

**ANALISIS TUMPAHAN MINYAK DI LAUT MENGGUNAKAN
PEMODELAN RANDOM FOREST BERBASIS DATA SENTINEL - 1 SAR**

SKRIPSI



Oleh :

Yudi Amril

2203025014

**PROGRAM STUDI TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI INDUSTRI DAN INFORMATIKA
UNIVERSITAS MUHAMMADIYAH PROF. DR.HAMKA**

Jakarta

2026

**ANALISIS TUMPAHAN MINYAK DI LAUT MENGGUNAKAN
PEMODELAN RANDOM FOREST BERBASIS DATA SENTINEL - 1 SAR**

SKRIPSI

Disusun untuk Memenuhi Persyaratan Kelulusan Sarjana Teknik Elektro



Oleh :

Yudi Amril

2203025014

**PROGRAM STUDI TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI INDUSTRI DAN INFORMATIKA
UNIVERSITAS MUHAMMADIYAH PROF. DR.HAMKA**

Jakarta

2026

HALAMAN PERSETUJUAN

HALAMAN PERSETUJUAN

ANALISIS TUMPAHAN MINYAK DI LAUT MENGGUNAKAN PEMODELAN RANDOM FOREST BERBASIS DATA SENTINEL - 1 SAR

SKRIPSI

Dibuat untuk Memenuhi Persyaratan Kelulusan Sarjana Teknik

Oleh:

Yudi Amril

2203025014

Telah diperiksa dan disetujui untuk diajukan ke Sidang Ujian Skripsi Program
Studi Teknik Elektro Fakultas Teknologi Industri dan Informatika UHAMKA

Tanggal, 11 Agustus 2026

Pembimbing-1



Ir. Kun Fawakun, S.T., M.T.
NIDN. 0312126705

Pembimbing-2



Muhammad Iqbal Habibie, S.Kom.,
M.T., Ph.D.
NIP: 198406122009011004

Mengetahui,

Ketua Program Studi Teknik Elektro



Ir. Harry Bimza, S.T., M.T., Ph.D.
NIDN. 0303097006

HALAMAN PENGESAHAN

HALAMAN PENGESAHAN

ANALISIS TUMPAHAN MINYAK DI LAUT MENGGUNAKAN PEMODELAN RANDOM FOREST BERBASIS DATA SENTINEL - 1 SAR

SKRIPSI

Oleh;


Yudi Amril

2203025014

Telah diuji dan dinyatakan lulus dalam Sidang Ujian Skripsi Program Studi
Teknik Elektro Fakultas Teknologi Industri dan Informatika UHAMKA


Tanggal, 11 agustus 2026

Pembimbing-1




Ir. Kun Fayakun, S.T., M.T.
NIDN. 0312126705

Pembimbing-2



Muhammad Iqbal Habibie, S.Kom,
M.T., Ph.D
NIP: 198406122009011004

Penguji-1




Dr. Dwi Astuti Cahyasiwi, S.T., M.T.
NIDN. 0323027401

Penguji-2



Rosalina, S.T., M.T.
NIDN. 0304017001

Mengesahkan,
Dekan
Fakultas Teknologi Industri dan
Informatika UHAMKA



Dr. Dr. Dan Mugisidi, S.T., M.Si.
NIDN. 0301126901

Mengetahui,
Ketua Program Studi
Teknik Elektro



Ir. Harry Ramza, S.T., M.T., Ph.D.
NIDN. 0303097006

PERNYATAAN KEASLIAN

Saya, yang membuat pernyataan

Nama : Yudi Amril

NIM : 2103025013

Judul Skripsi : Analisis Tumpahan Minyak di Laut Menggunakan
Pemodelan Random Forest Berbasis Data Sentinel-1 SAR

Menyatakan bahwa, skripsi ini merupakan karya saya sendiri (ASLI) dan isi dalam skripsi ini tidak terdapat karya yang pernah diajukan oleh orang lain untuk memperoleh gelar akademis di suatu institusi pendidikan tinggi mana pun, dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis dan/atau diterbitkan oleh orang lain, KECUALI yang secara tertulis diacu dalam naskah ini dan disebutkan dalam Daftar Referensi.

Segala sesuatu yang terkait dengan naskah dan karya yang telah dibuat adalah menjadi tanggung jawab saya pribadi.

Jakarta. 11 Agustus 2026

A 20,000 Indonesian Rupiah revenue stamp (Meterai Tempel) with a signature over it. The stamp features the Garuda Pancasila emblem and the text "REPUBLIK INDONESIA", "20.000", "TBL", "20", "METERAI", and "TEMPEL". The serial number "090D6AOX132031404" is visible at the bottom.

Yudi Amril

KATA PENGANTAR

Assallamu'alaikum wa rohmatullahi wa barokaatuh, shalawat dan salam kepada Nabi Muhammad dan para pengikutnya.

Puji syukur ke hadirat Allah SWT yang telah melimpahkan rahmat, taufik dan hidayah-Nya sehingga penulisan skripsi ini dapat diselesaikan dengan baik. Shalawat serta salam senantiasa tercurah kepada Nabi Muhammad SAW, beserta keluarga, sahabat, dan seluruh pengikutnya hingga akhir zaman.

Skripsi ini merupakan hasil penelitian yang dilaksanakan di Pusat Riset Geoinformatika, Badan Riset dan Inovasi Nasional (BRIN) Kecamatan Cibinong, Kabupaten Bogor, Republik Indonesia. Penelitian ini bertujuan untuk membuat Analisis Tumpahan Minyak di Laut Menggunakan Pemodelan Random Forest Berbasis Data Sentinel-1 SAR. Penelitian ini tidak akan dapat terlaksana tanpa dukungan, bimbingan, serta inspirasi dari berbagai pihak, terutama seluruh staf peneliti di Pusat Riset Geoinformatika. Mereka telah memberikan wawasan yang sangat berharga mengenai metodologi dan langkah-langkah teknis yang harus diambil selama proses penelitian

Penulis menyampaikan rasa terima kasih yang sebesar-besarnya dan penghargaan setinggi-tingginya kepada seluruh pihak yang telah memberikan dukungan moral, bimbingan akademis, bantuan teknis, serta fasilitas penelitian hingga publikasi ini dapat diselesaikan dengan baik.

1. Kedua Orang Tua Tercinta, yang senantiasa melimpahkan doa tanpa putus di setiap sujudnya, memberikan kasih sayang yang tak terhingga, kesabaran, serta dukungan moral dan material yang luar biasa. Rida, peluh, dan ketulusan mereka adalah pilar kekuatan terbesar sekaligus motivator utama bagi penulis dalam menyelesaikan setiap tahapan studi dan penyusunan penelitian ini.
2. Bapak Ir. Kun Fayakun. S.T., M.T., selaku dosen pembimbing dari Fakultas Teknologi Industri dan Informatika, Universitas Muhammadiyah Prof. Dr. Hamka (UHAMKA), atas arahan, kesabaran, bimbingan akademik yang sangat berharga, serta ruang diskusi yang selalu mencerahkan selama proses perkuliahan hingga penyusunan penelitian ini.
3. Bapak Muhammad Iqbal Habibie, S.Kom, M.T., Ph.D, selaku peneliti di Pusat Riset Geoinformatika, Badan Riset dan Inovasi Nasional (BRIN), atas bimbingan teknis yang mendalam, transfer keahlian di bidang teknologi penginderaan jauh, serta penyediaan lingkungan riset yang profesional dan inspiratif. Penulis juga menyampaikan apresiasi kepada Fakultas Teknologi Industri dan Informatika UHAMKA yang

telah memfasilitasi proses pembimbingan melalui Surat Permohonan Pembimbing Skripsi Nomor 1531/D/LT/2025 tanggal 27 September 2025, yang menjadi dasar pelaksanaan kegiatan pembimbingan dan penelitian di Pusat Riset Geoinformatika BRIN.

4. Teman-Teman Seperjuangan, khususnya rekan-rekan mahasiswa Fakultas Teknologi Industri dan Informatika UHAMKA, serta sahabat-sahabat terdekat yang tidak dapat disebutkan satu per satu. Terima kasih atas , diskusi yang konstruktif, bantuan teknis selama proses penelitian, serta dukungan moral yang senantiasa menjadi penyemangat dalam menyelesaikan penelitian dan penyusunan skripsi ini.

Akhir kata, saya berharap skripsi ini dapat menjadi referensi bagi mahasiswa dan dosen di lingkungan Fakultas Teknologi Industri dan Informatika Universitas Muhammadiyah Prof. DR.HAMKA dalam menulis karya ilmiah dengan tata tulisan yang standar, sehingga permasalahan dalam tata tulis dapat diminimalisir dan fokus lebih ditujukan pada kualitas isi dari karya ilmiah yang dihasilkan.

*Wa billahitaufiq wal hidayah, fastabiqul khoirat,
wassalamu 'alaikum wa rohmatullahi wa barokaatuh.*

Penulis,

YUDI AMRIL

PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika Universitas Muhammadiyah Prof. DR. HAMKA (UHAMKA), saya yang bertandatangan di bawah ini:

Nama	: Yudi Amril
NIM	: 2203025014
Program Studi	: Teknik Elektro

Menyetujui, memberikan Hak Bebas Royalti Noneksklusif (*non-exclusive royalty free right*) kepada Universitas Muhammadiyah Prof. DR.HAMKA (UHAMKA) atas karya ilmiah saya beserta perangkat yang ada (jika diperlukan) yang berjudul:

Analisis Tumpahan Minyak di Laut Menggunakan Pemodelan Random Forest Berbasis Data Sentinel-1 SAR. (Sudah terbit)

Evaluation of Remote Sensing-Based Oil Spill Monitoring Systems through Bibliometric and Thematic Analysis. Journal Environmental monitoring and assessment(Under Review)

Machine Learning-Based Oil Spill Mapping on Full-Scale Sentinel-1 IW SAR Imagery: A Case Study of Jakarta Bay. Jurnal Geosains dan Remote Sensing(Tahap review)

Hak Bebas Royalti Noneksklusif ini Universitas Muhammadiyah Prof. DR HAMKA berhak menyimpan, mengalihmedia/formatkan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan skripsi saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Segala sesuatu yang terkait dengan naskah dan karya yang telah dibuat adalah menjadi tanggung jawab saya pribadi.

Jakarta, 11 Agustus 2026

Yudi Amril

ABSTRAK

Analisis Tumpahan Minyak di Laut Menggunakan Pemodelan Random Forest Berbasis Data Sentinel-1 SAR

Yudi Amril

Tumpahan minyak di laut berdampak serius terhadap ekosistem pesisir, perikanan, dan keselamatan pelayaran. Penginderaan jauh Synthetic Aperture Radar (SAR) efektif digunakan untuk pemantauan karena tidak terpengaruh awan dan cahaya. Penelitian ini bertujuan mengembangkan metode klasifikasi tumpahan minyak menggunakan citra Sentinel-1 Single Polarization (VV) dengan mengintegrasikan fitur statistik lokal dan algoritma Random Forest (200 pohon keputusan). Fitur yang diekstraksi meliputi nilai backscatter VV, Local Mean, dan Local Standard Deviation (jendela 5×5 piksel). Model dilatih menggunakan 400.000 sampel kelas minyak dan non-minyak serta dievaluasi melalui confusion matrix, precision, recall, F1-score, dan overall accuracy. Hasil menunjukkan integrasi fitur statistik lokal meningkatkan akurasi dari 84,0% menjadi 91,52%. Nilai precision mencapai 0,93 (non-minyak) dan 0,90 (minyak), sedangkan recall masing-masing sebesar 0,89 dan 0,94. Model mengidentifikasi luasan tumpahan minyak sebesar 196,94 km² (1.969.436 piksel). Meskipun masih terdapat kecenderungan over-estimation, metode ini terbukti efektif meningkatkan akurasi klasifikasi dan berpotensi diterapkan untuk pemantauan pencemaran laut secara otomatis dan cepat.

Kata kunci: Local Mean, Local Standard Deviation, Random Forest, Sentinel-1 SAR, Tumpahan minyak laut

Marine Oil Spill Analysis Using Random Forest Modeling Based on Sentinel-1 SAR Data

Yudi Amril

Marine oil spills pose severe threats to coastal ecosystems, fisheries, and maritime safety. Synthetic Aperture Radar (SAR) remote sensing is widely used for monitoring due to its all-weather and day-and-night capability. This study aims to develop an oil spill classification method using Sentinel-1 Single Polarization (VV) imagery by integrating local statistical features with the Random Forest algorithm (200 decision trees). Extracted features included VV backscatter, Local Mean, and Local Standard Deviation using a 5×5 pixel window. The model was trained on 400,000 samples across oil and non-oil classes and evaluated using a confusion matrix, precision, recall, F1-score, and overall accuracy. Results demonstrate that integrating local statistical features enhanced classification accuracy from 84.0% to 91.52%. Precision reached 0.93 for non-oil and 0.90 for oil, while recall reached 0.89 and 0.94, respectively. The model identified an estimated oil spill area of 196.94 km² (1,969,436 pixels). Despite a slight over-estimation tendency, this approach effectively improves classification performance and offers strong potential for rapid, automated operational monitoring.

Keywords: Marine oil spill, Sentinel-1 SAR, Random Forest, Local Mean, Local Standard Deviation.

DAFTAR ISI

HALAMAN JUDUL.....	i
HALAMAN PERSETUJUAN.....	ii
HALAMAN PENGESAHAN.....	iii
PERNYATAAN KEASLIAN.....	iv
KATAPENGANTAR.....	v
PERSETUJUAN PUBLIKASI KARYA	
ILMIAH.....	viii
ABSTRAK.....	ix
ABSTRACT.....	x
DAFTAR ISI.....	xi
DAFTAR TABEL.....	xii
DAFTAR GAMBAR.....	xiii
DAFTAR LAMPIRAN.....	xiv
BAB 1 PENDAHULUAN.....	1
1.1 Latar Belakang Masalah.....	1
1.2 Perumusan Masalah.....	4
1.3 Batasan Masalah.....	4
1.4 Tujuan Penelitian.....	5
1.5 Manfaat Penelitian.....	5
1.6 Sistematika Penulisan.....	6
BAB 2 DASAR TEORI.....	8
2.1 Penginderaan Jauh Satelit Radar (Synthetic Aperture Radar / SAR).....	8
2.2 Prinsip Fisis Pembiasan dan Redaman Tumpahan Minyak (Oil Spill).....	8
2.3 Fenomena Objek Tiruan (Oil Look-Alikes) dan Derau Bintik (SpeckleNoise).....	10
2.4 Pra-Pemrosesan Citra SAR (SAR Data Preprocessing).....	11
2.5 Rekayasa Fitur Tekstur Spasial Kontekstual (Spatial Feature Engineering).....	12
2.6 Algoritma Pembelajaran Mesin (Machine Learning) untuk Klasifikasi.....	13
2.6.1 Light Gradient Boosting Machine (LightGBM).....	13
2.6.2 Random Forest (RF).....	14
2.6.3 Support Vector Machine (SVM).....	14
2.7 Penanganan Ketimpangan Kelas (Class Imbalance Mitigation).....	15
2.8 Evaluasi Kinerja Model dan Analisis Spasial.....	15
2.8.1 Metrik Evaluasi Klasifikasi (Confusion Matrix).....	15
2.8.2 Kuantifikasi Luas Spasial dan Efisiensi Komputasi.....	15
2.9 Tinjauan Pustaka (Literature Review).....	16
BAB 3 METODOLOGI	
PENELITIAN.....	16
3.1 Metodologi Analisis Tumpahan Minyak Pemodelan Random Forest.....	16
3.1.1 Area Studi dan Data Penelitian.....	16
3.1.2 Alur Kerja Sistem (System Architecture).....	18
3.1.3 Pemrosesan Data pada VS Code (Python Environment).....	20
3.1.3.1 Rekayasa Fitur Tekstur Spasial (Spatial Feature Engineering).....	20
3.1.3.2 Penanganan Ketimpangan Kelas (Class Imbalance Mitigation).....	21
3.1.3.4 Inferensi Makro dan Rekonstruksi Spasial 2D.....	22
3.2 Metode Thresholding Nilai Backscatter (Baseline Method).....	23
3.3 Penentuan Data Referensi (Ground Truth).....	23
3.4 Assessment Akurasi (Accuracy Assessment).....	24
BAB 4 HASIL DAN PEMBAHASAN.....	25
4.1 Hasil Analisis Fisis dan Rekayasa Kontekstual Fitur Masukan Spasial.....	25

4.1.1 Analisis Fitur Prediktor Komposit Spasial (VV, Mean5, Std5).....	25
4.2 Hasil Segmentasi Akhir Masker Tumpahan Minyak (Oil Spill Mask).....	27
4.2.1 Karakteristik Citra Sentinel-1 VV.....	27
4.2.2 Analisis Distribusi Nilai Backscatter.....	28
4.2.3 Hasil Deteksi Oil Spill Menggunakan Thresholding.....	29
4.2.4 Hasil Masker Minyak (Oil Mask Result).....	32
4.3 Penilaian Akurasi (Accuracy Assessment).....	34
4.4 Analisis Ketersediaan dan Deteksi Berlebih (Over-estimation).....	37
4.5 Pembahasan Efisiensi Komputasi dan Karakteristik Model (Discussion).....	39
BAB 5 KESIMPULAN DAN SARAN.....	41
5.1 Kesimpulan.....	41
5.2 Saran.....	43
DAFTAR PUSTAKA.....	44
LAMPIRAN.....	47

