: accuracy did not improve from 1.00000  
  
Epoch 137: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.5834 - accuracy: 1.0000 - val_loss: 4.2159 - val_accuracy:  
0.3636  
Epoch 138/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.5628 - accuracy: 1.0000  
Epoch 138: accuracy did not improve from 1.00000  
  
Epoch 138: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.5727 - accuracy: 1.0000 - val_loss: 4.2050 - val_accuracy:  
0.3636  
Epoch 139/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.5610 - accuracy: 1.0000  
Epoch 139: accuracy did not improve from 1.00000  
  
Epoch 139: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.5622 - accuracy: 1.0000 - val_loss: 4.2087 - val_accuracy:  
0.3636  
Epoch 140/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.5525 - accuracy: 1.0000  
Epoch 140: accuracy did not improve from 1.00000  
  
Epoch 140: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.5520 - accuracy: 1.0000 - val_loss: 4.1991 - val_accuracy:  
0.3636  
Epoch 141/300  
12/13 [=====>...] - ETA: 0s - loss:  
1.5385 - accuracy: 1.0000  
Epoch 141: accuracy did not improve from 1.00000  
  
Epoch 141: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
1.5419 - accuracy: 1.0000 - val_loss: 4.1916 - val_accuracy:  
0.3636  
Epoch 142/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.5279 - accuracy: 1.0000  
Epoch 142: accuracy did not improve from 1.00000  
  
Epoch 142: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.5314 - accuracy: 1.0000 - val_loss: 4.1806 - val_accuracy:  
0.3636  
Epoch 143/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.5413 - accuracy: 1.0000  
Epoch 143: accuracy did not improve from 1.00000  
  
Epoch 143: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.5213 - accuracy: 1.0000 - val_loss: 4.1619 - val_accuracy:  
0.3636  
Epoch 144/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.5125 - accuracy: 1.0000  
Epoch 144: accuracy did not improve from 1.00000  
  
Epoch 144: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.5116 - accuracy: 1.0000 - val_loss: 4.1720 - val_accuracy:  
0.3636  
Epoch 145/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.4925 - accuracy: 1.0000  
Epoch 145: accuracy did not improve from 1.00000  
  
Epoch 145: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.5013 - accuracy: 1.0000 - val_loss: 4.1565 - val_accuracy:  
0.3636  
Epoch 146/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.5083 - accuracy: 1.0000  
Epoch 146: accuracy did not improve from 1.00000  
  
Epoch 146: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.4917 - accuracy: 1.0000 - val_loss: 4.1454 - val_accuracy:  
0.3636  
Epoch 147/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.5170 - accuracy: 1.0000  
Epoch 147: accuracy did not improve from 1.00000  
  
Epoch 147: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.4818 - accuracy: 1.0000 - val_loss: 4.1457 - val_accuracy:  
0.3636  
Epoch 148/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.4670 - accuracy: 1.0000  
Epoch 148: accuracy did not improve from 1.00000  
  
Epoch 148: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.4716 - accuracy: 1.0000 - val_loss: 4.1243 - val_accuracy:  
0.3636  
Epoch 149/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.4569 - accuracy: 1.0000  
Epoch 149: accuracy did not improve from 1.00000  
  
Epoch 149: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.4621 - accuracy: 1.0000 - val_loss: 4.1187 - val_accuracy:  
0.3636  
Epoch 150/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.4414 - accuracy: 1.0000  
Epoch 150: accuracy did not improve from 1.00000  
  
Epoch 150: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.4527 - accuracy: 1.0000 - val_loss: 4.1108 - val_accuracy:  
0.3636  
Epoch 151/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.4462 - accuracy: 1.0000  
Epoch 151: accuracy did not improve from 1.00000  
  
Epoch 151: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.4427 - accuracy: 1.0000 - val_loss: 4.1027 - val_accuracy:  
0.3636  
Epoch 152/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.4230 - accuracy: 1.0000  
Epoch 152: accuracy did not improve from 1.00000  
  
Epoch 152: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.4331 - accuracy: 1.0000 - val_loss: 4.0933 - val_accuracy:  
0.3636  
Epoch 153/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.4715 - accuracy: 1.0000  
Epoch 153: accuracy did not improve from 1.00000  
  
Epoch 153: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.4236 - accuracy: 1.0000 - val_loss: 4.0860 - val_accuracy:  
0.3636  
Epoch 154/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.4007 - accuracy: 1.0000  
Epoch 154: accuracy did not improve from 1.00000  
  
Epoch 154: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.4143 - accuracy: 1.0000 - val_loss: 4.0811 - val_accuracy:  
0.3636  
Epoch 155/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.4021 - accuracy: 1.0000  
Epoch 155: accuracy did not improve from 1.00000  
  
Epoch 155: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.4046 - accuracy: 1.0000 - val_loss: 4.0595 - val_accuracy:  
0.3636  
Epoch 156/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.4283 - accuracy: 1.0000  
Epoch 156: accuracy did not improve from 1.00000  
  
Epoch 156: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.3957 - accuracy: 1.0000 - val_loss: 4.0533 - val_accuracy:  
0.3636  
Epoch 157/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.3848 - accuracy: 1.0000  
Epoch 157: accuracy did not improve from 1.00000  
  
Epoch 157: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.3862 - accuracy: 1.0000 - val_loss: 4.0443 - val_accuracy:  
0.3636  
Epoch 158/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.3807 - accuracy: 1.0000  
Epoch 158: accuracy did not improve from 1.00000  
  
Epoch 158: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.3771 - accuracy: 1.0000 - val_loss: 4.0369 - val_accuracy:  
0.3636  
Epoch 159/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.3683 - accuracy: 1.0000  
Epoch 159: accuracy did not improve from 1.00000  
  
Epoch 159: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.3678 - accuracy: 1.0000 - val_loss: 4.0302 - val_accuracy:  
0.3636  
Epoch 160/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.3564 - accuracy: 1.0000  
Epoch 160: accuracy did not improve from 1.00000  
  
Epoch 160: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.3590 - accuracy: 1.0000 - val_loss: 4.0215 - val_accuracy:  
0.3636  
Epoch 161/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.3556 - accuracy: 1.0000  
Epoch 161: accuracy did not improve from 1.00000  
  
Epoch 161: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.3500 - accuracy: 1.0000 - val_loss: 4.0106 - val_accuracy:  
0.3636  
Epoch 162/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.3304 - accuracy: 1.0000  
Epoch 162: accuracy did not improve from 1.00000  
  
Epoch 162: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.3405 - accuracy: 1.0000 - val_loss: 3.9995 - val_accuracy:  
0.3636  
Epoch 163/300  
13/13 [=====] - ETA: 0s - loss:  
1.3317 - accuracy: 1.0000  
Epoch 163: accuracy did not improve from 1.00000  
  
Epoch 163: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
1.3317 - accuracy: 1.0000 - val_loss: 3.9894 - val_accuracy:  
0.3636  
Epoch 164/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.3229 - accuracy: 1.0000  
Epoch 164: accuracy did not improve from 1.00000  
  
Epoch 164: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.3230 - accuracy: 1.0000 - val_loss: 3.9838 - val_accuracy:  
0.3636  
Epoch 165/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.3217 - accuracy: 1.0000  
Epoch 165: accuracy did not improve from 1.00000  
  
Epoch 165: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.3137 - accuracy: 1.0000 - val_loss: 3.9729 - val_accuracy:  
0.3636  
Epoch 166/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.3058 - accuracy: 1.0000  
Epoch 166: accuracy did not improve from 1.00000  
  
Epoch 166: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.3057 - accuracy: 1.0000 - val_loss: 3.9582 - val_accuracy:  
0.3636  
Epoch 167/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.2969 - accuracy: 1.0000  
Epoch 167: accuracy did not improve from 1.00000  
  
Epoch 167: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.2967 - accuracy: 1.0000 - val_loss: 3.9511 - val_accuracy:  
0.3636  
Epoch 168/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.3167 - accuracy: 1.0000  
Epoch 168: accuracy did not improve from 1.00000  
  
Epoch 168: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.2878 - accuracy: 1.0000 - val_loss: 3.9410 - val_accuracy:  
0.3636  
Epoch 169/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.2742 - accuracy: 1.0000  
Epoch 169: accuracy did not improve from 1.00000  
  
Epoch 169: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.2793 - accuracy: 1.0000 - val_loss: 3.9367 - val_accuracy:  
0.3636  
Epoch 170/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.2842 - accuracy: 1.0000  
Epoch 170: accuracy did not improve from 1.00000  
  
Epoch 170: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.2705 - accuracy: 1.0000 - val_loss: 3.9244 - val_accuracy:  
0.3636  
Epoch 171/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.2668 - accuracy: 1.0000  
Epoch 171: accuracy did not improve from 1.00000  
  
Epoch 171: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
1.2623 - accuracy: 1.0000 - val_loss: 3.9211 - val_accuracy:  
0.3636  
Epoch 172/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
1.2671 - accuracy: 1.0000  
Epoch 172: accuracy did not improve from 1.00000  
  
Epoch 172: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
1.2538 - accuracy: 1.0000 - val_loss: 3.9194 - val_accuracy:  
0.3636  
Epoch 173/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.2453 - accuracy: 1.0000  
Epoch 173: accuracy did not improve from 1.00000  
  
Epoch 173: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.2457 - accuracy: 1.0000 - val_loss: 3.8900 - val_accuracy:  
0.3636  
Epoch 174/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.2586 - accuracy: 1.0000  
Epoch 174: accuracy did not improve from 1.00000  
  
Epoch 174: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.2370 - accuracy: 1.0000 - val_loss: 3.8933 - val_accuracy:  
0.3636  
Epoch 175/300  
13/13 [=====] - ETA: 0s - loss:  
1.2288 - accuracy: 1.0000  
Epoch 175: accuracy did not improve from 1.00000  
  
Epoch 175: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
1.2288 - accuracy: 1.0000 - val_loss: 3.8845 - val_accuracy:  
0.3636  
Epoch 176/300  
10/13 [=====>.....] - ETA: 0s - loss:  
1.2164 - accuracy: 1.0000  
Epoch 176: accuracy did not improve from 1.00000  
  
Epoch 176: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 12ms/step - loss:  
1.2203 - accuracy: 1.0000 - val_loss: 3.8749 - val_accuracy:  
0.3636  
Epoch 177/300  
11/13 [=====>.....] - ETA: 0s - loss:  
1.2136 - accuracy: 1.0000  
Epoch 177: accuracy did not improve from 1.00000  
  
Epoch 177: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
1.2119 - accuracy: 1.0000 - val_loss: 3.8614 - val_accuracy:  
0.3636  
Epoch 178/300
```

```
11/13 [=====>.....] - ETA: 0s - loss:  
1.2053 - accuracy: 1.0000  
Epoch 178: accuracy did not improve from 1.00000  
  
Epoch 178: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
1.2039 - accuracy: 1.0000 - val_loss: 3.8587 - val_accuracy:  
0.3636  
Epoch 179/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.2143 - accuracy: 1.0000  
Epoch 179: accuracy did not improve from 1.00000  
  
Epoch 179: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
1.1956 - accuracy: 1.0000 - val_loss: 3.8498 - val_accuracy:  
0.3636  
Epoch 180/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.2056 - accuracy: 1.0000  
Epoch 180: accuracy did not improve from 1.00000  
  
Epoch 180: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
1.1877 - accuracy: 1.0000 - val_loss: 3.8429 - val_accuracy:  
0.3636  
Epoch 181/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.1879 - accuracy: 1.0000  
Epoch 181: accuracy did not improve from 1.00000  
  
Epoch 181: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 13ms/step - loss:  
1.1796 - accuracy: 1.0000 - val_loss: 3.8327 - val_accuracy:  
0.3636  
Epoch 182/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.1808 - accuracy: 1.0000  
Epoch 182: accuracy did not improve from 1.00000  
  
Epoch 182: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.1720 - accuracy: 1.0000 - val_loss: 3.8281 - val_accuracy:  
0.3636  
Epoch 183/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.1717 - accuracy: 1.0000  
Epoch 183: accuracy did not improve from 1.00000  
  
Epoch 183: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
1.1639 - accuracy: 1.0000 - val_loss: 3.8104 - val_accuracy:  
0.3636  
Epoch 184/300
```

```
13/13 [=====] - ETA: 0s - loss:  
1.1557 - accuracy: 1.0000  
Epoch 184: accuracy did not improve from 1.00000  
  