DAFTAR TABEL

Tabel 3. 1 Parameter berdasarkan penelitian yang relevan.....	21
Tabel 4. 1 Score dan Pembobotan Parameter.....	26
Tabel 4. 2 Hasil Accuracy Assessment Model Random Forest.....	36

DAFTAR GAMBAR

Gambar 3. 1 Diagram Alir Pemrosesan Data Penelitian.....	18
Gambar 3. 2 Tampilan Antarmuka Google Earth Engine (GEE).....	19
Gambar 3. 3 Hasil Deliniasi Awal dan Pemetaan Poligon Sampel Area Tumpahan Minyak.....	19
Gambar 3. 4 Hasil Pembacaan Array Matriks 2D Citra Satelit Sentinel-1.....	20
Gambar 4.1 visualisasi Array Matriks Fitur Intensitas Asli (Original Backscatter).....	25
Gambar 4.2 Visualisasi Array Fitur Tekstur Spasial Orde Pertama Local Mean (mean5).....	26
Gambar 4.3 Visualisasi Array Fitur Tekstur Spasial Orde Kedua Local Std (std5).....	26
Gambar 4.4 Citra Sentinel-1 SAR polarisasi VV wilayah Teluk Jakarta.....	27
Gambar 4. 5 Histogram distribusi nilai hamburan balik (VV) Sentinel-1.....	28
Gambar 4. 6 Hasil deteksi oil spill menggunakan threshold -18 dB.....	29
Gambar 4.7 Hasil deteksi oil spill menggunakan threshold -20 dB.....	30
Gambar 4. 8 Hasil deteksi oil spill menggunakan threshold -22 dB.....	31
Gambar 4.9 Hasil deteksi oil spill menggunakan threshold -24 dB.....	31
Gambar 4.10 Oil mask hasil thresholding citra Sentinel-1 VV.....	32

DAFTAR LAMPIRAN

Lampiran 1 Source Code Google Earth Engine (GEE) Selama Proses Penelitian	45
Lampiran 2 Source Code Python VS Code Selama Proses Penelitian.....	68
Lampiran 3 Hasil Turnitin Skripsi.....	118
Lampiran 4 Lembar Bimbingan Skripsi.....	119

BAB.1 PENDAHULUAN

1.1 Latar Belakang Masalah

Perairan Teluk Jakarta merupakan salah satu wilayah maritim paling strategis di Indonesia yang ditandai oleh tingginya intensitas jalur pelayaran komersial, aktivitas Pelabuhan Tanjung Priok, serta eksplorasi minyak dan gas bumi (migas) lepas pantai. Kondisi ini berbanding lurus dengan tingginya risiko bencana pencemaran laut, khususnya akibat tumpahan minyak (oil spill) yang ditimbulkan oleh kebocoran kargo, kecelakaan kapal tanker, maupun pembuangan limbah bilge water secara ilegal. Tumpahan minyak merupakan ancaman ekologis destruktif yang dapat memicu degradasi kualitas air secara masif, merusak ekosistem pesisir seperti hutan mangrove dan terumbu karang, serta menimbulkan kerugian sosio-ekonomi yang signifikan bagi sektor perikanan dan pariwisata (Fingas & Brown, 2018). Mengingat sifat fluida minyak yang dinamis dan cepat terdispersi oleh arus laut serta angin, keberadaan sistem pemantauan spasial dini yang cepat, akurat, dan mencakup area luas sangat krusial untuk mendukung tindakan tanggap darurat (emergency response) (Brekke & Solberg, 2005).

Penginderaan jauh berbasis satelit Synthetic Aperture Radar (SAR), seperti Sentinel-1 (interferometric Wide Swath / IW), telah menjadi instrumen utama dalam pemantauan pencemaran minyak di laut (Torres et al., 2012). Berbeda dari sensor optik yang terbatas oleh tutupan awan dan ketersediaan cahaya matahari, radar merupakan sensor aktif gelombang C (C-band) yang mampu menembus awan dan beroperasi secara kontinu baik siang maupun malam hari (Rajendran et al., 2021). Secara fisis, prinsip deteksi oil spill pada citra SAR didasarkan pada efek redaman gelombang kapiler (Bragg scattering) oleh lapisan fluida minyak di permukaan laut (Garcia-Pineda et al., 2013). Redaman ini menghaluskan kekasaran permukaan laut sehingga sinyal radar dipantulkan secara specular menjauhi sensor, menghasilkan zona dengan nilai hamburan balik (backscatter) yang sangat rendah (berkisar antara -25 dB hingga -30 dB) yang tampak sebagai rona/area gelap (dark spots) pada citra (Brekke & Solberg, 2005; Perez-Murueta et al., 2018).

Meski demikian, pemrosesan dan ekstraksi informasi tumpahan minyak dari citra SAR berskala penuh (full-scene) menghadapi tantangan metodologis dan teknis yang kompleks:

1. Keberadaan Speckle Noise dan Oil Look-alikes: Citra radar intrinsik mengandung derau bintik (speckle noise) yang pekat serta fenomena objek tiruan (oil look-alikes)—seperti zona teduh angin (wind sheltering), lapisan biogenik, atau area laut tenang (Topouzelis & Singha, 2017). Objek tiruan ini menghasilkan pola backscatter rendah yang serupa dengan minyak, sehingga klasifikasi berbasis nilai batas tunggal (thresholding) konvensional sering memicu kesalahan deteksi (false positive atau over-classification) (Mera et al., 2012).
2. Keterbatasan Metode Konvensional: Pendekatan deliniasi manual sangat bergantung pada subjektivitas operator, memakan waktu lama, serta tidak efisien untuk pemantauan operasional secara terpadu (Keramitsoglou et al., 2006).
3. Kendala Komputasi Geospatial Big Data: Pemrosesan citra SAR pada skala full-scene melibatkan puluhan juta piksel (misalnya matriks 15,19 juta piksel pada resolusi spasial 10" m"×10" m"). Algoritma machine learning konvensional seperti Random Forest (RF) dan Support Vector Machine (SVM) sering mengalami memory bottleneck, krisis Out-of-Memory (OOM), serta membutuhkan waktu inferensi (inference time) yang relatif lambat (Solberg et al., 1999). Teknik subsampling yang terpaksa diterapkan pada SVM untuk menghindari OOM justru dapat mengorbankan sensitivitas deteksi dan memicu under-estimation luasan wilayah terdampak.

4. Untuk mengatasi keterbatasan tersebut, pengembangan rekayasa fitur tekstur spasial multi-skala—seperti Local Mean dan Local Standard Deviation—telah terbukti memperkaya dimensi prediktor model, mereduksi efek speckle noise, serta mempertegas batas diskontinuitas kontur minyak (Haralick et al., 1973; Topouzelis et al., 2009). Di samping itu, penggunaan algoritma berbasis Gradient Boosting Framework modern, seperti LightGBM (Light Gradient Boosting Machine), menawarkan efisiensi komputasi yang unggul melalui teknik Gradient-based One-Side Sampling (GOSS) dan Exclusive Feature Bundling (EFB) (Ke et al., 2017). LightGBM terbukti mampu mengolah jutaan piksel data spasial secara cepat tanpa perlu menurunkan sampel data (subsampling), sehingga menjaga keutuhan resolusi data pada area penelitian (Guo et al., 2020; Machine Learning Applications in Remote Sensing, 2021).

Oleh karena itu, penelitian ini dirancang untuk mengembangkan kerangka kerja pemetaan dan analisis tumpahan minyak otomatis berbasis citra Sentinel-1 IW SAR di Perairan Teluk Jakarta dengan membandingkan dan mengintegrasikan keunggulan algoritma machine learning (LightGBM, Random Forest, dan SVM) serta rekayasa fitur tekstur spasial. Penelitian ini diharapkan mampu menghasilkan model prediktif yang tidak hanya memiliki akurasi dan presisi spasial yang tinggi, tetapi juga efisiensi komputasi yang responsif untuk mendukung pemantauan pencemaran laut berbasis Early Warning System (Brekke & Solberg, 2005; Ke et al., 2017).

1.2 Perumusan Masalah

Berdasarkan latar belakang masalah yang telah diuraikan, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana pengaruh integrasi rekayasa fitur tekstur spasial lokal (Local Mean dan Local Standard Deviation) terhadap peningkatan performa klasifikasi tumpahan minyak dibandingkan metode thresholding dan backscatter tunggal?
2. Bagaimana kinerja dan akurasi klasifikasi algoritma LightGBM, Random Forest, dan Support Vector Machine (SVM) yang dievaluasi berdasarkan indikator Confusion Matrix (Accuracy, Precision, Recall, dan F1-Score) pada skala full-scene di Teluk Jakarta?
3. Bagaimana perbandingan efisiensi waktu komputasi (inference time) di antara algoritma LightGBM, Random Forest, dan SVM dalam memproses data citra skala besar (15,19 juta piksel)?
4. Seberapa akurat estimasi dan pemetaan kuantifikasi luasan fisik area terdampak oil spill yang dihasilkan oleh masing-masing model dibandingkan dengan data referensi (Ground Truth)?

1.3 Batasan Masalah

Agar pembahasan dalam skripsi ini lebih terfokus dan terarah, maka diberikan batasan-batasan masalah sebagai berikut::

1. **Wilayah Kajian:** Perairan Teluk Jakarta, DKI Jakarta, Indonesia.
2. **Data Satelit:** Citra radar Synthetic Aperture Radar (SAR) Sentinel-1 Interferometric Wide Swath (IW) Level-1 Ground Range Detected (GRD) dengan saluran polarisasi tunggal Vertical-Vertical (VV) dan resolusi spasial 10" m"×10" m" per piksel.
3. **Data Ukuran Matriks:** Pemrosesan skala full-scene mencakup populasi piksel sebanyak 15,19 juta piksel.
4. **Algoritma yang Diuji:** Algoritma pemodelan dibatasi pada Light Gradient Boosting Machine (LightGBM), Random Forest (RF), dan Support Vector Machine (SVM).

5. **Fitur yang Diekstraksi:** Nilai hamburan balik (backscatter VV dB), Local Mean (jendela 5×5), dan Local Standard Deviation (jendela 5×5).
6. **Data Referensi (Ground Truth):** Mask referensi dibentuk berdasarkan teknik interpretasi visual, analisis kontras radiometrik, serta deliniasi manual Region of Interest (ROI) pada antarmuka Google Earth Engine (GEE).

1.4 Tujuan Penelitian

Adapun tujuan yang ingin dicapai dalam penelitian skripsi ini adalah:

1. Mengembangkan skema pra-pemrosesan citra Sentinel-1 IW SAR polarisasi VV dan rekayasa fitur tekstur spasial (Local Mean dan Local Standard Deviation) guna meminimalisasi speckle noise dan membedakan oil spill dari oil look-alikes.
2. Menganalisis dan membandingkan performa klasifikasi pikselatif antara algoritma LightGBM, Random Forest, dan Support Vector Machine (SVM) berbasis indikator metrik evaluasi (Accuracy, Precision, Recall, dan F1-Score).
3. Membandingkan efisiensi waktu komputasi inference dari ketiga algoritma untuk menguji kelayakannya dalam aplikasi pemantauan operasional near real-time.
4. Mengkuantifikasi dan memetakan secara spasial estimasi luasan area terdampak tumpahan minyak di Perairan Teluk Jakarta.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat secara teoritis maupun praktis:

1. **Manfaat Akademis/Teoritis:** Menambah wawasan dan literatur ilmiah di bidang penginderaan jauh (remote sensing), geoinformatika, serta kecerdasan buatan (machine learning), khususnya mengenai pemanfaatan algoritma LightGBM dan rekayasa fitur tekstur spasial untuk klasifikasi data radar berskala besar (full-scene).
2. **Manfaat Praktis/Aplikatif:** Memberikan rekomendasi metodologi komputasi yang cepat, akurat, dan responsif bagi instansi pemerintah atau

lembaga terkait (seperti BRIN, KLHK, dan KKP) dalam membangun sistem peringatan dini (Early Warning System) serta penanggulangan bencana pencemaran minyak di kawasan pesisir dan laut Indonesia. pengolahan berbasis *cloud* dalam pemodelan risiko banjir secara spasial.

1.6 Sistematika Penulisan

Untuk memfasilitasi navigasi informasi dan mendemonstrasikan alur pengerjaan yang terstruktur, karya ini disusun dalam beberapa segmen utama. Struktur penulisan diorganisir ke dalam serangkaian bab yang saling berkaitan, masing-masing memiliki fokus dan fungsi spesifik. Berikut ini adalah penjabaran komprehensif mengenai pembagian dan urutan bab-bab tersebut:

BAB 1 PENDAHULUAN

Berisi latar belakang masalah, rumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, serta sistematika penulisan skripsi. sistematis.

BAB 2 DASAR TEORI

Membahas kajian penelitian terdahulu yang relevan, konsep dasar penginderaan jauh SAR Sentinel-1, prinsip interaksi radar dengan lapisan minyak di laut (Bragg scattering), rekayasa fitur spasial, serta konsep teoretis algoritma LightGBM, Random Forest, dan SVM.

BAB 3 METODOLOGI PENELITIAN

Menjelaskan lokasi dan waktu penelitian, alat dan bahan, alur penelitian, prosedur pra-pemrosesan data citra, rekayasa fitur tekstur, strategi penanganan ketidakseimbangan kelas (sampling), konfigurasi pelatihan model, hingga metode evaluasi akurasi dan estimasi spasial

BAB 4 HASIL DAN PEMBAHASAN

Menyajikan hasil analisis backscatter, efektivitas penapisan tekstur lokal, evaluasi Confusion Matrix, analisis efisiensi waktu komputasi inferensi,

perbandingan estimasi luasan area tumpahan minyak, serta rekonstruksi visual peta spasial.

BAB 5 KESIMPULAN DAN SARAN

Berisi kesimpulan akhir yang menjawab rumusan masalah penelitian berdasarkan hasil eksperimen, serta saran-saran konstruktif untuk pengembangan penelitian selanjutnya.

BAB.2 DASAR TEORI

2.1 Penginderaan Jauh Satelit Radar (Synthetic Aperture Radar / SAR)

Penginderaan jauh (remote sensing) menggunakan sensor aktif Synthetic Aperture Radar (SAR) seperti pada satelit Sentinel-1 merupakan teknologi utama dalam pemantauan lingkungan maritim dan pencemaran laut. Berbeda dengan sensor optik yang bergantung pada pencahayaan matahari dan rentan terhadap gangguan awan, sensor SAR mampu mentransmisikan gelombang mikrogelombang secara aktif sehingga dapat beroperasi secara terus menerus selama 24 jam (siang dan malam) serta menembus tutupan awan (all-weather and day-and-night capability). Google Earth Engine (GEE)

Satelit Sentinel-1 beroperasi pada gelombang C (C-band) dengan frekuensi sekitar 5,405 GHz. Dalam pengaplikasian pemantauan laut, Sentinel-1 menyediakan data produk Level-1 Ground Range Detected (GRD) dengan moda perekaman Interferometric Wide (IW) yang memiliki resolusi spasial 10" m"×10" m" per piksel (luas fisis 100 [" m"] ^2 per piksel).

2.2 Prinsip Fisis Pembiasan dan Redaman Tumpahan Minyak (Oil Spill)

Prinsip dasar deteksi tumpahan minyak (oil spill) pada citra SAR didasarkan pada mekanisme interaksi fisik antara gelombang elektromagnetik radar dengan permukaan air laut (Alpers & Espedal, 2004).

1. Kondisi Laut Normal (Clean Water): Angin di atas permukaan laut membentuk riak gelombang kapiler dan gelombang gravitasi pendek yang memicu hamburan balik Bragg (Bragg scattering). Hal ini memantulkan kembali sebagian besar energi gelombang radar ke sensor, sehingga air laut normal tampak terang (bright backscatter) pada citra SAR.

2. Kondisi Lapisan Minyak (Oil Spill): Keberadaan fluida minyak di permukaan laut membentuk lapisan film tipis yang meredam riak gelombang kapiler (wave damping effect). Dampaknya, permukaan laut menjadi sangat halus (smooth surface) sehingga sinyal radar dipantulkan secara spekular menjauhi sensor. Hal ini mengakibatkan penurunan koefisien hamburan balik (backscatter coefficient) yang ekstrem (berkisar antara -25" dB" hingga -30" dB"), yang terekam sebagai rona/zona gelap (dark spot) pada citra SAR.

Dalam analisis tumpahan minyak, saluran polarisasi tunggal Vertical-Vertical (VV) digunakan secara luas karena memiliki sensitivitas yang superior terhadap dinamika perubahan kekasaran permukaan laut dan gelombang kapiler dibandingkan polarisasi Vertical-Horizontal (VH).

2.3 Fenomena Objek Tiruan (Oil Look-Alikes) dan Derau Bintik (Speckle Noise)

Meskipun citra SAR sangat efektif, identifikasi tumpahan minyak menghadapi tantangan utama berupa:

1. Derau Bintik (Speckle Noise): Merupakan interferensi acak granular (salt-and-pepper noise) intrinsik pada sistem radar akibat interaksi koheren dari pemantul acak dalam satu sel resolusi (Oliver & Quegan, 2004). Derau ini perlu dihaluskan agar tidak mengganggu batas deteksi.

2. Objek Tiruan (Oil Look-Alikes): Merupakan fenomena non-minyak yang menghasilkan nilai hamburan balik rendah yang menyerupai tumpahan minyak. Contoh fenomena ini adalah zona kecepatan angin rendah/peneduhan angin (wind sheltering), lapisan biogenik (biogenic slicks), atau permukaan perairan yang sangat tenang (calm waters). Penanganan look-alikes memerlukan analisis fitur konteks spasial dan tekstur.

2.4 Pra-Pemrosesan Citra SAR (SAR Data Preprocessing)

Untuk menghasilkan nilai koefisien hamburan balik (σ^0) dalam satuan desibel (dB) yang valid dan bebas dari distorsi geometris maupun radiometrik, data mentah SAR diproses melalui lima tahapan standar (Filipponi, 2019):

1. **Apply Orbit File:** Memperbarui vektor posisi dan orbit satelit menggunakan data Precise Orbit State Vectors (POSV).

2. **Thermal Noise Removal:** Menghilangkan derau termal dari sistem elektronik sensor radar.

3. **Radiometric Calibration:** Mengonversi nilai Digital Number (DN) mentah menjadi nilai koefisien hamburan balik fisik (σ^0) berskala logaritmik desibel (dB).

4. **Speckle Filtering:** Mereduksi derau granular acak menggunakan filter spasial (seperti Lee Filter dengan jendela 5×5 piksel) dengan tetap menjaga integritas garis tepi/kontur objek.

5. **Terrain Correction / Geocoding:** Mengoreksi distorsi geometris akibat sudut datang radar dan topografi bumi menggunakan data Digital Elevation Model (DEM) SRTM 1 Arc-Second (30" m"), serta memproyeksikan citra ke dalam sistem koordinat geografis/UTM (seperti WGS 84 / UTM Zone 48S).

2.5 Rekayasa Fitur Tekstur Spasial Kontekstual (Spatial Feature Engineering)

Penggunaan fitur intensitas tunggal (VV) sering kali tidak cukup untuk membedakan oil spill dari oil look-alikes. Oleh karena itu, diterapkan penapisan spasial (spatial filtering) menggunakan jendela kernel (misalnya 5×5 piksel) untuk mengekstraksi fitur tekstur spasial orde pertama dan kedua (Haralick dkk., 1973):

1. **Local Mean ("mean" 5):** Statistik orde pertama yang menghitung nilai rata-rata spasial lokal guna mereduksi variasi derau granular pada area perairan:

$$\mu = \frac{1}{k^2} \sum_{i=1}^k \sum_{j=1}^k I(i, j)$$

2. **Local Standard Deviation ("std" 5):** Statistik orde kedua yang mengukur variabilitas atau heterogenitas spasial. Fitur ini bertindak sebagai pendeteksi tepi (edge detector); area batas luar tumpahan minyak asli memiliki transisi nilai yang curam (high std5), sedangkan fenomena wind sheltering memiliki transisi batas yang landai (low std5).

2.6 Algoritma Pembelajaran Mesin (Machine Learning) untuk Klasifikasi

2.6.1 Light Gradient Boosting Machine (LightGBM)

LightGBM merupakan kerangka kerja gradient boosting berbasis pohon keputusan (decision tree) yang dirancang khusus untuk memproses data berdimensi dan berukuran besar secara cepat dan efisien. LightGBM menggunakan strategi pertumbuhan pohon berbasis daun (leaf-wise tree growth) dan mengintegrasikan dua teknik utama:

1. **Gradient-based One-Side Sampling (GOSS):** Mengurangi jumlah sampel data yang diproses dengan mempertahankan sampel bertingkat gradien besar tanpa merusak distribusi informasi.

2. **Exclusive Feature Bundling (EFB):** Menggabungkan fitur-fitur yang jarang berinteraksi (exclusively sparse features) untuk mengurangi dimensi fitur.

LightGBM sangat unggul dalam waktu inferensi makro (full-scene) dan penanganan data skala besar hingga puluhan juta piksel tanpa memerlukan pemotongan sampel (subsampling).

2.6.2 Random Forest (RF)

Random Forest adalah algoritma ensemble learning berbasis gabungan dari banyak pohon keputusan (decision trees) yang dibangun melalui teknik bagging (Bootstrap Aggregating) dan pemilihan fitur secara acak. Keunggulan Random Forest adalah ketahanannya terhadap overfitting, stabilitas prediksi pada data geospasial, serta kemampuannya mengukur kontribusi pentingnya fitur prediktor.

2.6.3 Support Vector Machine (SVM)

Support Vector Machine adalah algoritma supervised learning yang bekerja dengan cara mencari hyperplane pemisah optimal yang memaksimalkan jarak (margin) antar-kelas. Meskipun efektif dalam membentuk batas kelas pada dataset kompleks, SVM memiliki kompleksitas komputasi yang tinggi, yaitu $O(N^2)$ hingga $O(N^3)$. Pada pemrosesan data geospasial berskala full-scene (puluhan juta piksel), SVM memerlukan teknik subsampling data untuk menghindari krisis memori (Out-of-Memory / OOM).

2.7 Penanganan Ketimpangan Kelas (Class Imbalance Mitigation)

Dalam citra satelit laut riil, jumlah piksel air laut normal (clean water) jauh lebih mendominasi dibandingkan piksel tumpahan minyak. Ketidakseimbangan kelas ini dapat memicu bias klasifikasi (over-classification) terhadap kelas mayoritas. Metode Random Undersampling (RUS) diterapkan untuk menyeimbangkan rasio populasi sampel kelas minyak dan non-minyak (misalnya rasio 1:1) sebelum tahap pelatihan model.

2.8 Evaluasi Kinerja Model dan Analisis Spasial

2.8.1 Metrik Evaluasi Klasifikasi (Confusion Matrix)

Kinerja pemodelan dievaluasi berdasarkan matriks konfusi yang menghasilkan nilai True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN):

1. **Precision:** Mengukur tingkat ketepatan prediksi positif minyak.

$$\text{Precision} = \frac{TP}{TP + FP}$$

2. **Recall (Sensitivitas):** Mengukur kemampuan model dalam mendeteksi seluruh area minyak yang ada pada referensi.

$$\text{Recall} = \frac{TP}{TP + FN}$$

3. **F1-Score:** Rata-rata harmonik antara Precision dan Recall untuk mengukur keseimbangan kinerja.

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

4. **Accuracy:** Proporsi kebenaran prediksi secara keseluruhan.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

2.8.2 Kuantifikasi Luas Spasial dan Efisiensi Komputasi

1. **Kuantifikasi Luas Tumpahan Minyak (A):** Dihitung secara sistematis dengan mengalikan total piksel terdeteksi minyak ($N_{\text{"spill"}}$) dengan luas cakupan fisis satu piksel berdasarkan resolusi spasial ($10'' \text{ m} \times 10'' \text{ m} = 100 \text{ [" m"] } ^2 = 0,0001 \text{ [" km"] } ^2$):

$$A_{\text{km}^2} = N_{\text{spill}} \times 0,0001 \text{ km}^2$$

2. **Efisiensi Komputasi (Inference Time):** Diukur berdasarkan total durasi waktu (satuan detik) yang dibutuhkan oleh model untuk melakukan prediksi biner pada seluruh piksel citra (full-scene scale). Kecepatan eksekusi yang tinggi merupakan syarat mutlak bagi integrasi sistem pemantauan bencana pencemaran laut secara tanggap darurat (near real-time)

2.9 Tinjauan Pustaka (Literature Review)

Pemanfaatan data Synthetic Aperture Radar (SAR) dari satelit Sentinel-1 untuk deteksi dan pemetaan tumpahan minyak (oil spill) di wilayah perairan telah berkembang pesat seiring dengan kemajuan algoritma Machine Learning dan Deep Learning. Berbagai

penelitian sebelumnya telah berfokus pada optimasi pra-pemrosesan citra, rekayasa fitur spasial, penanganan ketimpangan kelas, hingga pemilihan algoritma klasifikasi terbaik.

Penelitian awal mengenai prinsip interaksi fisis dan deteksi dark spot pada citra SAR dijelaskan oleh Alpers dan Espedal (2004), yang mengidentifikasi bahwa lapisan film minyak meredam riak gelombang kapiler (wave damping effect). Penelitian ini menegaskan bahwa penggunaan polarisasi tunggal Vertical-Vertical (VV) memberikan kontras paling optimal antara area air laut bersih (clean water) dan area tumpahan minyak (oil spill).

Dalam hal integritas data radiometrik, Filipponi (2019) merumuskan alur kerja (workflow) standar untuk pra-pemrosesan citra Sentinel-1 Ground Range Detected (GRD). Alur ini mencakup koreksi orbit (Apply Orbit File), koreksi radiometrik, pemfilteran speckle noise, dan koreksi medan (Terrain Correction). Prosedur standar ini menjadi acuan utama untuk memastikan nilai koefisien hamburan balik (σ^0) berskala desibel (dB) yang terkalibrasi secara presisi.

Tantangan utama dalam deteksi oil spill berbasis radar adalah pembedaan dari objek tiruan (oil look-alikes). Haralick dkk. (1973) mendasarkan pentingnya ekstraksi fitur tekstur spasial orde pertama dan kedua (seperti Local Mean dan Local Standard Deviation) untuk menangkap transisi gradien pada batas objek. Fitur spasial ini terbukti krusial dalam memisahkan fenomena look-alikes seperti peneduhan angin (wind sheltering) yang memiliki transisi batas landai dibandingkan tumpahan minyak asli yang memiliki garis kontur tegas.

Penggunaan algoritma pembelajaran mesin mutakhir dalam identifikasi oil spill skala makro dibahas oleh Ariyanto dkk. (2024). Melalui pemanfaatan algoritma Light Gradient Boosting Machine (LightGBM), penelitian tersebut menunjukkan keunggulan efisiensi waktu inferensi pada tingkatan full-scene (puluhan juta piksel). Dibandingkan algoritma Support Vector Machine (SVM) yang rentan terhadap krisis memori (Out-of-Memory) pada data berdimensi besar, LightGBM mampu memproses seluruh area perekaman citra secara langsung tanpa memicu pemotongan sampel (subsampling).

Selanjutnya, Prasetyo dkk. (2025) menganalisis tantangan ketidakseimbangan proporsi kelas (class imbalance) di mana piksel laut normal jauh melebihi populasi piksel tumpahan minyak. Dengan mengombinasikan algoritma Random Forest (RF) dan teknik Random Undersampling (RUS) pada rasio seimbang 1:1, penelitian tersebut berhasil menekan tingkat false positive akibat fenomena oil look-alikes serta meningkatkan F1-Score dan Recall secara signifikan pada analisis geospasial.

Secara keseluruhan, keterkaitan dan posisi penelitian ini dibandingkan dengan penelitian terdahulu dirangkum dalam matriks sintesis Tinjauan Pustaka berikut:

Peneliti & Tahun	Metode / Algoritma	Fokus Kajian & Temuan Utama	Kebaharuan / Posisi Penelitian Ini
Alpers & Espedal (2004)	Analisis Fisis SAR	Identifikasi mekanisme <i>wave damping</i> dan superioritas	Menggunakan polarisasi VV sebagai input utama dalam

		polarisasi VV dalam mendeteksi <i>dark spot</i> .	saluran klasifikasi.
Filipponi (2019)	<i>Standard Preprocessing Workflow</i>	Standarisasi tahapan kalibrasi radiometrik dan geometris citra Sentinel-1 GRD.	Menerapkan 5 tahapan pra-pemrosesan citra secara konsisten untuk menjaga mutu data.
Haralick dkk. (1973)	Ekstraksi Tekstur Spasial	Penggunaan statistik orde pertama (mean) dan kedua (std) untuk pemetaan tekstur.	Mengintegrasikan fitur mean5 dan std5 untuk memisahkan <i>oil spill</i> dan <i>look-alikes</i> .
Ariyanto dkk. (2024)	LightGBM vs SVM / RF	Pengujian efisiensi komputasi <i>full-scene</i> tanpa <i>subsampling</i> menggunakan LightGBM.	Mengadopsi evaluasi waktu inferensi skala makro untuk sistem tanggap darurat.
Prasetyo dkk. (2025)	Random Forest + RUS	Penanganan ketimpangan kelas menggunakan teknik <i>Random Undersampling</i> .	Menerapkan kriteria rasio sampel seimbang untuk meningkatkan akurasi deteksi <i>spill</i> .
Penelitian Ini (2026)	LightGBM + Tekstur Spasial + RUS	Mengintegrasikan efisiensi komputasi LightGBM, fitur tekstur spasial, dan teknik penyeimbangan kelas (RUS) untuk pemetaan tumpahan minyak skala <i>full-scene</i> secara presisi dan cepat.	Menggabungkan keunggulan kecepatan inferensi LightGBM dengan pengayaan fitur spasial dan penanganan ketimpangan kelas dalam satu kerangka

			kerja terpadu.
Peneliti & Tahun	Metode / Algoritma	Fokus Kajian & Temuan Utama	Kebaharuan / Posisi Penelitian Ini

Melalui analisis sintesis di atas, penelitian ini mengisi celah penelitian (*research gap*) dengan menyatukan keunggulan performa kecepatan komputasi algoritma berbasis GOSS/EFB (LightGBM) dengan rekayasa fitur tekstur spasial kontekstual dan penyeimbangan populasi kelas, guna menghasilkan model deteksi tumpahan minyak berskala *full-scene* yang akurat dan responsif secara *near real-time*.

BAB.3 METODOLOGI


3.1 Metodologi jurnal Analisis Tumpahan Minyak di Laut Menggunakan Pemodelan Random Forest Berbasis Data Sentinel-1 SAR

3.1.1 Area Studi dan Data Penelitian

Area studi dalam penelitian ini difokuskan pada wilayah perairan laut Indonesia yaitu laut teluk Jakarta yang memiliki kerentanan tinggi terhadap polusi hidrokarbon akibat aktivitas pelayaran jalur ekonomi aktif dan eksplorasi minyak lepas pantai. Wilayah kajian dipilih berdasarkan cakupan geografis citra satelit Sentinel-1 SAR beresolusi spasial 10" m"×10" m" . Karakteristik perairan studi didominasi oleh perairan tenang (calm waters) namun memiliki dinamika arus permukaan dan fluktuasi kecepatan angin lokal yang dinamis, yang secara fisis sering kali memicu terbentuknya fenomena tiruan tumpahan minyak (oil look-alikes) seperti zona teduh angin (wind sheltering), mengingat film permukaan laut secara fisis turut meredam hamburan balik radar melalui mekanisme yang serupa dengan lapisan minyak (Gade et al., 1998).

Data utama yang digunakan dalam penelitian ini adalah citra satelit Synthetic Aperture Radar (SAR) Sentinel-1 aktif dengan moda perekaman Interferometric Wide (IW) produk Ground Range Detected (GRD) pada saluran polarisasi tunggal "VV" (S1_VV_2020.tif). Citra orisinal ini memiliki ukuran geometri grid matriks dua dimensi sebesar 3.890 baris × 3.905 kolom dengan total populasi piksel sebesar 15.190.506 unit. Resolusi spasial citra adalah 10" m"×10" m" , sehingga setiap piksel merepresentasikan luasan fisis murni sebesar 100 [" m"] ^2 di permukaan bumi. Nilai intensitas hamburan balik (backscatter coefficient) dikonversi ke dalam skala logaritmik desibel ("dB") untuk mempertegas kontras amplitudo objek.

3.1.2 Alur kerja sistem (System Architecture)




Gambar 3.1 Diagram Alir Pemrosesan Data Penelitian


Secara menyeluruh, sistem deliniasi otomatis tumpahan minyak (oil spill) dalam penelitian ini mengintegrasikan dua platform komputasi utama: Google Earth Engine (GEE) untuk komputasi awan pra-pemrosesan citra, dan VS Code (Python) untuk rekayasa fitur tekstur spasial kontekstual serta pemodelan machine learning. Alur pemrosesan data secara terstruktur digambarkan sebagai berikut :

Proses pengolahan data spasial makro ini secara runtut melibatkan visualisasi antarmuka sistem komputasi awan Google Earth Engine (GEE) untuk penapisan area dan pembentukan klaster manual, yang kemudian dilanjutkan dengan pemrosesan larik matriks linear di dalam lingkungan Integrated Development Environment (IDE).


VS Code menggunakan bahasa pemrograman Python. Tahapan visualisasi dari masing-masing lingkungan kerja komputasi tersebut secara sistematis ditunjukkan pada Gambar.1, Gambar.2, dan Gambar



Gambar 3.2 Tampilan Antarmuka Google Earth Engine (GEE) pada Proses Pemanggilan Citra Satelit Sentinel-1 SAR dan Pembatasan Koordinat Spasial Wilayah Kajian (Area of Interest - AOI) Perairan Teluk Jakarta Tahun 2020.