Epoch 184: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
1.1557 - accuracy: 1.0000 - val_loss: 3.8048 - val_accuracy:  
0.3636  
Epoch 185/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.1561 - accuracy: 1.0000  
Epoch 185: accuracy did not improve from 1.00000  
  
Epoch 185: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.1481 - accuracy: 1.0000 - val_loss: 3.7979 - val_accuracy:  
0.3636  
Epoch 186/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.1274 - accuracy: 1.0000  
Epoch 186: accuracy did not improve from 1.00000  
  
Epoch 186: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
1.1402 - accuracy: 1.0000 - val_loss: 3.7949 - val_accuracy:  
0.3636  
Epoch 187/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.1323 - accuracy: 1.0000  
Epoch 187: accuracy did not improve from 1.00000  
  
Epoch 187: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
1.1326 - accuracy: 1.0000 - val_loss: 3.7739 - val_accuracy:  
0.3636  
Epoch 188/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.1308 - accuracy: 1.0000  
Epoch 188: accuracy did not improve from 1.00000  
  
Epoch 188: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
1.1252 - accuracy: 1.0000 - val_loss: 3.7837 - val_accuracy:  
0.3636  
Epoch 189/300  
1/13 [=>.....] - ETA: 0s - loss:  
1.1323 - accuracy: 1.0000  
Epoch 189: accuracy did not improve from 1.00000  
  
Epoch 189: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
1.1172 - accuracy: 1.0000 - val_loss: 3.7632 - val_accuracy:  
0.3636  
Epoch 190/300
```

```
11/13 [=====>.....] - ETA: 0s - loss:  
1.1106 - accuracy: 1.0000  
Epoch 190: accuracy did not improve from 1.00000  
  
Epoch 190: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
1.1100 - accuracy: 1.0000 - val_loss: 3.7517 - val_accuracy:  
0.3636  
Epoch 191/300  
12/13 [=====>...] - ETA: 0s - loss:  
1.1024 - accuracy: 1.0000  
Epoch 191: accuracy did not improve from 1.00000  
  
Epoch 191: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 14ms/step - loss:  
1.1022 - accuracy: 1.0000 - val_loss: 3.7545 - val_accuracy:  
0.3636  
Epoch 192/300  
10/13 [=====>.....] - ETA: 0s - loss:  
1.0971 - accuracy: 1.0000  
Epoch 192: accuracy did not improve from 1.00000  
  
Epoch 192: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 13ms/step - loss:  
1.0948 - accuracy: 1.0000 - val_loss: 3.7451 - val_accuracy:  
0.3636  
Epoch 193/300  
10/13 [=====>.....] - ETA: 0s - loss:  
1.0887 - accuracy: 1.0000  
Epoch 193: accuracy did not improve from 1.00000  
  
Epoch 193: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 13ms/step - loss:  
1.0873 - accuracy: 1.0000 - val_loss: 3.7329 - val_accuracy:  
0.3636  
Epoch 194/300  
11/13 [=====>.....] - ETA: 0s - loss:  
1.0805 - accuracy: 1.0000  
Epoch 194: accuracy did not improve from 1.00000  
  
Epoch 194: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
1.0799 - accuracy: 1.0000 - val_loss: 3.7288 - val_accuracy:  
0.3636  
Epoch 195/300  
13/13 [=====] - ETA: 0s - loss:  
1.0730 - accuracy: 1.0000  
Epoch 195: accuracy did not improve from 1.00000  
  
Epoch 195: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
1.0730 - accuracy: 1.0000 - val_loss: 3.7238 - val_accuracy:  
0.3636  
Epoch 196/300
```

```
13/13 [=====] - ETA: 0s - loss:  
1.0651 - accuracy: 1.0000  
Epoch 196: accuracy did not improve from 1.00000  
  
Epoch 196: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 13ms/step - loss:  
1.0651 - accuracy: 1.0000 - val_loss: 3.6980 - val_accuracy:  
0.3636  
Epoch 197/300  
13/13 [=====] - ETA: 0s - loss:  
1.0584 - accuracy: 1.0000  
Epoch 197: accuracy did not improve from 1.00000  
  
Epoch 197: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
1.0584 - accuracy: 1.0000 - val_loss: 3.6907 - val_accuracy:  
0.3636  
Epoch 198/300  
12/13 [=====>...] - ETA: 0s - loss:  
1.0516 - accuracy: 1.0000  
Epoch 198: accuracy did not improve from 1.00000  
  
Epoch 198: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 14ms/step - loss:  
1.0506 - accuracy: 1.0000 - val_loss: 3.6961 - val_accuracy:  
0.3636  
Epoch 199/300  
12/13 [=====>...] - ETA: 0s - loss:  
1.0446 - accuracy: 1.0000  
Epoch 199: accuracy did not improve from 1.00000  
  
Epoch 199: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
1.0443 - accuracy: 1.0000 - val_loss: 3.6842 - val_accuracy:  
0.4091  
Epoch 200/300  
13/13 [=====] - ETA: 0s - loss:  
1.0369 - accuracy: 1.0000  
Epoch 200: accuracy did not improve from 1.00000  
  
Epoch 200: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
1.0369 - accuracy: 1.0000 - val_loss: 3.6762 - val_accuracy:  
0.3636  
Epoch 201/300  
11/13 [=====>.....] - ETA: 0s - loss:  
1.0314 - accuracy: 1.0000  
Epoch 201: accuracy did not improve from 1.00000  
  
Epoch 201: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
1.0298 - accuracy: 1.0000 - val_loss: 3.6633 - val_accuracy:  
0.3636  
Epoch 202/300
```

```
    1/13 [=>.....] - ETA: 0s - loss:  
1.0306 - accuracy: 1.0000  
Epoch 202: accuracy did not improve from 1.00000  
  
Epoch 202: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
1.0228 - accuracy: 1.0000 - val_loss: 3.6563 - val_accuracy:  
0.3636  
Epoch 203/300  
    1/13 [=>.....] - ETA: 0s - loss:  
1.0267 - accuracy: 1.0000  
Epoch 203: accuracy did not improve from 1.00000  
  