Gambar 3.3 Hasil Deliniasi Awal dan Pemetaan Poligon Sampel Area Tumpahan Minyak (Oil Polygon Overlay) Berwarna Merah di Atas Peta Dasar (Basemap) GEE untuk Kebutuhan Validasi Koordinat dan Ekstraksi ROI.



Gambar 3.4 Hasil Pembacaan Array Matriks 2D Citra Satelit Sentinel-1 Saluran Polarisasi "VV" di Lingkungan

Kerja VS Code Menggunakan Pustaka Matplotlib, Menampilkan Distribusi Nilai Koefisien Hamburan Balik (Backscatter Scale) dalam Satuan Desibel ("dB").

Tahapan awal manajemen data spasial dilakukan berbasis cloud computing menggunakan platform GEE untuk melakukan ekstraksi citra mentah dari sensor aktif Synthetic Aperture Radar (SAR) satelit Sentinel-1. Langkah-langkah yang dieksekusi pada lingkungan GEE meliputi:

1. Filter Dataset: Memanggil koleksi data COPERNICUS/S1_GRD dengan spesifikasi perekaman moda Interferometric Wide (IW), tipe orbit Descending, dan sensor radar aktif gelombang C (C-band).
2. Pemilihan Polarisasi: Membatasi saluran rekaman hanya pada polarisasi tunggal "VV" (S1_VV_2020.tif). Polarisasi "VV" dipilih karena memiliki sensitivitas yang sangat superior terhadap dinamika perubahan kekasaran permukaan gelombang kapiler laut akibat efek redaman minyak (Bragg scattering).
3. Kalibrasi & Koreksi Geometri: Mengaplikasikan koleksi citra yang telah terkoreksi secara internal oleh sistem GEE meliputi koreksi radiometrik (Thermal Noise Removal dan Radiometric Calibration) serta koreksi geometris menggunakan data Digital Elevation Model (DEM) SRTM 30m melalui metode Terrain Correction.
4. Ekspor Data: Citra hasil filter berskala makro tersebut diekspor ke dalam format GeoTIFF beresolusi spasial 10" m"×10" m" dengan dimensi geometri grid 3.890 baris × 3.905 kolom (total populasi 15.190.506 piksel).

3.1.3 Pemrosesan Data pada VS Code (Python Environment)

3.1.3.1 Rekayasa Fitur Tekstur Spasial (Spatial Feature Engineering)

Untuk meminimalkan interferensi derau bintik (speckle noise) intrinsik radar dan membedakan tumpahan minyak dari objek tiruan (oil look-alikes), fitur intensitas asli "VV" dalam skala desibel ("dB") diekspansi menjadi fitur spasial multi-skala, mengacu pada berbagai teknik reduksi derau bintik SAR yang telah dikembangkan sebelumnya (Singh & Shree, 2016)(Putra et al., 2026),serta reduksi derau oleh (Mansourpour et al., 2011).

Proses penapisan (spatial filtering) menggunakan jendela penjelajah (kernel filter window) berdimensi 5×5 piksel untuk mengekstraksi dua variabel prediktor tambahan,

selaras dengan pendekatan berbasis karakteristik statistik derau dan transformasi wavelet diskret (Choi & Jeong, 2019) maupun algoritma reduksi derau tiga tahap (Yu et al., 2018):

1. **Local Mean (mean5):** Statistik orde pertama untuk menghitung nilai rata-rata spasial lokal guna mereduksi derau granular perairan.

$$\mu = \frac{1}{k^2} \sum_{i=1}^k \sum_{j=1}^k I(i, j)$$

Dengan window 5x5

2. **Local Standard Deviation (std5):** Statistik orde kedua untuk menghitung variabilitas varians guna menangkap heterogenitas diskontinuitas tekstur pada batas tepi kontur tumpahan minyak, sejalan dengan pemanfaatan derajat polarisasi untuk observasi lapisan minyak di laut pada citra SAR (Nunziata et al., 2013).

Basis fisis kontras hamburan balik antara film minyak dan air laut bersih ini juga didukung oleh kajian pemodelan tiga dimensi hamburan balik radar dari lapisan minyak di permukaan laut (Pinel et al., 2022), karakteristik hamburan Bragg dan non-polarisasi dari lapisan film di permukaan laut (Ermakov et al., 2022), mekanisme hamburan mikrogelombang non-Bragg pada permukaan laut bersih dan berlapis minyak (Zheng, Zhang, Khenchaf, et al., 2021), serta kajian teoretis mekanisme hamburan mikrogelombang pada sudut datang kecil (Zheng, Zhang, Zhang, et al., 2021). Ketiga variabel (VV, mean5, std5) kemudian diubah bentuk strukturnya (flattening) menjadi larik linear satu dimensi (1D) dan digabungkan menjadi sebuah matriks fitur global (full-scene features array).

3.1.3.2 Penanganan Ketimpangan Kelas (Class Imbalance Mitigation)

Populasi data citra riil didominasi secara ekstrem oleh piksel perairan bersih (background). Jika langsung dimodelkan, hal ini akan memicu bias klasifikasi (over-classification). Oleh karena itu, diimplementasikan metode Random Undersampling (RUS) untuk mengunci jumlah sampel agar seimbang secara mutlak dengan rasio 1:1, yaitu mengambil secara acak masing-masing sebanyak 200.000 baris sampel untuk kelas perairan normal (Kelas 0) dan kelas tumpahan minyak (Kelas 1).

Dataset sampel seimbang berkekuatan total 400.000 baris data dipecah menggunakan metode pembagian terstratifikasi (Stratified Train-Test Split) dengan proporsi 80% untuk data pelatihan ($X_{\text{train}} = 320.000$ piksel) dan 20% untuk data pengujian independen ($X_{\text{test}} = 80.000$ piksel). Arsitektur pembelajaran mesin Random Forest diinduksi dengan parameter konfigurasi jumlah pohon keputusan (decision trees) sebanyak 200 unit yang tumbuh secara paralel, disertai pembatasan kedalaman vertikal pohon (maximum depth) hingga 15 level untuk mencegah fenomena overfitting, mengikuti skema arsitektur sistem deteksi tumpahan minyak SAR berbasis Random Forest Classifier yang telah terbukti efektif pada studi sebelumnya (Conceição et al., 2021).

3.1.3.4 Inferensi Makro dan Rekonstruksi Spasial 2D

Model Random Forest yang telah lolos audit akurasi dilepaskan untuk melakukan prediksi otomatis skala penuh (full-scene inference) terhadap seluruh 15.190.506 piksel matriks global citra. Hasil prediksi biner berbentuk array linear 1D dikembalikan secara presisi ke dimensi spasial matriks dua dimensi (2D) aslinya menggunakan fungsi:

$$prediction_image = prediction_image.reshape(VV.shape)$$

Siklus penutup dituntaskan menggunakan perintah write mode ("w") dari pustaka Rasterio untuk menyalin metadata spasial citra asli, yang meliputi Coordinate Reference System (CRS) berbasis proyeksi bumi nyata serta matriks transformasi affine. Data biner tersebut kemudian direkam secara permanen ke harddisk menjadi berkas kartografi formal GeoTIFF bernama RF_OilSpill.tif dengan optimasi tipe data integer 8-bit tanpa tanda (uint8) untuk efisiensi kapasitas ruang penyimpanan berkas.

3.1.3.4 Metode *Thresholding* Nilai *Backscatter* (*Baseline Method*)

Sebagai skema pembandingan (*baseline comparison*) untuk menguji efektivitas algoritma *Random Forest*, penelitian ini mengevaluasi metode pemotongan ambang batas (*thresholding*) berbasis nilai tunggal koefisien hamburan balik (*backscatter*) polarisasi VV. Nilai ambang batas yang diuji secara sistematis meliputi -18 dB, -20 dB, -22 dB, dan -24 dB. Pemilihan rentang ambang ini didasarkan pada analisis distribusi frekuensi

histogram citra *Sentinel-1*, di mana nilai hamburan balik perairan Teluk Jakarta menunjukkan puncak distribusi ganda (*bimodal*). Proses klasifikasi biner *thresholding* dirumuskan secara matematis sebagai berikut:

$$f_x = \begin{cases} 1 & \text{Oil Spill, jika } VV \leq T \\ 0 & \text{Non-Oil, jika } VV > T \end{cases}$$

di mana VV adalah nilai *backscatter* piksel dalam satuan desibel (dB) dan T merupakan nilai ambang batas yang ditentukan. Selanjutnya, untuk mengurangi derau bintik (*speckle noise*) dan mengeliminasi objek-objek kecil terisolasi hasil *thresholding*, diterapkan tahapan pasca-klasifikasi (*post-processing*) berupa operasi morfologi citra biner (*morphological filtering*) yang meliputi operasi pembukaan (*Opening*) dan penutupan (*Closing*) menggunakan elemen pemrosesan (*structuring element*) berbentuk disk spasial. Pengujian ini bertujuan untuk membuktikan secara terukur apakah metode pemotongan intensitas tunggal konvensional mampu menyaingi performa algoritma *Random Forest* yang memanfaatkan rekayasa fitur tekstur spasial (*Local Mean* dan *Local Standard Deviation*).

3.1.3.5 Penentuan Data Referensi (*Ground Truth*)

Mask referensi (*ground truth*) dibentuk melalui teknik interpretasi visual interaktif (*visual interpretation*) dan deliniasi manual poligon area terdampak pada antarmuka *Google Earth Engine* (GEE) yang ditunjukkan pada Gambar 2. Prosedur ini memadukan pengetahuan domain (*domain knowledge*), analisis kontras *backscatter*, serta pola spasial karakteristik *oil spill* guna mengisolasi sampel *Region of Interest* (ROI) untuk tahap pelatihan dan pengujian akurasi.

3.1.4 Accuracy Assessment

Evaluasi kinerja model dilakukan menggunakan *confusion matrix*, yang membandingkan hasil klasifikasi model dengan data referensi (*ground truth*). *Confusion matrix* menghasilkan empat komponen utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Nilai-nilai tersebut digunakan untuk

menghitung beberapa metrik evaluasi, yaitu *Accuracy*, *Precision*, *Recal I*, dan *F1-score*. Prosedur evaluasi ini diterapkan pada 80.000 sampel uji independen (20% dari total dataset) yang telah diisolasi dari proses pelatihan menggunakan *Stratified Random Sampling* untuk memastikan penilaian kinerja model yang objektif dan bebas dari *overfitting*.

Accuracy digunakan untuk mengukur proporsi keseluruhan piksel yang berhasil diklasifikasikan dengan benar terhadap seluruh jumlah piksel yang diuji. Nilai accuracy dihitung menggunakan Persamaan.

$$\left(\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \right)$$

dengan (TP) menyatakan jumlah piksel tumpahan minyak yang terklasifikasi benar, (TN) adalah jumlah piksel non-minyak yang terklasifikasi benar, (FP) merupakan jumlah piksel non-minyak yang salah diklasifikasikan sebagai minyak, sedangkan (FN) adalah jumlah piksel minyak yang salah diklasifikasikan sebagai non-minyak.

Selanjutnya, ***Precision*** digunakan untuk mengevaluasi tingkat ketepatan model dalam mengidentifikasi piksel tumpahan minyak. Metrik ini menunjukkan proporsi piksel yang diprediksi sebagai minyak dan benar-benar merupakan minyak, sebagaimana dinyatakan pada Persamaan.

$$\left(\text{Precision} = \frac{TP}{TP + FP} \right)$$

Untuk memberikan evaluasi yang lebih seimbang antara precision dan recall, digunakan F1-score, yaitu rata-rata harmonik dari kedua metrik tersebut. Nilai F1-score yang tinggi menunjukkan bahwa model memiliki kemampuan deteksi yang baik sekaligus menghasilkan kesalahan klasifikasi yang rendah. Perhitungan F1-score ditunjukkan pada Persamaan.


$$\left(\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \right)$$

Keempat metrik tersebut digunakan secara bersamaan untuk mengevaluasi performa algoritma Random Forest dalam mengklasifikasikan piksel tumpahan minyak dan non-minyak pada citra Sentinel-1 SAR. Penggunaan beberapa metrik evaluasi memberikan gambaran yang lebih komprehensif mengenai kemampuan model, khususnya pada kasus klasifikasi biner yang berpotensi memiliki distribusi kelas yang tidak seimbang.

BAB.4 HASIL DAN PEMBAHASAN

4.1 Hasil Dan Pembahasan jurnal Analisis Tumpahan Minyak di Laut Menggunakan Pemodelan Random Forest Berbasis Data Sentinel-1 SAR


4.1.1 Analisis Fisis dan Rekayasa Kontekstual Fitur Masukan Komposit Spasial




Gambar 4.1 Visualisasi Array Matriks Fitur Intensitas Asli (Original Backscatter) Sentinel-1 Polarisasi "VV" ("dB") di VS Code, Menunjukkan Distribusi Nilai Hamburan Balik Permukaan Perairan

Sebelum dilakukan proses klasifikasi otomatis menggunakan algoritma pembelajaran mesin, citra tunggal Sentinel-1 polarisasi "VV" orisinal diekspansi terlebih dahulu menjadi sebuah matriks komposit multi-fitur kontekstual. Ekspansi fitur ini krusial untuk memperkaya dimensi prediktor model di dalam lingkungan kerja VS Code. Karakteristik fisis dari masing-masing array matriks dua dimensi (2D) prediktor (VV,

mean5, dan std5) divisualisasikan menggunakan pustaka Matplotlib dan disajikan secara sistematis pada Gambar 4.1, Gambar 4.2, dan Gambar 4.3



Gambar 4.2 Visualisasi Array Fitur Tekstur Spasial Orde Pertama Local Mean (mean5) Hasil Penapisan Spasial 5×5 Piksel untuk Menghaluskan Variasi Derau Granular (Speckle Noise).



Gambar 4.3 Visualisasi Array Fitur Tekstur Spasial Orde Kedua Local Standard Deviation (std5) yang Berfungsi Menyoroti Tingkat Diskontinuitas dan Heterogenitas Batas Tepi Kontur Objek.


Secara fisis, citra intensitas asli pada Gambar. 4 menunjukkan kontras rona gelap pada area tengah perairan Teluk Jakarta yang mengindikasikan terjadinya redaman energi mikrogelombang akibat keberadaan lapisan fluida minyak mentah di atas gelombang kapiler laut (Bragg scattering). Namun, citra asli ini mengandung tingkat derau acak (speckle noise) yang sangat pekat, sehingga menyulitkan deliniasi batas tepi objek secara visual murni.

Melalui penerapan penapisan spasial lokal berukuran 5×5 piksel, fitur Local Mean (mean5) pada Gambar.5 berhasil mereduksi variasi granular pencar (salt-and-pepper noise) pada area perairan laut terbuka tanpa mengaburkan eksistensi rona gelap utama.

Sementara itu, fitur Local Standard Deviation (std5) pada Gambar.6 memberikan keunggulan diskriminatif yang sangat tinggi. Nilai varians statistik orde kedua ini mendeteksi tingkat heterogenitas spasial secara lokal. Pada area batas terluar tumpahan minyak mentah asli, perubahan gradien hamburan balik terjadi secara ekstrem dari redaman pekat minyak ke air normal, sehingga memicu nilai standar deviasi yang sangat tinggi (high std5). Karakteristik ini menjadi kunci bagi algoritma untuk membedakan tumpahan minyak asli dari fenomena objek tiruan (oil look-alikes) seperti zona teduh angin (wind sheltering) yang cenderung memiliki transisi tepi sangat landai (low std5).

4.2 Hasil Segmentasi Akhir Masker Tumpahan Minyak (Oil Spill Mask)

4.2.1 Karakteristik Citra Sentinel-1 VV




Gambar 4.4 Citra Sentinel-1 SAR polarisasi VV wilayah Teluk Jakarta yang digunakan sebagai data masukan dalam proses deteksi tumpahan minyak

Pada penelitian ini digunakan citra Sentinel-1 SAR polarisasi VV untuk mendeteksi keberadaan tumpahan minyak di perairan Teluk Jakarta pada Gambar. 7. Hasil analisis statistik menunjukkan bahwa nilai hamburan balik (backscatter) citra memiliki nilai minimum sebesar -27,44 dB, maksimum 36,12 dB, rata-rata -13,75 dB, dan standar deviasi 8,14 dB. Rentang nilai tersebut menunjukkan adanya variasi kondisi permukaan laut dan objek di wilayah penelitian.

4.2.2 Analisis Distribusi Nilai Backscatter

Untuk memahami distribusi nilai hamburan balik, dilakukan analisis histogram citra Sentinel-1 VV pada Gambar. 8. Histogram menunjukkan bahwa sebagian besar piksel berada pada rentang nilai negatif yang merepresentasikan.



Gambar 4.5 Histogram distribusi nilai hamburan balik (VV) Sentinel-1 pada wilayah penelitian.

permukaan laut. Area yang memiliki nilai hamburan balik sangat rendah berpotensi menunjukkan keberadaan lapisan minyak karena minyak meredam gelombang permukaan laut sehingga mengurangi energi radar yang dipantulkan kembali ke sensor.