Epoch 203: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
1.0161 - accuracy: 1.0000 - val_loss: 3.6601 - val_accuracy:  
0.3636  
Epoch 204/300  
    11/13 [=====>....] - ETA: 0s - loss:  
1.0096 - accuracy: 1.0000  
Epoch 204: accuracy did not improve from 1.00000  
  
Epoch 204: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
1.0093 - accuracy: 1.0000 - val_loss: 3.6424 - val_accuracy:  
0.3636  
Epoch 205/300  
    1/13 [=>.....] - ETA: 0s - loss:  
1.0043 - accuracy: 1.0000  
Epoch 205: accuracy did not improve from 1.00000  
  
Epoch 205: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
1.0020 - accuracy: 1.0000 - val_loss: 3.6423 - val_accuracy:  
0.3636  
Epoch 206/300  
    1/13 [=>.....] - ETA: 0s - loss:  
0.9861 - accuracy: 1.0000  
Epoch 206: accuracy did not improve from 1.00000  
  
Epoch 206: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 13ms/step - loss:  
0.9952 - accuracy: 1.0000 - val_loss: 3.6256 - val_accuracy:  
0.3636  
Epoch 207/300  
    1/13 [=>.....] - ETA: 0s - loss:  
0.9825 - accuracy: 1.0000  
Epoch 207: accuracy did not improve from 1.00000  
  
Epoch 207: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.9887 - accuracy: 1.0000 - val_loss: 3.6149 - val_accuracy:  
0.3636  
Epoch 208/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.9746 - accuracy: 1.0000  
Epoch 208: accuracy did not improve from 1.00000  
  
Epoch 208: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.9821 - accuracy: 1.0000 - val_loss: 3.6161 - val_accuracy:  
0.4091  
Epoch 209/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.9658 - accuracy: 1.0000  
Epoch 209: accuracy did not improve from 1.00000  
  
Epoch 209: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.9757 - accuracy: 1.0000 - val_loss: 3.6004 - val_accuracy:  
0.3636  
Epoch 210/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.9673 - accuracy: 1.0000  
Epoch 210: accuracy did not improve from 1.00000  
  
Epoch 210: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 12ms/step - loss:  
0.9685 - accuracy: 1.0000 - val_loss: 3.6062 - val_accuracy:  
0.4091  
Epoch 211/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.9647 - accuracy: 1.0000  
Epoch 211: accuracy did not improve from 1.00000  
  
Epoch 211: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.9623 - accuracy: 1.0000 - val_loss: 3.5966 - val_accuracy:  
0.3636  
Epoch 212/300  
13/13 [=====] - ETA: 0s - loss:  
0.9554 - accuracy: 1.0000  
Epoch 212: accuracy did not improve from 1.00000  
  
Epoch 212: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
0.9554 - accuracy: 1.0000 - val_loss: 3.5842 - val_accuracy:  
0.4091  
Epoch 213/300  
11/13 [=====>....] - ETA: 0s - loss:  
0.9504 - accuracy: 1.0000  
Epoch 213: accuracy did not improve from 1.00000  
  
Epoch 213: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.9492 - accuracy: 1.0000 - val_loss: 3.5836 - val_accuracy:  
0.3636  
Epoch 214/300
```

```
11/13 [=====>.....] - ETA: 0s - loss:  
0.9386 - accuracy: 1.0000  
Epoch 214: accuracy did not improve from 1.00000  
  
Epoch 214: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.9427 - accuracy: 1.0000 - val_loss: 3.5772 - val_accuracy:  
0.4091  
Epoch 215/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.9255 - accuracy: 1.0000  
Epoch 215: accuracy did not improve from 1.00000  
  
Epoch 215: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.9363 - accuracy: 1.0000 - val_loss: 3.5472 - val_accuracy:  
0.4091  
Epoch 216/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.9459 - accuracy: 1.0000  
Epoch 216: accuracy did not improve from 1.00000  
  
Epoch 216: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 13ms/step - loss:  
0.9300 - accuracy: 1.0000 - val_loss: 3.5611 - val_accuracy:  
0.4091  
Epoch 217/300  
11/13 [=====>.....] - ETA: 0s - loss:  
0.9253 - accuracy: 1.0000  
Epoch 217: accuracy did not improve from 1.00000  
  
Epoch 217: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 12ms/step - loss:  
0.9238 - accuracy: 1.0000 - val_loss: 3.5416 - val_accuracy:  
0.4091  
Epoch 218/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.9142 - accuracy: 1.0000  
Epoch 218: accuracy did not improve from 1.00000  
  
Epoch 218: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.9173 - accuracy: 1.0000 - val_loss: 3.5397 - val_accuracy:  
0.4091  
Epoch 219/300  
13/13 [=====] - ETA: 0s - loss:  
0.9114 - accuracy: 1.0000  
Epoch 219: accuracy did not improve from 1.00000  
  
Epoch 219: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.9114 - accuracy: 1.0000 - val_loss: 3.5371 - val_accuracy:  
0.4091  
Epoch 220/300
```

```
13/13 [=====] - ETA: 0s - loss:  
0.9051 - accuracy: 1.0000  
Epoch 220: accuracy did not improve from 1.00000  
  
Epoch 220: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 13ms/step - loss:  
0.9051 - accuracy: 1.0000 - val_loss: 3.5256 - val_accuracy:  
0.4091  
Epoch 221/300  
13/13 [=====] - ETA: 0s - loss:  
0.8987 - accuracy: 1.0000  
Epoch 221: accuracy did not improve from 1.00000  
  
Epoch 221: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.8987 - accuracy: 1.0000 - val_loss: 3.5136 - val_accuracy:  
0.4091  
Epoch 222/300  
13/13 [=====] - ETA: 0s - loss:  
0.8928 - accuracy: 1.0000  
Epoch 222: accuracy did not improve from 1.00000  
  
Epoch 222: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.8928 - accuracy: 1.0000 - val_loss: 3.5149 - val_accuracy:  
0.4091  
Epoch 223/300  
12/13 [=====>...] - ETA: 0s - loss:  
0.8861 - accuracy: 1.0000  
Epoch 223: accuracy did not improve from 1.00000  
  
Epoch 223: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.8867 - accuracy: 1.0000 - val_loss: 3.5098 - val_accuracy:  
0.4091  
Epoch 224/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8782 - accuracy: 1.0000  
Epoch 224: accuracy did not improve from 1.00000  
  
Epoch 224: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.8813 - accuracy: 1.0000 - val_loss: 3.5091 - val_accuracy:  
0.3636  
Epoch 225/300  
13/13 [=====] - ETA: 0s - loss:  
0.8747 - accuracy: 1.0000  
Epoch 225: accuracy did not improve from 1.00000  
  
Epoch 225: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.8747 - accuracy: 1.0000 - val_loss: 3.4949 - val_accuracy:  
0.4091  
Epoch 226/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.8725 - accuracy: 1.0000  
Epoch 226: accuracy did not improve from 1.00000  
  
Epoch 226: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.8689 - accuracy: 1.0000 - val_loss: 3.4774 - val_accuracy:  
0.4091  
Epoch 227/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8572 - accuracy: 1.0000  
Epoch 227: accuracy did not improve from 1.00000  
  
Epoch 227: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.8634 - accuracy: 1.0000 - val_loss: 3.4729 - val_accuracy:  
0.3636  
Epoch 228/300  
13/13 [=====] - ETA: 0s - loss:  
0.8575 - accuracy: 1.0000  
Epoch 228: accuracy did not improve from 1.00000  
  
Epoch 228: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 13ms/step - loss:  
0.8575 - accuracy: 1.0000 - val_loss: 3.4621 - val_accuracy:  
0.4091  
Epoch 229/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8632 - accuracy: 1.0000  
Epoch 229: accuracy did not improve from 1.00000  
  
Epoch 229: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.8514 - accuracy: 1.0000 - val_loss: 3.4603 - val_accuracy:  
0.3636  
Epoch 230/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8532 - accuracy: 1.0000  
Epoch 230: accuracy did not improve from 1.00000  
  
Epoch 230: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.8458 - accuracy: 1.0000 - val_loss: 3.4546 - val_accuracy:  
0.3636  
Epoch 231/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8327 - accuracy: 1.0000  
Epoch 231: accuracy did not improve from 1.00000  
  
Epoch 231: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.8402 - accuracy: 1.0000 - val_loss: 3.4411 - val_accuracy:  
0.4091  
Epoch 232/300
```

```
13/13 [=====] - ETA: 0s - loss:  
0.8349 - accuracy: 1.0000  
Epoch 232: accuracy did not improve from 1.00000  
  
Epoch 232: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.8349 - accuracy: 1.0000 - val_loss: 3.4413 - val_accuracy:  
0.4091  
Epoch 233/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8218 - accuracy: 1.0000  
Epoch 233: accuracy did not improve from 1.00000  
  
Epoch 233: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.8288 - accuracy: 1.0000 - val_loss: 3.4388 - val_accuracy:  
0.3636  
Epoch 234/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8275 - accuracy: 1.0000  
Epoch 234: accuracy did not improve from 1.00000  
  
Epoch 234: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.8234 - accuracy: 1.0000 - val_loss: 3.4381 - val_accuracy:  
0.4091  
Epoch 235/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8133 - accuracy: 1.0000  
Epoch 235: accuracy did not improve from 1.00000  
  
Epoch 235: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.8180 - accuracy: 1.0000 - val_loss: 3.4156 - val_accuracy:  
0.4091  
Epoch 236/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8233 - accuracy: 1.0000  
Epoch 236: accuracy did not improve from 1.00000  
  
Epoch 236: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.8126 - accuracy: 1.0000 - val_loss: 3.4195 - val_accuracy:  
0.3636  
Epoch 237/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8171 - accuracy: 1.0000  
Epoch 237: accuracy did not improve from 1.00000  
  
Epoch 237: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.8071 - accuracy: 1.0000 - val_loss: 3.3989 - val_accuracy:  
0.4091  
Epoch 238/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.8029 - accuracy: 1.0000  
Epoch 238: accuracy did not improve from 1.00000  
  
Epoch 238: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.8014 - accuracy: 1.0000 - val_loss: 3.4107 - val_accuracy:  
0.3636  
Epoch 239/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.8042 - accuracy: 1.0000  
Epoch 239: accuracy did not improve from 1.00000  
  
Epoch 239: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7967 - accuracy: 1.0000 - val_loss: 3.3927 - val_accuracy:  
0.3636  
Epoch 240/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7868 - accuracy: 1.0000  
Epoch 240: accuracy did not improve from 1.00000  
  
Epoch 240: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7908 - accuracy: 1.0000 - val_loss: 3.3844 - val_accuracy:  
0.3636  
Epoch 241/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7783 - accuracy: 1.0000  
Epoch 241: accuracy did not improve from 1.00000  
  
Epoch 241: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7854 - accuracy: 1.0000 - val_loss: 3.3805 - val_accuracy:  
0.3636  
Epoch 242/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7836 - accuracy: 1.0000  
Epoch 242: accuracy did not improve from 1.00000  
  
Epoch 242: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7804 - accuracy: 1.0000 - val_loss: 3.3781 - val_accuracy:  
0.3636  
Epoch 243/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7849 - accuracy: 1.0000  
Epoch 243: accuracy did not improve from 1.00000  
  
Epoch 243: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7753 - accuracy: 1.0000 - val_loss: 3.3669 - val_accuracy:  
0.3636  
Epoch 244/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.7623 - accuracy: 1.0000  
Epoch 244: accuracy did not improve from 1.00000  
  
Epoch 244: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.7703 - accuracy: 1.0000 - val_loss: 3.3573 - val_accuracy:  
0.4091  
Epoch 245/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7505 - accuracy: 1.0000  
Epoch 245: accuracy did not improve from 1.00000  
  
Epoch 245: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7650 - accuracy: 1.0000 - val_loss: 3.3630 - val_accuracy:  
0.3636  
Epoch 246/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7537 - accuracy: 1.0000  
Epoch 246: accuracy did not improve from 1.00000  
  
Epoch 246: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.7599 - accuracy: 1.0000 - val_loss: 3.3457 - val_accuracy:  
0.3636  
Epoch 247/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7696 - accuracy: 1.0000  
Epoch 247: accuracy did not improve from 1.00000  
  
Epoch 247: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.7550 - accuracy: 1.0000 - val_loss: 3.3397 - val_accuracy:  
0.3636  
Epoch 248/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7449 - accuracy: 1.0000  
Epoch 248: accuracy did not improve from 1.00000  
  