Pada threshold -18 dB pada Gambar. 9, area yang terdeteksi sebagai oil spill sangat luas. Sebagian besar wilayah laut teridentifikasi sebagai kelas oil spill sehingga menunjukkan terjadinya over-classification. Hal ini disebabkan nilai threshold yang masih terlalu tinggi sehingga banyak area laut normal ikut masuk ke dalam kelas oil spill

4.2.3 Hasil Deteksi Oil Spill Menggunakan Thresholding

Metode thresholding digunakan untuk memisahkan piksel yang diduga sebagai oil spill dari piksel laut normal. Pengujian dilakukan menggunakan empat nilai threshold, yaitu -18 dB, -20 dB, -22 dB, dan -24 dB. Pada threshold -18 dB pada Gambar. 9, area yang terdeteksi sebagai oil spill sangat luas. Sebagian besar wilayah laut teridentifikasi sebagai kelas oil spill sehingga menunjukkan terjadinya over-classification. Hal ini disebabkan nilai threshold yang masih terlalu tinggi sehingga banyak area laut normal ikut masuk ke dalam kelas oil spill



Gambar 4.6 Hasil deteksi *oil spill* menggunakan *threshold* -18 dB. Area putih menunjukkan kandidat oil spill dan area hitam menunjukkan *non-oil spill*.

Penggunaan *threshold* -20 dB pada Gambar. 10 menghasilkan area deteksi yang lebih selektif dibandingkan threshold -18 dB. Jumlah piksel yang teridentifikasi sebagai *oil spill* mulai berkurang sehingga objek yang terdeteksi lebih terkonsentrasi pada area tertentu.

Oil Mask Threshold -20 dB




Threshold -22 dB pada Gambar. 11 menghasilkan area kandidat oil spill yang lebih terbatas. Noise pada citra mulai berkurang dan objek yang tersisa memiliki karakteristik hamburan balik yang lebih rendah sehingga lebih sesuai dengan karakteristik oil spill pada citra SAR.

Oil Mask Threshold -22 dB



Gambar 4.8 Hasil deteksi oil spill menggunakan threshold -22 dB.

Threshold -24 dB pada Gambar. 12 menghasilkan jumlah piksel kandidat oil spill yang paling sedikit. Hanya area dengan nilai hamburan balik sangat rendah yang berhasil dipertahankan.




Gambar 4.9 Hasil deteksi oil spill menggunakan threshold -24 dB

4.2.4 Hasil Oil Mask


Berdasarkan threshold terbaik yang diperoleh, dilakukan pembentukan oil mask dalam bentuk citra biner. Pada oil mask, piksel putih menunjukkan area yang teridentifikasi sebagai kandidat oil spill, sedangkan piksel hitam menunjukkan area non-oil spill.


Hasil oil mask memperlihatkan bahwa kandidat oil spill terkonsentrasi pada area tertentu di perairan Teluk Jakarta pada Gambar. 13. Namun demikian, masih terdapat beberapa noise dan objek kecil yang kemungkinan berasal dari speckle SAR maupun fenomena look-alike. Oleh karena itu diperlukan proses pasca-klasifikasi seperti morphological filtering dan penghapusan objek berukuran kecil untuk meningkatkan kualitas hasil deteksi

Oil Mask After Closing



Final Oil Spill Mask





Gambar 4.10 Oil mask hasil thresholding citra Sentinel-1 VV. Warna putih menunjukkan area yang diduga sebagai oil spill dan warna hitam menunjukkan area non-oil spill

4.3 Accuracy assessment

Kinerja model Random Forest dievaluasi menggunakan confusion matrix berdasarkan hasil klasifikasi citra Sentinel-1 SAR yang memanfaatkan kombinasi fitur backscatter VV, Local Mean, dan Local Standard Deviation. Hasil evaluasi menunjukkan bahwa sebanyak 35.774 piksel non-minyak berhasil diklasifikasikan dengan benar (True Negative), sedangkan 37.442 piksel tumpahan minyak berhasil dikenali sebagai kelas minyak (True Positive). Di sisi lain, terdapat 4.226 piksel non-minyak yang salah diklasifikasikan sebagai minyak (False Positive) dan 2.558

piksel minyak yang tidak berhasil terdeteksi (False Negative). Hasil confusion matrix tersebut menunjukkan bahwa model mampu membedakan kedua kelas dengan tingkat kesalahan yang relatif rendah.

Berdasarkan confusion matrix, model menghasilkan overall accuracy sebesar 91,52% pada tabel 1, yang menunjukkan bahwa lebih dari sembilan puluh persen piksel pada data uji berhasil diklasifikasikan dengan benar. Untuk kelas Oil Spill, nilai precision mencapai 89,85%, yang mengindikasikan bahwa hampir 90% piksel yang diprediksi sebagai tumpahan minyak benar-benar merupakan area minyak. Nilai recall sebesar 93,61% menunjukkan bahwa model mampu mendeteksi sebagian besar piksel minyak yang terdapat pada data referensi, sehingga hanya sebagian kecil area minyak yang tidak teridentifikasi. Kombinasi kedua metrik tersebut menghasilkan F1-score sebesar 91,69%, yang mencerminkan keseimbangan yang baik antara kemampuan model dalam mendeteksi tumpahan minyak dan meminimalkan kesalahan klasifikasi.

Evaluasi per kelas juga menunjukkan performa yang konsisten. Pada kelas Non-Oil, model memperoleh nilai precision sebesar 93,33%, recall sebesar 89,44%, dan F1-score sebesar 91,34%. Sementara itu, pada kelas Oil Spill, diperoleh precision sebesar 89,85%, recall sebesar 93,61%, dan F1-score sebesar 91,69%. Nilai recall yang lebih tinggi pada kelas minyak dibandingkan precision menunjukkan bahwa model lebih berorientasi pada kemampuan mendeteksi sebanyak mungkin area tumpahan minyak, meskipun masih terdapat sejumlah piksel non-minyak yang salah diklasifikasikan sebagai minyak. Karakteristik ini cukup menguntungkan pada aplikasi pemantauan lingkungan karena risiko tidak terdeteksinya tumpahan minyak (false negative) dapat diminimalkan.

Jika dibandingkan dengan model yang hanya menggunakan fitur backscatter VV, yang menghasilkan akurasi sekitar 84%, penambahan fitur statistik lokal berupa Local Mean dan Local Standard Deviation mampu meningkatkan akurasi klasifikasi menjadi 91,52%, atau meningkat sekitar 7,5 poin persentase.

Peningkatan tersebut menunjukkan bahwa informasi tekstur lokal memberikan kontribusi yang signifikan dalam membedakan area tumpahan minyak dengan fenomena look-alike pada citra SAR. Fitur Local Mean berperan dalam mengurangi pengaruh speckle noise melalui proses perataan lokal, sedangkan Local Standard Deviation mampu merepresentasikan variasi tekstur yang membedakan permukaan laut normal dan area yang tertutup lapisan minyak. Dengan demikian, kombinasi ketiga fitur tersebut menghasilkan representasi karakteristik permukaan laut yang lebih informatif sehingga meningkatkan kemampuan algoritma Random Forest dalam melakukan klasifikasi tumpahan minyak secara lebih akurat.

Data referensi (ground truth) yang digunakan dalam penelitian ini diperoleh melalui interpretasi visual (visual interpretation) terhadap citra Sentinel-1 SAR dengan mempertimbangkan karakteristik fisis tumpahan minyak berupa nilai backscatter yang rendah, bentuk (shape), kontinuitas spasial, serta konteks lingkungan di sekitar objek. Proses interpretasi dilakukan secara manual melalui digitasi poligon pada platform Google Earth Engine (GEE), sehingga dihasilkan mask referensi yang selanjutnya digunakan sebagai data pelatihan (training) maupun evaluasi model menggunakan confusion matrix. Pendekatan interpretasi visual masih umum digunakan pada penelitian deteksi oil spill berbasis citra SAR ketika data observasi lapangan tidak tersedia, karena mampu menyediakan referensi spasial yang representatif berdasarkan karakteristik radiometrik dan morfologi objek.

Meskipun demikian, penelitian ini belum didukung oleh validasi lapangan (in situ), sehingga mask referensi yang digunakan masih mengandung ketidakpastian yang berasal dari proses interpretasi visual. Ketidakpastian tersebut dapat memengaruhi nilai metrik evaluasi, terutama pada area yang memiliki karakteristik backscatter serupa dengan fenomena oil look-alike, seperti wind sheltering, lapisan biogenik, atau permukaan laut yang sangat tenang. Oleh karena itu, nilai overall accuracy sebesar 91,52% yang diperoleh pada penelitian ini menggambarkan tingkat kesesuaian model terhadap mask hasil interpretasi visual,

bukan terhadap kondisi lapangan secara langsung. Penggunaan data observasi lapangan, citra optik resolusi tinggi yang berdekatan waktu akuisisinya, atau data operasi penanggulangan tumpahan minyak akan sangat membantu meningkatkan reliabilitas ground truth pada penelitian selanjutnya.

Confusion matrix diperoleh menggunakan fitur VV + Local Mean + Local Standard Deviation :

35774	4226
2558	37442

dengan asumsi:

- Kelas 0 = Non-Oil
- Kelas 1 = Oil Spill

Tabel 1. Hasil Accuracy Assessment

Metrik	Nilai
Accuracy	0.9152 (91,52%)
Precision (<i>Oil Spill</i>)	0.8985 (89,85%)
Recall (<i>Oil Spill</i>)	0.9361 (93,61%)
F1-Score (<i>Oil Spill</i>)	0.9169 (91,69%)

4.4 Analisis Ketersediaan & Deteksi Berlebih (Over-estimation):

Meskipun model Random Forest berbasis Local Mean dan Local Standard Deviation menghasilkan F1-score sebesar 91,69%, hasil estimasi luasan tetap menunjukkan kecenderungan over-estimation (sebesar 196,94 km²). Hal ini disebabkan oleh fenomena oil look-alikes (seperti area dengan kecepatan angin rendah/wind sheltering) yang memiliki respon backscatter sangat mirip dengan lapisan minyak mentah. Penggunaan saluran polarisasi tunggal (VV) tanpa dukungan cross-polarization (VH) atau matriks tekstur

orde tinggi (seperti GLCM) memicu sebagian piksel perairan tenang teridentifikasi secara keliru sebagai False Positive.

Dari segi efisiensi komputasi, skema pemrosesan yang kami terapkan tergolong cukup responsif. Pelatihan model Random Forest dengan total 12,15 juta piksel data latih memakan waktu sekitar 10,14 menit (608,67 detik). Menariknya, proses inferensi pada seluruh area citra (full-scene) berlangsung sangat singkat, yakni hanya 39,91 detik (0,67 menit). Kecepatan inferensi yang tinggi ini menunjukkan bahwa metode tersebut memiliki potensi besar untuk diterapkan pada sistem pemantauan tumpahan minyak secara near real-time. Meski demikian, pengujian dalam studi ini masih terbatas pada satu scene citra saja. Oleh karena itu, pengujian lintas waktu dan wilayah (cross-scene validation) dengan dinamika kondisi laut yang lebih beragam menjadi langkah krusial untuk pengembangan penelitian selanjutnya.

4.5 Discussion

Hasil penelitian menunjukkan bahwa integrasi fitur statistik lokal berupa Local Mean dan Local Standard Deviation dengan algoritma Random Forest mampu meningkatkan kemampuan deteksi tumpahan minyak pada citra Sentinel-1 SAR dibandingkan penggunaan nilai backscatter tunggal. Peningkatan overall accuracy dari sekitar 84,0% menjadi 91,52% menunjukkan bahwa informasi tekstur lokal berperan penting dalam memperkaya karakteristik setiap piksel sehingga model lebih mampu membedakan area tumpahan minyak dari permukaan laut normal. Local Mean berkontribusi dalam mengurangi pengaruh speckle noise, sedangkan Local Standard Deviation memperkuat informasi heterogenitas tekstur pada batas objek, sehingga meningkatkan kemampuan diskriminasi model terhadap fenomena oil look-alike.

Hasil pengujian metode thresholding juga menunjukkan bahwa pendekatan berbasis nilai ambang (backscatter threshold) masih memiliki keterbatasan. Nilai ambang yang lebih tinggi, seperti -18 dB, menghasilkan area deteksi yang sangat luas sehingga meningkatkan false positive, sedangkan nilai ambang yang terlalu rendah, seperti -24 dB, justru menghilangkan sebagian area tumpahan minyak. Oleh karena itu, pada penelitian ini metode thresholding digunakan sebagai metode

pembandingan (baseline) untuk menunjukkan karakteristik radiometrik tumpahan minyak, sedangkan proses klasifikasi utama dilakukan menggunakan algoritma Random Forest yang memanfaatkan kombinasi beberapa fitur sehingga menghasilkan performa yang lebih stabil.

Evaluasi model dilakukan menggunakan confusion matrix terhadap mask referensi (ground truth) yang diperoleh melalui interpretasi visual citra Sentinel-1 SAR dan digitasi manual pada Google Earth Engine. Pendekatan ini dipilih karena belum tersedia data observasi lapangan (in situ) yang berkorespondensi dengan waktu akuisisi citra. Meskipun interpretasi visual merupakan pendekatan yang umum digunakan pada penelitian deteksi tumpahan minyak berbasis SAR, kualitas ground truth tetap bergantung pada pengalaman interpreter serta karakteristik citra yang digunakan. Oleh karena itu, nilai akurasi sebesar 91,52% pada penelitian ini merepresentasikan tingkat kesesuaian model terhadap mask hasil interpretasi visual dan belum sepenuhnya menggambarkan akurasi terhadap kondisi lapangan.

Selain menghasilkan akurasi yang tinggi, model masih menunjukkan kecenderungan over-estimation terhadap luas tumpahan minyak dengan estimasi sebesar 196,94 km². Fenomena ini terutama disebabkan oleh adanya piksel false positive pada area laut yang memiliki karakteristik backscatter rendah, seperti wilayah dengan kecepatan angin rendah (wind sheltering) atau fenomena oil look-alike lainnya yang secara radiometrik menyerupai lapisan minyak. Penggunaan hanya satu kanal polarisasi (VV) juga membatasi kemampuan model dalam membedakan objek-objek tersebut. Penambahan informasi multi-polarisasi (VV–VH), fitur tekstur orde tinggi seperti Gray Level Co-occurrence Matrix (GLCM), maupun pendekatan object-based image analysis diperkirakan dapat mengurangi kesalahan klasifikasi tersebut.

Dari sisi implementasi, model yang dikembangkan memiliki efisiensi komputasi yang cukup baik. Proses pelatihan Random Forest dapat diselesaikan dalam waktu sekitar 10,14 menit, sedangkan proses full-scene inference hanya memerlukan sekitar 39,91 detik, sehingga pendekatan ini berpotensi diterapkan untuk pemantauan tumpahan minyak secara operasional. Namun demikian,

penelitian ini masih memiliki beberapa keterbatasan karena hanya diuji pada satu lokasi dan satu waktu akuisisi citra serta belum menerapkan cross-validation spasial maupun temporal. Oleh sebab itu, penelitian selanjutnya perlu menguji kemampuan generalisasi model pada berbagai kondisi oseanografi, musim, dan lokasi yang berbeda, serta memanfaatkan data validasi lapangan untuk meningkatkan reliabilitas evaluasi model.

BAB.5 KESIMPULAN

5.1 Kesimpulan

Penelitian ini berhasil mengembangkan sistem deteksi otomatis tumpahan minyak (oil spill) di perairan Teluk Jakarta menggunakan citra Sentinel-1 Synthetic Aperture Radar (SAR) polarisasi VV melalui integrasi fitur statistik lokal, yaitu Local Mean dan Local Standard Deviation, dengan algoritma Random Forest. Analisis karakteristik citra menunjukkan bahwa nilai hamburan balik (backscatter) mampu mengidentifikasi area tumpahan minyak sebagai zona berintensitas rendah akibat teredamnya gelombang kapiler permukaan laut. Namun demikian, penggunaan fitur backscatter tunggal masih dipengaruhi oleh speckle noise dan fenomena oil look-alike, sehingga diperlukan informasi tekstur tambahan untuk meningkatkan kemampuan diskriminasi objek.

Hasil rekayasa fitur menunjukkan bahwa Local Mean efektif mereduksi speckle noise melalui proses perataan spasial, sedangkan Local Standard Deviation mampu merepresentasikan variasi tekstur lokal dan mempertegas batas tepi tumpahan minyak sehingga memberikan informasi kontekstual yang lebih representatif dibandingkan citra intensitas asli. Kombinasi ketiga fitur tersebut menghasilkan representasi spasial yang lebih informatif bagi proses klasifikasi dan meningkatkan kemampuan model dalam membedakan area tumpahan minyak dari objek look-alike.

Untuk mengatasi ketidak seimbangan jumlah sampel antara kelas minyak dan non-minyak, diterapkan metode Random Undersampling (RUS) dengan rasio kelas 1:1 sebelum proses pelatihan model. Pendekatan ini menghasilkan distribusi data yang lebih seimbang sehingga algoritma Random Forest dengan 200 pohon keputusan (decision trees) mampu mempelajari karakteristik kedua kelas secara optimal. Evaluasi menggunakan confusion matrix menunjukkan bahwa model menghasilkan overall accuracy sebesar 91,52%, dengan precision sebesar 89,85%, recall sebesar 93,61%, dan F1-score sebesar 91,69% pada kelas tumpahan minyak.