Epoch 248: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7501 - accuracy: 1.0000 - val_loss: 3.3312 - val_accuracy:  
0.3636  
Epoch 249/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7680 - accuracy: 1.0000  
Epoch 249: accuracy did not improve from 1.00000  
  
Epoch 249: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.7447 - accuracy: 1.0000 - val_loss: 3.3299 - val_accuracy:  
0.3636  
Epoch 250/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.7413 - accuracy: 1.0000  
Epoch 250: accuracy did not improve from 1.00000  
  
Epoch 250: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.7396 - accuracy: 1.0000 - val_loss: 3.3319 - val_accuracy:  
0.3636  
Epoch 251/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7365 - accuracy: 1.0000  
Epoch 251: accuracy did not improve from 1.00000  
  
Epoch 251: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.7349 - accuracy: 1.0000 - val_loss: 3.3163 - val_accuracy:  
0.3636  
Epoch 252/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7251 - accuracy: 1.0000  
Epoch 252: accuracy did not improve from 1.00000  
  
Epoch 252: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.7299 - accuracy: 1.0000 - val_loss: 3.3233 - val_accuracy:  
0.3636  
Epoch 253/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7420 - accuracy: 1.0000  
Epoch 253: accuracy did not improve from 1.00000  
  
Epoch 253: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7251 - accuracy: 1.0000 - val_loss: 3.2988 - val_accuracy:  
0.3636  
Epoch 254/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7228 - accuracy: 1.0000  
Epoch 254: accuracy did not improve from 1.00000  
  
Epoch 254: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7205 - accuracy: 1.0000 - val_loss: 3.3086 - val_accuracy:  
0.3636  
Epoch 255/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7281 - accuracy: 1.0000  
Epoch 255: accuracy did not improve from 1.00000  
  
Epoch 255: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7156 - accuracy: 1.0000 - val_loss: 3.2916 - val_accuracy:  
0.3636  
Epoch 256/300
```

```
11/13 [=====>.....] - ETA: 0s - loss:  
0.7085 - accuracy: 1.0000  
Epoch 256: accuracy did not improve from 1.00000  
  
Epoch 256: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.7107 - accuracy: 1.0000 - val_loss: 3.2870 - val_accuracy:  
0.3636  
Epoch 257/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6990 - accuracy: 1.0000  
Epoch 257: accuracy did not improve from 1.00000  
  
Epoch 257: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.7062 - accuracy: 1.0000 - val_loss: 3.2802 - val_accuracy:  
0.3636  
Epoch 258/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6995 - accuracy: 1.0000  
Epoch 258: accuracy did not improve from 1.00000  
  
Epoch 258: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
0.7018 - accuracy: 1.0000 - val_loss: 3.2852 - val_accuracy:  
0.3636  
Epoch 259/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6957 - accuracy: 1.0000  
Epoch 259: accuracy did not improve from 1.00000  
  
Epoch 259: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.6979 - accuracy: 1.0000 - val_loss: 3.2481 - val_accuracy:  
0.3636  
Epoch 260/300  
13/13 [=====] - ETA: 0s - loss:  
0.6922 - accuracy: 1.0000  
Epoch 260: accuracy did not improve from 1.00000  
  
Epoch 260: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.6922 - accuracy: 1.0000 - val_loss: 3.2695 - val_accuracy:  
0.3636  
Epoch 261/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.7015 - accuracy: 1.0000  
Epoch 261: accuracy did not improve from 1.00000  
  
Epoch 261: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.6877 - accuracy: 1.0000 - val_loss: 3.2652 - val_accuracy:  
0.3636  
Epoch 262/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.6748 - accuracy: 1.0000  
Epoch 262: accuracy did not improve from 1.00000  
  
Epoch 262: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6832 - accuracy: 1.0000 - val_loss: 3.2526 - val_accuracy:  
0.3636  
Epoch 263/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6903 - accuracy: 1.0000  
Epoch 263: accuracy did not improve from 1.00000  
  
Epoch 263: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.6787 - accuracy: 1.0000 - val_loss: 3.2427 - val_accuracy:  
0.3636  
Epoch 264/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6892 - accuracy: 1.0000  
Epoch 264: accuracy did not improve from 1.00000  
  
Epoch 264: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6747 - accuracy: 1.0000 - val_loss: 3.2297 - val_accuracy:  
0.3636  
Epoch 265/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6815 - accuracy: 1.0000  
Epoch 265: accuracy did not improve from 1.00000  
  
Epoch 265: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.6705 - accuracy: 1.0000 - val_loss: 3.2342 - val_accuracy:  
0.3636  
Epoch 266/300  
12/13 [=====>...] - ETA: 0s - loss:  
0.6665 - accuracy: 1.0000  
Epoch 266: accuracy did not improve from 1.00000  
  
Epoch 266: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.6661 - accuracy: 1.0000 - val_loss: 3.2271 - val_accuracy:  
0.3636  
Epoch 267/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6852 - accuracy: 1.0000  
Epoch 267: accuracy did not improve from 1.00000  
  
Epoch 267: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6613 - accuracy: 1.0000 - val_loss: 3.2225 - val_accuracy:  
0.3636  
Epoch 268/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.6528 - accuracy: 1.0000  
Epoch 268: accuracy did not improve from 1.00000  
  
Epoch 268: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6573 - accuracy: 1.0000 - val_loss: 3.2062 - val_accuracy:  
0.3636  
Epoch 269/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6596 - accuracy: 1.0000  
Epoch 269: accuracy did not improve from 1.00000  
  
Epoch 269: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.6529 - accuracy: 1.0000 - val_loss: 3.2153 - val_accuracy:  
0.3636  
Epoch 270/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6608 - accuracy: 1.0000  
Epoch 270: accuracy did not improve from 1.00000  
  
Epoch 270: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.6489 - accuracy: 1.0000 - val_loss: 3.2101 - val_accuracy:  
0.3636  
Epoch 271/300  
13/13 [=====] - ETA: 0s - loss:  
0.6447 - accuracy: 1.0000  
Epoch 271: accuracy did not improve from 1.00000  
  
Epoch 271: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.6447 - accuracy: 1.0000 - val_loss: 3.2088 - val_accuracy:  
0.3636  
Epoch 272/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6580 - accuracy: 1.0000  
Epoch 272: accuracy did not improve from 1.00000  
  
Epoch 272: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6403 - accuracy: 1.0000 - val_loss: 3.1868 - val_accuracy:  
0.3636  
Epoch 273/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6438 - accuracy: 1.0000  
Epoch 273: accuracy did not improve from 1.00000  
  
Epoch 273: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6360 - accuracy: 1.0000 - val_loss: 3.1980 - val_accuracy:  
0.3636  
Epoch 274/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.6310 - accuracy: 1.0000  
Epoch 274: accuracy did not improve from 1.00000  
  
Epoch 274: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6323 - accuracy: 1.0000 - val_loss: 3.1865 - val_accuracy:  
0.3636  
Epoch 275/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6444 - accuracy: 1.0000  
Epoch 275: accuracy did not improve from 1.00000  
  
Epoch 275: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6283 - accuracy: 1.0000 - val_loss: 3.1721 - val_accuracy:  
0.3636  
Epoch 276/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6225 - accuracy: 1.0000  
Epoch 276: accuracy did not improve from 1.00000  
  
Epoch 276: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.6239 - accuracy: 1.0000 - val_loss: 3.1716 - val_accuracy:  
0.3636  
Epoch 277/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6077 - accuracy: 1.0000  
Epoch 277: accuracy did not improve from 1.00000  
  
Epoch 277: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6198 - accuracy: 1.0000 - val_loss: 3.1658 - val_accuracy:  
0.3636  
Epoch 278/300  
13/13 [=====] - ETA: 0s - loss:  
0.6160 - accuracy: 1.0000  
Epoch 278: accuracy did not improve from 1.00000  
  
Epoch 278: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.6160 - accuracy: 1.0000 - val_loss: 3.1519 - val_accuracy:  
0.3636  
Epoch 279/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6222 - accuracy: 1.0000  
Epoch 279: accuracy did not improve from 1.00000  
  
Epoch 279: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.6119 - accuracy: 1.0000 - val_loss: 3.1698 - val_accuracy:  
0.3636  
Epoch 280/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.6015 - accuracy: 1.0000  
Epoch 280: accuracy did not improve from 1.00000  
  
Epoch 280: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6087 - accuracy: 1.0000 - val_loss: 3.1580 - val_accuracy:  
0.3636  
Epoch 281/300  
13/13 [=====] - ETA: 0s - loss:  
0.6042 - accuracy: 1.0000  
Epoch 281: accuracy did not improve from 1.00000  
  
Epoch 281: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.6042 - accuracy: 1.0000 - val_loss: 3.1503 - val_accuracy:  
0.3636  
Epoch 282/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.6031 - accuracy: 1.0000  
Epoch 282: accuracy did not improve from 1.00000  
  
Epoch 282: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.6005 - accuracy: 1.0000 - val_loss: 3.1468 - val_accuracy:  
0.3636  
Epoch 283/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.5867 - accuracy: 1.0000  
Epoch 283: accuracy did not improve from 1.00000  
  
Epoch 283: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.5972 - accuracy: 1.0000 - val_loss: 3.1250 - val_accuracy:  
0.3636  
Epoch 284/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.5928 - accuracy: 1.0000  
Epoch 284: accuracy did not improve from 1.00000  
  
Epoch 284: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.5932 - accuracy: 1.0000 - val_loss: 3.1517 - val_accuracy:  
0.3636  
Epoch 285/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.5774 - accuracy: 1.0000  
Epoch 285: accuracy did not improve from 1.00000  
  
Epoch 285: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 9ms/step - loss:  
0.5891 - accuracy: 1.0000 - val_loss: 3.1167 - val_accuracy:  
0.3636  
Epoch 286/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.5808 - accuracy: 1.0000  
Epoch 286: accuracy did not improve from 1.00000  
  
Epoch 286: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.5855 - accuracy: 1.0000 - val_loss: 3.1202 - val_accuracy:  
0.3636  
Epoch 287/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.5899 - accuracy: 1.0000  
Epoch 287: accuracy did not improve from 1.00000  
  
Epoch 287: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.5816 - accuracy: 1.0000 - val_loss: 3.1216 - val_accuracy:  
0.3636  
Epoch 288/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.5824 - accuracy: 1.0000  
Epoch 288: accuracy did not improve from 1.00000  
  
Epoch 288: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.5780 - accuracy: 1.0000 - val_loss: 3.1267 - val_accuracy:  
0.3636  
Epoch 289/300  
12/13 [=====>...] - ETA: 0s - loss:  
0.5741 - accuracy: 1.0000  
Epoch 289: accuracy did not improve from 1.00000  
  
Epoch 289: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.5745 - accuracy: 1.0000 - val_loss: 3.1094 - val_accuracy:  
0.3636  
Epoch 290/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.5921 - accuracy: 1.0000  
Epoch 290: accuracy did not improve from 1.00000  
  
Epoch 290: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.5711 - accuracy: 1.0000 - val_loss: 3.1135 - val_accuracy:  
0.3636  
Epoch 291/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.5845 - accuracy: 1.0000  
Epoch 291: accuracy did not improve from 1.00000  
  
Epoch 291: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.5675 - accuracy: 1.0000 - val_loss: 3.1047 - val_accuracy:  
0.3636  
Epoch 292/300
```

```
1/13 [=>.....] - ETA: 0s - loss:  
0.5623 - accuracy: 1.0000  
Epoch 292: accuracy did not improve from 1.00000  
  
Epoch 292: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 6ms/step - loss:  
0.5636 - accuracy: 1.0000 - val_loss: 3.1039 - val_accuracy:  
0.3636  
Epoch 293/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.5674 - accuracy: 1.0000  
Epoch 293: accuracy did not improve from 1.00000  
  
Epoch 293: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 7ms/step - loss:  
0.5603 - accuracy: 1.0000 - val_loss: 3.0894 - val_accuracy:  
0.3636  
Epoch 294/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.5672 - accuracy: 1.0000  
Epoch 294: accuracy did not improve from 1.00000  
  
Epoch 294: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.5567 - accuracy: 1.0000 - val_loss: 3.0999 - val_accuracy:  
0.3636  
Epoch 295/300  
12/13 [=====>...] - ETA: 0s - loss:  
0.5525 - accuracy: 1.0000  
Epoch 295: accuracy did not improve from 1.00000  
  