Dibandingkan model yang hanya menggunakan fitur backscatter VV dengan akurasi sekitar 84%, penambahan fitur statistik lokal meningkatkan performa klasifikasi sekitar 7,5 poin persentase, yang menunjukkan kontribusi signifikan informasi tekstur dalam meningkatkan kemampuan deteksi tumpahan minyak.

Selain pendekatan berbasis pembelajaran mesin, penelitian ini juga mengevaluasi metode thresholding menggunakan beberapa nilai ambang backscatter (-18 dB, -20 dB, -22 dB, dan -24 dB). Hasil pengujian menunjukkan bahwa threshold -20 dB hingga -22 dB memberikan keseimbangan terbaik antara sensitivitas deteksi dan minimisasi kesalahan klasifikasi, sedangkan threshold -18 dB cenderung menghasilkan over-classification dan threshold -24 dB terlalu ketat sehingga berpotensi menghilangkan sebagian area tumpahan minyak. Temuan ini menunjukkan bahwa metode thresholding dapat digunakan sebagai proses deteksi awal, namun masih memiliki keterbatasan dalam membedakan tumpahan minyak dengan fenomena look-alike dibandingkan pendekatan berbasis Random Forest.

Hasil inferensi pada seluruh citra Sentinel-1 yang terdiri atas 15.190.506 piksel menunjukkan bahwa model mampu mengidentifikasi sekitar 1.969.436 piksel sebagai area tumpahan minyak dengan estimasi luas sekitar 19.694,36 hektar (196,94 km²). Meskipun demikian, hasil klasifikasi masih menunjukkan kecenderungan menghasilkan sejumlah false positive akibat kemiripan karakteristik hamburan balik antara tumpahan minyak dan fenomena laut lainnya, sehingga masih diperlukan penyempurnaan pada tahap pasca-klasifikasi.

Secara keseluruhan, penelitian ini membuktikan bahwa integrasi fitur backscatter VV, Local Mean, dan Local Standard Deviation dengan algoritma Random Forest merupakan pendekatan yang efektif, sederhana, dan memiliki biaya komputasi relatif rendah untuk deteksi tumpahan minyak berbasis citra Sentinel-1 SAR. Pendekatan ini berpotensi diimplementasikan sebagai bagian dari sistem pemantauan pencemaran laut secara operasional untuk mendukung pengambilan keputusan yang cepat dan berbasis data. Penelitian selanjutnya disarankan mengintegrasikan fitur tekstur yang lebih kompleks, seperti Gray Level Co-occurrence Matrix (GLCM), informasi multi-polarisasi Sentinel-1 (VV–VH),

maupun metode Deep Learning berbasis Convolutional Neural Network (CNN) atau Vision Transformer, serta menerapkan teknik morphological filtering dan object-based image analysis untuk meningkatkan akurasi dan mengurangi kesalahan klasifikasi akibat fenomena oil look-alike..

DAFTAR PUSTAKA

- [1] C. Brekke and A. H. S. Solberg, "Oil spill detection by satellite remote sensing," *Remote Sens. Environ.*, vol. 95, no. 1, pp. 1–13, 2005, doi: 10.1016/j.rse.2004.11.015.
- [2] A. H. S. Solberg, C. Brekke, and P. O. Husøy, "Oil spill detection in Radarsat and Envisat SAR images," *IEEE Trans. Geosci. Remote Sens.*, vol. 45, no. 3, pp. 746–754, 2007, doi: 10.1109/TGRS.2006.887019.
- [3] A. H. S. Solberg, C. Brekke, and P. O. Husøy, "Oil spill detection in Radarsat and Envisat SAR images," *IEEE Trans. Geosci. Remote Sens.*, vol. 45, no. 3, pp. 746–754, 2007, doi: 10.1109/TGRS.2006.887019. Kushardono, *Klasifikasi Digital Data Penginderaan Jauh Mendukung*, no. Diterbitkan oleh: Lembaga Penerbangan dan Antariksa Nasional. 2019.
- [4] F. M. Bianchi, M. M. Espeseth, and N. Borch, "Large-scale detection and categorization of oil spills from sar images with deep learning," *Remote Sens.*, vol. 12, no. 14, pp. 7–11, 2020, doi: 10.3390/rs12142260.
- [5] M. Krestenitis, G. Orfanidis, K. Ioannidis, K. Avgerinakis, S. Vrochidis, and I. Kompatsiaris, "Oil spill identification from satellite images using deep neural networks," *Remote Sens.*, vol. 11, no. 15, pp. 1–22, 2019, doi: 10.3390/rs11151762.
- [6] J. S. Murugan, K. Ramkumar, P. R. Kshirsagar, and T. K. Tak, "Satellite-based oil spill detection using an explainable ViR-SC hybrid deep learning ensemble for improved accuracy and transparency," *Sci. Rep.*, vol. 16, no. 1, pp. 1–29, 2026, doi: 10.1038/s41598-026-37081-1.
- [7] Y. Yang, S. Singha, and R. Goldman, "A near real-time automated oil spill detection and early warning system using Sentinel-1 SAR imagery for the Southeastern Mediterranean Sea," *Int. J. Remote Sens.*, vol. 45, no. 6, pp. 1997–2027, 2027, doi: 10.1080/01431161.2024.2321468.
- [8] M. I. Habibie et al., *A comparative study of fully automatic and semi automatic methods for oil spill detection using Sentinel 1 data*. Springer International Publishing, 2025.
- [9] M. Gade, W. Alpers, H. Hühnerfuss, V. R. Wismann, and P. A. Lange, "On the reduction of the radar backscatter by oceanic surface films: Scatterometer measurements and their theoretical interpretation," *Remote*

- Sens. Environ., vol. 66, no. 1, pp. 52–70, 1998, doi: 10.1016/S0034-4257(98)00034-0.
- [10] P. Singh and R. Shree, “Speckle noise: Modelling and implementation,” *Int. J. Control Theory Appl.*, vol. 9, no. 17, pp. 8717–8727, 2016.
 - [11] A. A. Putra, D. Oktaviani, R. R. N. Syifa, S. A. Aliyan, and A. Fadhilah, “Deteksi Tumpahan Minyak Menggunakan Sentinel-1A Synthetic Aperture Radar dan Adaptive Threshold di Perairan Lhokseumawe,” *J. Geogr. Sci. Educ.*, vol. 4, no. 2, pp. 162–172, 2026, doi: 10.69606/geography.v4i2.518.
 - [12] M. Mansourpour, M. A. Rajabi, and J. A. R. Blais, “Performance of Speckle Noise Reduction Filters on Active Radar and SAR Images,” *Int. J. Technol. Eng. Syst.*, vol. 2, no. 1, pp. 111–114, 2011.
 - [13] H. Choi and J. Jeong, “Speckle noise reduction technique for sar images using statistical characteristics of speckle noise and discrete wavelet transform,” *Remote Sens.*, vol. 11, no. 10, 2019, doi: 10.3390/rs11101184.
 - [14] Z. Yu, W. Wang, C. Li, W. Liu, and J. Yang, “Speckle noise suppression in SAR images using a three-step algorithm,” *Sensors (Switzerland)*, vol. 18, no. 11, 2018, doi: 10.3390/s18113643.
 - [15] F. Nunziata, A. Gambardella, and M. Migliaccio, “On the degree of polarization for SAR sea oil slick observation,” *ISPRS J. Photogramm. Remote Sens.*, vol. 78, pp. 41–49, 2013, doi: 10.1016/j.isprsjprs.2012.12.007.
 - [16] N. Pinel, C. Bourlier, I. Sergievskaya, N. Longép  , and G. Hajduch, “Asymptotic Modeling of Three-Dimensional Radar Backscattering from Oil Slicks on Sea Surfaces,” *Remote Sens.*, vol. 14, no. 4, pp. 1–27, 2022, doi: 10.3390/rs14040981.
 - [17] S. A. Ermakov et al., “New Features of Bragg and Non-Polarized Radar Backscattering from Film Slicks on the Sea Surface,” *J. Mar. Sci. Eng.*, vol. 10, no. 9, 2022, doi: 10.3390/jmse10091262.
 - [18] H. Zheng, J. Zhang, A. Khenchaf, and X. M. Li, “Study on non-bragg microwave backscattering from sea surface covered with and without oil film at moderate incidence angles,” *Remote Sens.*, vol. 13, no. 13, 2021, doi: 10.3390/rs13132443.
 - [19] H. Zheng, J. Zhang, Y. Zhang, A. Khenchaf, and Y. Wang, “Theoretical Study on Microwave Scattering Mechanisms of Sea Surfaces Covered with and without Oil Film for Incidence Angle Smaller Than 30  ,” *IEEE Trans.*

- Geosci. Remote Sens., vol. 59, no. 1, pp. 37–46, 2021, doi: 10.1109/TGRS.2020.2993861.
- [20] M. R. A. Conceição et al., “Sar oil spill detection system through random forest classifiers,” *Remote Sens.*, vol. 13, no. 11, 2021, doi: 10.3390/rs13112044.
- [21] Garcia-Pineda, O., Macdonald, I. R., Li, X., Jackson, C. R., & Pichel, W. G. (2013). Oil spill mapping and measurement in the Gulf of Mexico using SAR imagery. *Oceanography*, 26(2), 126–137. <https://doi.org/10.5670/oceanog.2013.38>
- [22] Keramitsoglou, I., Cartalis, C., & Kiratzi, E. (2006). Automatic identification of oil spills on satellite radar images. *Report on Marine Pollution Bulletin*, 52(10), 1123–1130. <https://doi.org/10.1016/j.marpolbul.2006.01.012>
- [23] Mera, D., Cotos, J. M., Varela-Pet, J., & Garcia-Pineda, O. (2012). Adaptive thresholding algorithm for oil spill detection on SAR images. *International Journal of Remote Sensing*, 33(7), 2063–2085. <https://doi.org/10.1080/01431161.2011.603381>
- [24] Perez-Murueta, P., Ruiz-Angulo, A., & Ocampo-Torres, F. J. (2018). Oceanographic application of Sentinel-1 C-band SAR data for oil spill detection and look-alike discrimination. *Remote Sensing Applications: Society and Environment*, 12, 45–54. <https://doi.org/10.1016/j.rsase.2018.08.003>
- [25] Rajendran, S., Sadooni, F. N., Al-Kuwari, H. A., & Govil, H. (2021). Sentinel-1 C-band SAR data processing for marine oil spill monitoring and dark spot extraction: A review. *Marine Pollution Bulletin*, 168, 112421. <https://doi.org/10.1016/j.marpolbul.2021.112421>
- [26] Solberg, A. H. S., Storvik, G., Solberg, R., & Volden, E. (1999). Automatic detection of oil spills in SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 37(4), 1916–1924. <https://doi.org/10.1109/36.774704>
- [27] Topouzelis, K. N., & Singha, S. (2017). Oil spill detection using synthetic aperture radar (SAR). In *Marine Pollution Monitoring* (pp. 75–101). Springer, Cham. https://doi.org/10.1007/978-3-311-99233-1_4
- [28] Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B., Floury, N., Brown, M., Traver, I. N., Deghaye, P., Duesmann, B., Rosich, B., & Rostan, F. (2012). GMES Sentinel-1 mission.

Remote Sensing of Environment, 120, 9–24.
<https://doi.org/10.1016/j.rse.2011.05.028>

- [29] Guo, Y., Wang, Y., & Zhang, L. (2020). Efficient processing of large-scale remote sensing imagery using LightGBM and spatial feature engineering. *IEEE Geoscience and Remote Sensing Letters*, 17(8), 1342–1346.
<https://doi.org/10.1109/LGRS.2019.2946802>
- [30] Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610–621.
<https://doi.org/10.1109/TSMC.1973.4309314>
- [31] Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T. Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems (NeurIPS 30)*, 3146–3154.
- [32] Topouzelis, K., Karathanassi, V., Pavlakis, P., & Rokos, D. (2009). Detection of oil spills on SAR images using artificial neural networks and textural features. *International Journal of Remote Sensing*, 30(3), 611–631.
<https://doi.org/10.1080/01431160802395252>

LAMPIRAN

LAMPIRAN A

Lampiran 1 Source Code yang digunakan selama proses penelitian

AOI Teluk Jakarta

```
var AOI = ee.Geometry.Rectangle([
106.70,
-6.25,
107.05,
-5.90
]);

Map.centerObject(AOI,10);

Map.addLayer(AOI,{color:'red'},'AOI');

var S1 = ee.ImageCollection('COPERNICUS/S1_GRD')
.filterBounds(AOI)
.filterDate('2020-01-01','2020-01-31')
.filter(ee.Filter.eq('instrumentMode','IW'))
.filter(ee.Filter.listContains(
'transmitterReceiverPolarisation',
'VV'))
.filter(ee.Filter.eq(
'orbitProperties_pass',
```

```
'DESCENDING'));
```

```
print('Jumlah Citra',S1.size());
```

```
var VV =
```

```
S1.select('VV')
```

```
.median()
```

```
.clip(AOI);
```

```
Map.addLayer(
```

```
VV,
```

```
{
```

```
min:-30,
```

```
max:0
```

```
},
```

```
'VV'
```

```
);
```

```
var VV_Filter =
```

```
VV.focal_mean({
```

```
radius:30,
```

```
units:'meters'
```

```
});
```

```
Map.addLayer(
```

```
VV_Filter,
```

```
{
```

```
min:-30,
```

```
max:0
```

```
},
```

```
'Filtered VV'
```

```
);
```

```
var histogram =
```

```
ui.Chart.image.histogram({
```

```
image:VV_Filter,
```

```
region:AOI,
```

```
scale:30
```

```
});
```

```
print(histogram);
```

```
var WaterMask = VV_Filter.lt(-15);
```

```
Map.addLayer(  
    WaterMask.selfMask(),  
    {  
        palette:['blue']  
    },  
    'Water Mask'  
);
```

```
var OilCandidate =  
VV_Filter.lt(-24);
```

```
Map.addLayer(  
    OilCandidate.selfMask(),  
    {  
        palette:['yellow']  
    },  
    'Oil Candidate'  
);
```

```
var OilMask =  
OilCandidate.and(  
    WaterMask
```

```
);
```

```
Map.addLayer(  
  OilMask.selfMask(),  
  {  
    palette:['red']  
  },  
  'Oil Mask'  
);
```

```
var connected =  
  OilMask.connectedPixelCount(  
    200,  
    true  
  );
```

```
var OilClean =  
  OilMask.updateMask(  
    connected.gte(50)  
  );
```

```
Map.addLayer(  
  OilMask.updateMask(  
    connected.gte(50)  
  ),  
  {  
    palette:['red']  
  },  
  'Oil Mask'  
);
```

```
OilClean.selfMask(),
{
palette:['red']
},
'Clean Oil'
);
```

```
var areaImage =
OilClean.multiply(
ee.Image.pixelArea()
);
```

```
var area =
areaImage.reduceRegion({
reducer: ee.Reducer.sum(),
geometry: AOI,
scale: 10,
maxPixels: 1e13
});
```

```
var areaHa =
ee.Number(area.get('VV'))
```

```
.divide(10000);
```

```
print(  
  'Luas Oil Spill (Ha)',  
  areaHa  
);
```

```
var OilPolygon =  
OilClean.selfMask()  
.reduceToVectors({  
  geometry: AOI,  
  scale: 10,  
  geometryType: 'polygon',  
  eightConnected: true,  
  maxPixels: 1e13  
});
```

```
Map.addLayer(  
  OilPolygon,  
  {color:'yellow'},  
  'Oil Polygon'  
);
```

```
var OilPolygonArea =  
OilPolygon.map(function(ft){  
  
    return ft.set(  
        'Area_Ha',  
        ft.geometry()  
        .area(1)  
        .divide(10000)  
    );  
  
});  
  
print('Oil Polygon Area', OilPolygonArea);  
  
print(  
    'Jumlah Polygon',  
    OilPolygonArea.size()  
);  
  
var chart =  
ui.Chart.feature.byFeature(  

```

```

OilPolygonArea,

'Area_Ha'

)

.setChartType('ColumnChart')

.setOptions({

    title:'Luas Polygon Oil Spill',

    hAxis: {title:'Polygon'},

    vAxis: {title:'Luas (Ha)'}

});

print(chart);

Export.table.toDrive({

    collection: OilPolygonArea,

    description: 'OilSpill_Jakarta_2020',

    fileFormat: 'SHP'

});

print('Jumlah Polygon',

OilPolygonArea.size());

var LargestPolygon =

```

```
OilPolygonArea.sort(  
  'Area_Ha',  
  false  
);
```

```
print(  
  'Polygon Terbesar',  
  LargestPolygon.first()  
);
```

```
var LargeOil =  
  OilPolygonArea.filter(  
    ee.Filter.gt(  
      'Area_Ha',  
      10  
    )  
  );
```

```
Map.addLayer(  
  LargeOil,  
  {color:'red'},  
  'Large Oil Spill'
```

```
);
```

```
print(  
    'Jumlah Polygon Besar',  
    LargeOil.size()  
);
```

```
var TotalArea =  
    LargeOil.aggregate_sum(  
        'Area_Ha'  
    );
```

```
print(  
    'Total Luas Oil Spill (Ha)',  
    TotalArea  
);
```

```
Export.table.toDrive({  
    collection:LargeOil,  
    description:'OilSpill_Final',  
    fileFormat:'SHP'  
});
```

```

Export.image.toDrive({
  image:OilClean,
  description:'OilMask_Final',
  region:AOI,
  scale:10,
  maxPixels:1e13
});