Epoch 295: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 11ms/step - loss:  
0.5534 - accuracy: 1.0000 - val_loss: 3.0829 - val_accuracy:  
0.3636  
Epoch 296/300  
10/13 [=====>.....] - ETA: 0s - loss:  
0.5507 - accuracy: 1.0000  
Epoch 296: accuracy did not improve from 1.00000  
  
Epoch 296: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 10ms/step - loss:  
0.5498 - accuracy: 1.0000 - val_loss: 3.0701 - val_accuracy:  
0.3636  
Epoch 297/300  
1/13 [=>.....] - ETA: 0s - loss:  
0.5424 - accuracy: 1.0000  
Epoch 297: accuracy did not improve from 1.00000  
  
Epoch 297: val_accuracy did not improve from 0.59091  
13/13 [=====] - 0s 8ms/step - loss:  
0.5464 - accuracy: 1.0000 - val_loss: 3.0918 - val_accuracy:  
0.3636  
Epoch 298/300
```

```

13/13 [=====] - ETA: 0s - loss:
0.5434 - accuracy: 1.0000
Epoch 298: accuracy did not improve from 1.00000

Epoch 298: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 10ms/step - loss:
0.5434 - accuracy: 1.0000 - val_loss: 3.0603 - val_accuracy:
0.3636
Epoch 299/300
1/13 [=>.....] - ETA: 0s - loss:
0.5381 - accuracy: 1.0000
Epoch 299: accuracy did not improve from 1.00000

Epoch 299: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 7ms/step - loss:
0.5399 - accuracy: 1.0000 - val_loss: 3.0782 - val_accuracy:
0.3636
Epoch 300/300
1/13 [=>.....] - ETA: 0s - loss:
0.5381 - accuracy: 1.0000
Epoch 300: accuracy did not improve from 1.00000

Epoch 300: val_accuracy did not improve from 0.59091
13/13 [=====] - 0s 9ms/step - loss:
0.5364 - accuracy: 1.0000 - val_loss: 3.0551 - val_accuracy:
0.3636

```

```

#evaluate
from tensorflow.keras.models import load_model
best_model_train=load_model('model_train.hdf5')
best_model_test=load_model('model_test.hdf5')
loss, accuracy = best_model_train.evaluate(x_train, y_train)
print("Training Loss:", loss*100, '%')
print("Training Accuracy:", accuracy*100, '%')
lossTest, accuracyTest = best_model_test.evaluate(x_test,
y_test)
print("Testing Loss:", lossTest*100, '%')
print("Testing Accuracy:", accuracyTest*100, '%')

#plot accuracy
import matplotlib.pyplot as plt
plt.plot(training2.history['accuracy'])
plt.plot(training2.history['val_accuracy'])
plt.title('Model Accuracy')
plt.ylabel('Accuracy')
plt.xlabel('Epoch')
plt.legend(['Training', 'Validation'], loc='upper left')
plt.show()

```

```

#plot loss
plt.plot(training2.history['loss'])
plt.plot(training2.history['val_loss'])
plt.title('Model loss')
plt.ylabel('Loss')
plt.xlabel('Epoch')
plt.legend(['Training', 'Validation'], loc='upper left')
plt.show()

import matplotlib.pyplot as plt

# Menghitung nilai loss dan accuracy
train_loss = loss * 100
train_accuracy = accuracy * 100
test_loss = lossTest * 100
test_accuracy = accuracyTest * 100

# Menyusun nilai loss dan accuracy dalam list
labels = ['Training Loss', 'Training Accuracy', 'Validation Loss',
          'Validation Accuracy']
values = [train_loss, train_accuracy, test_loss,
          test_accuracy]

# Membuat grafik batang
plt.bar(labels, values)
plt.ylim(0, 150) # Mengatur batas nilai y pada grafik
plt.ylabel('Percentage')
plt.title('Model Evaluate')

# Menambahkan label nilai pada tiap batang
for i in range(len(labels)):
    plt.text(i, values[i], str(round(values[i], 2)) + '%',
             ha='center', va='bottom')

# Menampilkan grafik
plt.show()

```

## BIOGRAFI PENULIS



Penulis lahir di Demak, 5 Juli 1975, Jawa Tengah. Masa kecil penulis dihabiskan di Demak mulai SD Negeri Kadilangu 1 Demak, SMP Negeri 2 Demak dan SMA Negeri 1 Demak. Lulus SMA pada tahun 1994, penulis mendapatkan PMDK untuk kuliah di Institut Pertanian Bogor (IPB) Jurusan Ilmu Tanah Fakultas Pertanian. Tahun 1995, Penulis ikut SMPTN dan diterima di Jurusan Teknik Geodesi Insitut Teknologi Bandung (ITB) dan akhirnya lulus pada Februari, 2000. Pada akhir tahun 2000, Penulis diterima sebagai CPNS di Jurusan Teknik Geodesi ITS dan diangkat sebagai PNS pada Februari 2002. Tahun 2004, Penulis melanjutkan Studi Magister di Fakultas Teknologi Kelautan Institut Teknologi Sepuluh Nopember (FTK ITS), Program Studi Teknik dan Manajemen Pantai dan lulus Tahun 2006. Pada tahun 2010, sempat dapat beasiswa S3 dari DIKTI untuk melanjutkan studi S3 di Waikato University, akan tetapi, baru 10 bulan di Hamilton, New Zealand, calon Promotor meninggal dunia dan akhirnya kembali lagi mengajar di Departemen Teknik Geomatik ITS. Pada tahun 2019, Penulis melanjutkan studi S3 di Program Pasca Sarjana, Departemen Teknik Kelautan, FTK ITS Surabaya, dengan keahlian Teknik dan Manajemen Pantai. Disertasi Penulis yang berjudul, “Studi Peningkatan Kualitas Klasifikasi Sedimen Dasar Laut dengan Menggunakan Selisih Batimetri Antar Frekuensi Dan Multispektral *Backscatter* Multibeam Echosounder (MBES)” diselesaikan setelah 5 (lima) tahun penulis menjalankan studi S3. Penulis berharap disertasi ini memberi manfaat dan barokah bagi kita semua. Amin yra.