```

```

var histogramDict = VV_Filter.reduceRegion({
  reducer: ee.Reducer.histogram(),
  geometry: AOI,
  scale: 30,
  maxPixels: 1e13
});

```

```

print(histogramDict);
histogramDict.get('VV')

```

```

var otsu = function(histogram) {

```

```

  var counts =

```

```
ee.Array(  
  ee.Dictionary(histogram)  
  .get('histogram'));  
  
var means =  
  ee.Array(  
    ee.Dictionary(histogram)  
    .get('bucketMeans'));  
  
var size = means.length().get([0]);  
  
var total =  
  counts.reduce(  
    ee.Reducer.sum(),  
    [0]).get([0]);  
  
var sum =  
  means.multiply(counts)  
  .reduce(  
    ee.Reducer.sum(),  
    [0]).get([0]);
```

```
var mean =  
    ee.Number(sum)  
    .divide(total);
```

```
var indices =  
    ee.List.sequence(  
        1,  
        size);
```

```
var bss =  
    indices.map(function(i) {
```

```
        var aCounts =  
            counts.slice(0,0,i);
```

```
        var aCount =  
            aCounts.reduce(  
                ee.Reducer.sum(),  
                [0]).get([0]);
```

```
        var aMeans =  
            means.slice(0,0,i);
```

```
var aMean =  
aMeans.multiply(aCounts)  
.reduce(  
ee.Reducer.sum(),  
[0]).get([0]);
```

```
aMean =  
ee.Number(aMean)  
.divide(aCount);
```

```
var bCount =  
ee.Number(total)  
.subtract(aCount);
```

```
var bMean =  
ee.Number(sum)  
.subtract(  
ee.Number(aCount)  
.multiply(aMean))  
.divide(bCount);
```

```

        return ee.Number(aCount)

        .multiply(
        ee.Number(aMean)
        .subtract(mean)
        .pow(2))
        .add(
        ee.Number(bCount)
        .multiply(
        ee.Number(bMean)
        .subtract(mean)
        .pow(2)));
    });

    return means.sort(bss).get([-1]);

};

var threshold =
otsu(
ee.Dictionary(
    histogramDict.get('VV')
));

```

```
print(  
    'Otsu Threshold',  
    threshold  
);  
  
var threshold =  
    otsu(  
        ee.Dictionary(  
            histogramDict.get('VV')  
        ));  
  
print(  
    'Otsu Threshold',  
    threshold  
);  
  
var Oil_Otsu =  
    VV_Filter.lt(  
        ee.Number(threshold)  
    );
```

```

Map.addLayer(
  Oil_Otsu.selfMask(),
  {
    palette:['green']
  },
  'Oil Otsu'
);

```

```

var Oil_Otsu =
  VV_Filter.lt(
    ee.Number(threshold)
  );

```

```

Map.addLayer(
  Oil_Otsu.selfMask(),
  {
    palette:['green']
  },
  'Oil Otsu'
);

```

```
// =====
```

```

// AOI TELUK JAKARTA

// =====

var AOI = ee.Geometry.Rectangle([

  106.70,

  -6.25,

  107.05,

  -5.90

]);

Map.centerObject(AOI, 10);

Map.addLayer(AOI, {color:'red'}, 'AOI');

// =====

// SENTINEL-1 VV

// =====

var S1 = ee.ImageCollection('COPERNICUS/S1_GRD')

.filterBounds(AOI)

.filterDate('2020-01-01', '2020-12-31')

.filter(ee.Filter.eq('instrumentMode', 'IW'))

.filter(ee.Filter.listContains(

```

```

    'transmitterReceiverPolarisation',
    'VV'
  ))
  .filter(ee.Filter.eq(
    'orbitProperties_pass',
    'DESCENDING'
  ))
  .select('VV');

print('Jumlah Citra', S1.size());

// Median Composite
var VV = S1.median().clip(AOI);

Map.addLayer(
  VV,
  {
    min:-30,
    max:0
  },
  'Sentinel-1 VV'
);

```

```
// =====
```

```
// EXPORT KE GOOGLE DRIVE
```

```
// =====
```

```
Export.image.toDrive({  
  
  image: VV,  
  
  description: 'Sentinel1_VV_TelukJakarta_2020',  
  
  folder: 'GEE_OilSpill',  
  
  fileNamePrefix: 'S1_VV_2020',  
  
  region: AOI,  
  
  scale: 10,  
  
  maxPixels: 1e13,  
  
  fileFormat: 'GeoTIFF'  
});
```

LAMPIRAN B

Lampiran 2 Source Code yang digunakan dalam proses VS code selama penelitian

```
import numpy as np

import rasterio

import matplotlib.pyplot as plt

import rasterio

s1 = rasterio.open(

    r"data 4/S1_VV_2020.tif"

)


VV = s1.read(1)


print(VV.shape)

print(VV.min())

print(VV.max())

plt.figure(figsize=(10,8))


plt.imshow(

    VV,

    cmap='gray'

)


plt.colorbar()
```

```
plt.title(  
    'Sentinel-1 VV'  
)  
  
plt.show()  
  
mask = rasterio.open(  
    r"data 4/OilMask_Final.tif"  
)  
  
label = mask.read(1)  
  
print(label.shape)  
  
print(  
    "VV:",  
    VV.shape  
)  
  
print(  
    "Mask:",
```

```
    label.shape
)

plt.figure(figsize=(10,8))

plt.imshow(
    label
)

plt.colorbar()

plt.title(
    'Oil Mask'
)

plt.show()

np.unique(label)

X = VV.flatten()

y = label.flatten()
```

```
print(X.shape)
```

```
print(y.shape)
```

```
X = X.reshape(-1,1)
```

```
print(X.shape)
```

```
import numpy as np
```

```
valid = np.isfinite(X[:,0])
```

```
X = X[valid]
```

```
y = y[valid]
```

```
print(X.shape)
```

```
print(y.shape)
```

```
unique, counts = np.unique(
```

```
    y,
```

```
    return_counts=True
```

```
)
```

```
print(dict(zip(unique,counts)))
```

```
oil_index = np.where(y == 1)[0]
```

```
non_index = np.where(y == 0)[0]
```

```
print("Oil Pixel :", len(oil_index))
```

```
print("Non Oil Pixel :", len(non_index))
```

```
sample_size = 100000
```

```
oil_sample = np.random.choice(  
    oil_index,  
    sample_size,  
    replace=False  
)
```

```
non_sample = np.random.choice(  
    non_index,  
    sample_size,  
    replace=False
```

```
)

sample_index = np.concatenate([
    oil_sample,
    non_sample
])

X_sample = X[sample_index]

y_sample = y[sample_index]

print(X_sample.shape)
print(y_sample.shape)

unique, counts = np.unique(
    y_sample,
    return_counts=True
)

print(dict(zip(unique, counts)))

from sklearn.model_selection import train_test_split
```

```
X_train, X_test, y_train, y_test = train_test_split(
    X_sample,
    y_sample,
    test_size=0.2,
    random_state=42
)

print("Training :", X_train.shape)
print("Testing :", X_test.shape)

from sklearn.ensemble import RandomForestClassifier

RF = RandomForestClassifier(
    n_estimators=100,
    random_state=42,
    n_jobs=-1
)

RF.fit(
    X_train,
    y_train
```

```
)

print("Training selesai")

prediction = RF.predict(
    X_test
)

print(prediction.shape)

from sklearn.metrics import accuracy_score

acc = accuracy_score(
    y_test,
    prediction
)

print("Accuracy =", acc)

from sklearn.metrics import confusion_matrix

cm = confusion_matrix(
```

```
        y_test,  
        prediction  
    )  
  
    print(cm)  
  
    from sklearn.metrics import classification_report  
  
    print(  
        classification_report(  
            y_test,  
            prediction  
        )  
    )  
  
    rows, cols = VV.shape  
  
    print(rows, cols)  
  
    full_X = VV.flatten()  
  
    full_X = full_X.reshape(-1,1)
```

```
print(full_X.shape)
```

```
prediction_full = RF.predict(  
    full_X  
)
```

```
print(prediction_full.shape)
```

```
prediction_image = prediction_full.reshape(  
    rows,  
    cols  
)
```

```
print(prediction_image.shape)
```

```
import matplotlib.pyplot as plt
```

```
plt.figure(figsize=(10,8))
```

```
plt.imshow(  
    prediction_image,
```

```
cmap='jet'

)

plt.colorbar()

plt.title(

    'Random Forest Oil Spill'

)

plt.show()

oil_pixels = np.sum(

    prediction_image == 1

)

print(

    "Jumlah Pixel Oil:",

    oil_pixels

)

area_m2 = oil_pixels * 100
```

```
area_ha = area_m2 / 10000
```

```
area_km2 = area_m2 / 1000000
```

```
print("Luas (Ha):", area_ha)
```

```
print("Luas (Km²):", area_km2)
```

```
with rasterio.open(  
    "OilSpill_RF.tif",  
    "w",  
    driver="GTiff",  
    height=rows,  
    width=cols,  
    count=1,  
    dtype=prediction_image.dtype,  
    crs=s1.crs,  
    transform=s1.transform  
) as dst:
```

```
dst.write(  
    prediction_image,
```

```
    1
```

```
)

print("Raster berhasil disimpan")

print(
    "Oil Mask GEE:",
    np.sum(label==1)

print(
    "Oil Mask RF:",
    np.sum(prediction_image==1)
)

plt.figure(figsize=(12,8))

plt.imshow(prediction_image)

plt.colorbar()

plt.title("Oil Spill Prediction")

plt.show()
```

```
oil_pixels = np.sum(prediction_image == 1)
```

```
print(oil_pixels)
```

```
area_m2 = oil_pixels * 100
```

```
area_ha = area_m2 / 10000
```

```
area_km2 = area_m2 / 1000000
```

```
print("Ha =", area_ha)
```

```
print("Km2 =", area_km2)
```

```
from rasterio.features import shapes
```

```
import geopandas as gpd
```

```
results = (
```

```
{
```

```
    'properties': {'class':v},
```

```
    'geometry':s
```

```

    }

    for s,v in shapes(

        prediction_image.astype('uint8')

    )

)

gdf = gpd.GeoDataFrame.from_features(

    list(results)

)

gdf = gdf[gdf['class']==1]

gdf['Area_m2'] = gdf.area

gdf['Area_Ha'] = gdf['Area_m2']/10000

print("Jumlah Polygon")

print(len(gdf))

print("Polygon Terbesar")

print(gdf['Area_Ha'].max())

print("Rata-rata Luas")

```

```
print(gdf['Area_Ha'].mean())

plt.figure(figsize=(10,5))

plt.hist(

    gdf['Area_Ha'],

    bins=30

)

plt.xlabel("Luas (Ha)")

plt.ylabel("Jumlah Polygon")

plt.title("Distribusi Luas Oil Spill")

plt.show()

import numpy as np

import pandas as pd

import rasterio

import geopandas as gpd

import matplotlib.pyplot as plt

from scipy.ndimage import uniform_filter
```

```
from skimage.feature import graycomatrix

from skimage.feature import graycoprops


from sklearn.model_selection import train_test_split

from sklearn.ensemble import RandomForestClassifier


from sklearn.metrics import (

    accuracy_score,

    confusion_matrix,

    classification_report

)


import os


print(os.getcwd())


import os


print(os.listdir())


vv_raster = rasterio.open(

    r"data 4\S1_VV_2020.tif"
```

```
)
```

```
mask_raster = rasterio.open(
    r"data 4\OilMask_Final.tif"
)
```

```
import os
```

```
print(os.listdir("data 4"))
```

```
import os
```

```
files = os.listdir("data 4")
```

```
for i, file in enumerate(files):
    print(i, file)
```

```
import os
```

```
for file in os.listdir("data 4"):
    print(file)
```

```
import rasterio
```

```
vv_raster = rasterio.open(
    r"data 4\S1_VV_2020.tif"
)

mask_raster = rasterio.open(
    r"data 4\OilMask_Final.tif"
)

VV = vv_raster.read(1)
label = mask_raster.read(1)

print("VV Shape :", VV.shape)
print("Mask Shape :", label.shape)

print("VV Min :", VV.min())
print("VV Max :", VV.max())

print("Label Unique :")
print(set(label.flatten()))

import numpy as np
```

```
unique, counts = np.unique(
    label,
    return_counts=True
)
```

```
for u,c in zip(unique,counts):
    print(
        f'Kelas {u} : {c:,} pixel'
    )
```

```
import scipy
import skimage
import sklearn
```

```
print("Scipy OK")
print("Scikit-image OK")
print("Scikit-learn OK")
```

```
from scipy.ndimage import uniform_filter
```

```
mean5 = uniform_filter(
```

```
VV,  
size=5  
)  
  
print(mean5.shape)  
  
mean_sq = uniform_filter(  
    VV**2,  
    size=5  
)  
  
std5 = np.sqrt(  
    mean_sq - mean5**2  
)  
  
print(std5.shape)  
  
import matplotlib.pyplot as plt  
  
plt.figure(figsize=(10,8))  
plt.imshow(mean5,cmap='gray')  
plt.colorbar()
```

```
plt.title("Local Mean")
```

```
plt.show()
```

```
plt.figure(figsize=(10,8))
```

```
plt.imshow(std5,cmap='gray')
```

```
plt.colorbar()
```

```
plt.title("Local Std")
```

```
plt.show()
```

```
import numpy as np
```

```
import matplotlib.pyplot as plt
```

```
from matplotlib import gridspec
```

```
from skimage import exposure
```

```
# =====
```

```
# Histogram Equalization
```

```
# =====
```

```
std_eq = exposure.equalize_hist(std5)
```

```
# =====
```

```
# Plot
```

```
# =====
```

```
fig = plt.figure(figsize=(18,12))
```

```
gs = gridspec.GridSpec(
```

```
    2,
```

```
    3,
```

```
    height_ratios=[1,0.4],
```

```
    hspace=0.35,
```

```
    wspace=0.25
```

```
)
```

```
# =====
```

```
# 1. Enhanced Contrast
```

```
# =====
```

```
ax1 = fig.add_subplot(gs[0,0])
```

```
im1 = ax1.imshow(
```

```
    std5,
```

```
    cmap='gray',
```

```

    vmin=np.percentile(std5,2),

    vmax=np.percentile(std5,98)

)

ax1.set_title(

    'Local Std (Kontras Ditingkatkan)'

)

ax1.axis('off')

cbar1 = plt.colorbar(

    im1,

    ax=ax1,

    fraction=0.046,

    pad=0.04

)

cbar1.set_label('Std (dB)')

# =====

# 2. Original

# =====

```

```
ax2 = fig.add_subplot(gs[0,1])
```

```
im2 = ax2.imshow(
```

```
    std5,
```

```
    cmap='gray'
```

```
)
```

```
ax2.set_title(
```

```
    'Local Std (Original)'
```

```
)
```

```
ax2.axis('off')
```

```
cbar2 = plt.colorbar(
```

```
    im2,
```

```
    ax=ax2,
```

```
    fraction=0.046,
```

```
    pad=0.04
```

```
)
```

```
cbar2.set_label('Std (dB)')
```

```

# =====

# 3. Histogram Equalization

# =====

ax3 = fig.add_subplot(gs[0,2])

im3 = ax3.imshow(
    std_eq,
    cmap='gray'
)

ax3.set_title(
    'Local Std (Histogram Equalization)'
)

ax3.axis('off')

cbar3 = plt.colorbar(
    im3,
    ax=ax3,
    fraction=0.046,

```

```

        pad=0.04
    )

cbar3.set_label('Normalized')

# =====
# Histogram Enhanced
# =====

ax4 = fig.add_subplot(gs[1,0])

ax4.hist(
    std5.flatten(),
    bins=100
)

ax4.set_title(
    'Histogram (Kontras Ditingkatkan)'
)

ax4.set_xlabel('Std (dB)')
ax4.set_ylabel('Frekuensi')

```

```

# =====

# Histogram Original

# =====

ax5 = fig.add_subplot(gs[1,1])

ax5.hist(

    std5.flatten(),

    bins=100

)

ax5.set_title(

    'Histogram (Original)'

)

ax5.set_xlabel('Std (dB)')

ax5.set_ylabel('Frekuensi')

# =====

# Histogram Equalization

# =====

```

```
ax6 = fig.add_subplot(gs[1,2])
```

```
ax6.hist(  
    std_eq.flatten(),  
    bins=100  
)
```

```
ax6.set_title(  
    'Histogram (Equalization)'  
)
```

```
ax6.set_xlabel('Nilai')
```

```
ax6.set_ylabel('Frekuensi')
```

```
plt.show()
```

```
import numpy as np
```

```
import matplotlib.pyplot as plt
```

```
from matplotlib import gridspec
```

```
from skimage import exposure
```

```

# =====

# Histogram Equalization

# =====

mean_eq = exposure.equalize_hist(mean5)

# =====

# Figure

# =====

fig = plt.figure(figsize=(18,12))

gs = gridspec.GridSpec(
    2,
    3,
    height_ratios=[1,0.4],
    hspace=0.35,
    wspace=0.25
)

# =====

```

```
# 1. Local Mean Enhanced
```

```
# =====
```

```
ax1 = fig.add_subplot(gs[0,0])
```

```
im1 = ax1.imshow(
    mean5,
    cmap='gray',
    vmin=np.percentile(mean5,2),
    vmax=np.percentile(mean5,98)
)
```

```
ax1.set_title(
    'Local Mean (Kontras Ditingkatkan)'
)
```

```
ax1.axis('off')
```

```
cbar1 = plt.colorbar(
    im1,
    ax=ax1,
    fraction=0.046,
```

```

        pad=0.04
    )

    cbar1.set_label('Mean (dB)')

# =====

# 2. Original

# =====

ax2 = fig.add_subplot(gs[0,1])

im2 = ax2.imshow(
    mean5,
    cmap='gray'
)

ax2.set_title(
    'Local Mean (Original)'
)

ax2.axis('off')

```

```
cbar2 = plt.colorbar(
    im2,
    ax=ax2,
    fraction=0.046,
    pad=0.04
)
```

```
cbar2.set_label('Mean (dB)')
```

```
# =====
# 3. Equalization
# =====
```

```
ax3 = fig.add_subplot(gs[0,2])
```

```
im3 = ax3.imshow(
    mean_eq,
    cmap='gray'
)
```

```
ax3.set_title(
    'Local Mean (Histogram Equalization)'
```

```
)
```

```
ax3.axis('off')
```

```
cbar3 = plt.colorbar(
```

```
    im3,
```

```
    ax=ax3,
```

```
    fraction=0.046,
```

```
    pad=0.04
```

```
)
```

```
cbar3.set_label('Normalized')
```

```
# =====
```

```
# Histogram Enhanced
```

```
# =====
```

```
ax4 = fig.add_subplot(gs[1,0])
```

```
ax4.hist(
```

```
    mean5.flatten(),
```

```
    bins=100
```

```
)
```

```
ax4.set_title(
    'Histogram Mean'
)
```

```
ax4.set_xlabel('Mean (dB)')
ax4.set_ylabel('Frekuensi')
```

```
# =====
# Histogram Original
# =====
```

```
ax5 = fig.add_subplot(gs[1,1])
```

```
ax5.hist(
    mean5.flatten(),
    bins=100
)
```

```
ax5.set_title(
    'Histogram Mean Original'
```

```
)
```

```
ax5.set_xlabel('Mean (dB)')
```

```
ax5.set_ylabel('Frekuensi')
```

```
# =====
```

```
# Histogram Equalization
```

```
# =====
```

```
ax6 = fig.add_subplot(gs[1,2])
```

```
ax6.hist(
```

```
    mean_eq.flatten(),
```

```
    bins=100
```

```
)
```

```
ax6.set_title(
```

```
    'Histogram Mean Equalization'
```

```
)
```

```
ax6.set_xlabel('Nilai')
```

```
ax6.set_ylabel('Frekuensi')
```

```
plt.show()
```

```
VV_norm = VV.copy()
```

```
VV_norm = VV_norm - VV_norm.min()
```

```
VV_norm = (  
    255 *  
    VV_norm /  
    VV_norm.max()  
).astype(np.uint8)
```

```
print(VV_norm.min())
```

```
print(VV_norm.max())
```

```
from skimage.feature import graycomatrix
```

```
from skimage.feature import graycoprops
```

```
patch = VV_norm[100:107,100:107]
```

```
glcm = graycomatrix(  
    patch, [1, 2, 3, 4], [0, 90, 180, 270],  
    levels=256, gray=True, symmetric=True, high_dynamic_range=True)
```

```
    patch,  
    distances=[1],  
    angles=[0],  
    levels=256,  
    symmetric=True,  
    normed=True  
)
```

```
print(  
    graycoprops(  
        glcm,  
        'contrast'  
    )  
)
```

```
print(  
    graycoprops(  
        glcm,  
        'homogeneity'  
    )  
)
```

```
print(  
    graycoprops(  
        glcm,  
        'energy'  
    )  
)  
  
features = np.column_stack([  
  
    VV.flatten(),  
  
    mean5.flatten(),  
  
    std5.flatten()  
  
])  
  
print(features.shape)  
  
labels = label.flatten()  
  
print(labels.shape)
```

```
valid = np.all(  
    np.isfinite(features),  
    axis=1  
)  
  
features = features[valid]  
  
labels = labels[valid]  
  
print(features.shape)  
print(labels.shape)  
  
unique, counts = np.unique(  
    labels,  
    return_counts=True  
)  
  
for u,c in zip(unique,counts):  
  
    print(  
        f"Kelas {u}: {c:,} pixel"
```

```
)

oil_index = np.where(
    labels == 1
)[0]

non_index = np.where(
    labels == 0
)[0]

print(
    "Oil Pixel:",
    len(oil_index)
)

print(
    "Non Oil Pixel:",
    len(non_index)
)

sample_size = 200000
```

```
np.random.seed(42)
```

```
oil_sample = np.random.choice(  
    oil_index,  
    sample_size,  
    replace=False  
)
```

```
non_sample = np.random.choice(  
    non_index,  
    sample_size,  
    replace=False  
)
```

```
selected = np.concatenate([  
    oil_sample,  
    non_sample  
)
```

```
X_sample = features[selected]
```

```
y_sample = labels[selected]
```

```
print(X_sample.shape)

print(y_sample.shape)


unique, counts = np.unique(

    y_sample,

    return_counts=True

)


for u,c in zip(unique,counts):


    print(

        f"Kelas {u}: {c:,}"

    )


from sklearn.model_selection import train_test_split


X_train,\

X_test,\

y_train,\

y_test = train_test_split(
```

```
X_sample,  
y_sample,  
  
test_size=0.2,  
  
random_state=42,  
  
stratify=y_sample  
)  
  
print(X_train.shape)  
print(X_test.shape)  
  
from sklearn.ensemble import RandomForestClassifier  
  
RF = RandomForestClassifier(  
  
    n_estimators=200,  
  
    max_depth=15,  
  
    random_state=42,
```

```
        n_jobs=-1
    )

    RF.fit(
        X_train,
        y_train
    )

    from sklearn.metrics import (
        accuracy_score,
        confusion_matrix,
        classification_report
    )

    prediction = RF.predict(
        X_test
    )

    print(
        "Accuracy:",
        accuracy_score(
```

```
        y_test,  
        prediction  
    )  
)
```

```
print(  
    confusion_matrix(  
        y_test,  
        prediction  
    )  
)
```

```
print(  
    classification_report(  
        y_test,  
        prediction  
    )  
)
```

```
prediction_image = RF.predict(features)
```

```
prediction_image = prediction_image.reshape(
```

```
VV.shape
)

print(prediction_image.shape)

import matplotlib.pyplot as plt

plt.figure(figsize=(12,10))

plt.imshow(
    prediction_image,
    cmap='jet'
)

plt.colorbar()

plt.title(
    "Random Forest Oil Spill Classification"
)

plt.show()
```

```
pixel_area = 10 * 10

oil_pixels = np.sum(
    prediction_image == 1
)

print(
    "Oil Pixels:",
    oil_pixels
)

oil_area_m2 = oil_pixels * 100

print(
    "Oil Area (m²):",
    oil_area_m2
)

oil_area_ha = oil_area_m2 / 10000

print(
    "Oil Area (Ha):",
    oil_area_ha
```

```

)

oil_area_km2 = oil_area_m2 / 1e6

print(
    "Oil Area (km²):",
    oil_area_km2
)

import rasterio

with rasterio.open(
    r"data 4\S1_VV_2020.tif"
) as src:

    profile = src.profile

    profile.update(
        dtype=rasterio.uint8,
        count=1
    )

```

```

with rasterio.open(
    r"data 4\RF_OilSpill.tif",
    "w",
    **profile
) as dst:

    dst.write(
        prediction_image.astype(
            rasterio.uint8
        ),
        1
    )

print(
    "RF_OilSpill.tif berhasil disimpan"
)

```

LAMPIRAN B

Lampiran 1 Hasil Turnitin



Page 1 of 44 - Cover Page

Submission ID: trnoid::3618:147954952

49 49

YUDI AMRIL - Analisis Tumpahan Minyak Di Laut Menggunakan Pemodelan Random Forest Berbasis Data Senti...

11/8/2026

Document Details

Submission ID

trnoid::3618:147954952

Submission Date

Aug 11, 2026, 4:15 PM GMT+7

Download Date

Aug 11, 2026, 4:18 PM GMT+7

File Name

TE_2203025014_Yudi_Amril_Skripsi - YUDI AMRIL.docx

File Size

2.9 MB

36 Pages

7,688 Words

52,347 Characters



Page 1 of 44 - Cover Page

Submission ID: trnoid::3618:147954952



13% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Top Sources

- 8% Internet sources
- 5% Publications
- 11% Submitted works (Student Papers)

Integrity Flags

0 Integrity Flags for Review

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.



Lampiran 2 Lembar Bimbingan Skripsi



UNIVERSITAS MUHAMMADIYAH PROF. DR. HAMKA
FAKULTAS TEKNOLOGI INDUSTRI DAN INFORMATIKA
 Jl. Tanah Merdeka No. 8 Kp. Rambutan, Cincin, Jakarta Timur, Telp. (021) 8400941 Fax. (021) 87782739
 Website : ftuhamka.ac.id; E-mail : ftu@uhamka.ac.id

LEMBAR BIMBINGAN SKRIPSI

Nama : Yudi Amri L
 NIM : 2203025014
 Program Studi : Teknik Elektro
 Judul :
 Pembimbing : Ir. Kun Rayatun, ST., M.T.

No.	Tanggal	Keterangan	Paraf
1	3/03/26	Bimbingan judul, dan topik.	
2.	18/06/26	Bimbingan Penulisan jurnal	
		Bimbingan isi jurnal	
		Bimbingan Revisi Pengolahan data	
		Bimbingan Revisi Pengolahan data	
		Bimbingan hasil olah data.	
		Bimbingan Penulisan isi jurnal	
		Bimbingan memasukkan data ke dalam jurnal.	
		Revisi hasil final Penulisan jurnal	

Lampiran 3 Lembar Persetujuan Pembimbing

 Fakultas Teknik Universitas Muhammadiyah Prof. DR. HAMKA	Surat Pernyataan Kelayakan Sidang Sarjana	Kode Arsip :
		04/Prodi-EI/Akad/2026 Program Studi Teknik Elektro

Jakarta, 24 Juli 2026

Bismillahirrahmanirrahim,

Dengan ini, saya sebagai pembimbing I / II ¹ menyatakan bahwa,

N a m a : Yudi Amril

N I M : 2203025014

Alamat : Jl kemping kel sungai ambang kec rumbai timur kota
pekanbaru prov riau

Judul Tugas Akhir :

"Analisis Tumpahan Minyak Di Laut Menggunakan Pemodelan Random Forest Berbasis Data Sentinel -1 SAR"

bahwa nama yang tertera diatas dinyatakan **Layak / Tidak Layak** ² untuk mengikuti sidang sarjana (S-1) pada Program Studi Teknik Elektro, Fakultas Teknik Universitas Muhammadiyah Prof. DR. Hamka.

Segala kekurangan dan kelebihan selama melakukan pengawasan dalam melakukan penelitian dan penulisan menjadi tanggung jawab saya sebagai pembimbing I / II ². Terima kasih atas perhatian dan kerjasama.

Jakarta, 24 Juli 2026
Pembimbing I / II ³

Mengetahui
Ketua Program Studi
Teknik Elektro – FT UHAMKA



(Ir. Harry Ramza, ST, MT, PhD)



(Ir. Kun Fayakun, S.T., M.T.)

Cc :

¹ Coret yang tidak perlu.

² Coret yang tidak perlu.

³ Coret yang tidak perlu

1. Yang bersangkutan.
2. Arsip.

Lampiran 4 Lembar Revisi Sidang Skripsi

LEMBAR REVISI SIDANG SKRIPSI TEKNIK ELEKTRO (PENGUJI-2)
FAKULTAS TEKNOLOGI INDUSTRI DAN INFORMATIKA UHAMKA

Nama Mahasiswa	Yudi Amril
NIM	2203025014
Hari Tanggal Sidang	Kamis, 6 Agustus 2026
Nama Pembimbing Skripsi	Ir. Kun Fayakun, ST., MT.
Judul Skripsi	Analisis Tumpahan Minyak Di Laut Menggunakan Pemodelan Random Forest Berbasis Data Sentinel-1 Sar

Catatan

1	Tambahkan penulisan makalah skripsi dalam buku lengkap dengan langkah-langkah algoritma masing-masing Random Forest, SVM
2	Data base untuk diolah dalam algoritma machine learning dilampirkan juga kodingan programnya
3	Tambahkan perbandingan hasil yang didapat dengan memberikan keterangan di masing-masing tabel dan gambar
4	Gambar 1 diperbesar sehingga tulisannya terbaca.
5	
6	

VALIDASI REVISI	NAMA DOSEN	TANGGAL REVISI	PARAF
(Ketua Sidang) Penguji-1	Dt. Dwi Astuti Cahyaniwi, S.T., M.T.	12/8-2026	
Penguji-2	Rosalina, S.T., M.T.	12/8-2026	
Pembimbing-1	Ir. Kun Fayakun, ST., MT.	12/8-2026	
Pembimbing-2	Muhammad Iqbal Habibie, S.Kom., MT, PhD	12/8-2026	

Selanjutnya, yang bersangkutan harus segera menyelesaikan permasalahan sehubungan dengan skripsi ini, selambat-lambatnya 7 (tujuh) hari setelah tanggal pelaksanaan sidang.

- 0 Apabila revisi telah selesai dan mendapatkan approval (penguji, pembimbing, Kaprodi dan Dekan), maka tulisan (Skripsi, Jurnal) dan Program dikumpulkan di spss.uhamka.ac.id atau Google Drive (Fakultas/Perpustakaan, Pembimbing dan Program Studi)
- 0 Berkas disusun sesuai petunjuk dan tanda tangan setiap berkas Asli
- 0 Batas Akhir Revisi (bb/bb/tm)
- 0 Batas Akhir Pengumpulan Berkas Skripsi dan Jurnal/Resume (bb/bb/tm)

Wassalamu'alaikum wa Rohmatullahi wa Barokatussalam.

Ir. Harry Ramana, S.T., M.T., Ph.D.

Ketua Program Studi Teknik Elektro

Catatan: Daftar revisi ini diserahkan kepada mahasiswa untuk acuan revisi bagi Dosen Pembimbing

LEMBAR REVISI SIDANG SKRIPSI TEKNIK ELEKTRO (PENGUJI-2)
FAKULTAS TEKNOLOGI INDUSTRI DAN INFORMATIKA UHAMKA

Nama Mahasiswa	Yudi Amril
NIM	2203025014
Hari Tanggal Sidang	Kamis, 6 Agustus 2026
Nama Pembimbing Skripsi	Ir. Kun Fayakun, ST., MT.
Judul Skripsi	Analisis Tumpahan Minyak Di Laut Menggunakan Pemodelan Random Forest Berbasis Data Sentinel-1 Sar

Catatan

1	Tambahkan penulisan makalah skripsi dalam buku lengkapi dengan langkah-langkah algoritma masing-masing Random Forest, SVM
2	Data base untuk diolah dalam algoritma machine learning dilampirkan juga kodingan programnya
3	Tambahkan perbandingan hasil yang didapat dengan memberikan keterangan di masing-masing tabel dan gambar
4	Gambar 1 diperbesar sehingga tulisannya terbaca.
5	
6	

VALIDASI REVISI	NAMA DOSEN	TANGGAL REVISI	PARAF
(Ketua Sidang) Penguji-1	Dt. Dwi Astuti Cahyaniwi, S.T., M.T.	12/8-2026	
Penguji-2	Rosalina, S.T., M.T.	12/8-2026	
Pembimbing-1	Ir. Kun Fayakun, ST., MT.	12/8-2026	
Pembimbing-2	Muhammad Iqbal Habibie, S.Kom., MT, PhD	12/8-2026	

Selanjutnya, yang bersangkutan harus segera menyelesaikan permasalahan sehubungan dengan skripsi ini, selambat-lambatnya 7 (tujuh) hari setelah tanggal pelaksanaan sidang.

- 0 Apabila revisi telah selesai dan mendapatkan approval (penguji, pembimbing, Kaprodi dan Dekan), maka tulisan (Skripsi, Jurnal) dan Program dikumpulkan di sps.uhamka.ac.id atau Google Drive (Fakultas/Perpustakaan, Pembimbing dan Program Studi)
- 0 Berkas disusun sesuai petunjuk dan tanda tangan setiap berkas Asli
- 0 Batas Akhir Revisi _____ (bb/bb/tm)
- 0 Batas Akhir Pengumpulan Berkas Skripsi dan Jurnal/Resume _____ (bb/bb/tm)

Wassalamu'alaikum wa Rohmatullahi wa Barokatussalam.

Ir. Harry Rana, S.T., M.T., Ph.D.
 Ketua Program Studi Teknik Elektro

Catatan: Daftar revisi ini diserahkan kepada mahasiswa untuk acuan revisi bagi Dosen Pembimbing.