

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

Yudi Amril^a, Muhammad Iqbal Habibie^{b,*}, Kun Fayakun^a

^aFakultas Teknologi Industri dan Informatika Universitas Muhammadiyah Prof. Dr. Hamka, Jl. Limau II No.2, DKI Jakarta 13830, Indonesia

^bPusat Penelitian Geoinformatika, Badan Riset dan Inovasi Nasional. Jl. Raya Jakarta-Bogor, Km.46, Cibinong, Bogor 16911, Indonesia

*Korespondensi Penulis: muha105@brin.go.id



Dikirim: 21 Juli 2026

Diterima: 24 Juli 2026

Diterbitkan: 26 Juli 2026

Abstrak. 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

Abstract. 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.

I. PENDAHULUAN

Pencemaran laut akibat tumpahan minyak (*oil spill*) merupakan ancaman ekologis destruktif yang memicu degradasi kualitas air secara masif, merusak ekosistem pesisir, serta menimbulkan kerugian sosio-ekonomi yang signifikan pada sektor perikanan dan pariwisata. Mengingat sifat dinamis fluida minyak yang mudah terdispersi oleh arus dan angin, diperlukan sistem pemantauan dini yang cepat, akurat, dan mencakup area spasial yang luas. Menurut [1], penginderaan jauh menggunakan satelit *Synthetic Aperture Radar* (SAR) Sentinel-1 menjadi pilar utama karena kemampuannya beroperasi aktif menembus awan dalam segala kondisi cuaca. [2] secara fisis, lapisan minyak meredam riak gelombang kapiler permukaan laut (*Bragg scattering*), sehingga memancarkan rona hamburan balik (*backscatter*) yang lebih gelap dibandingkan air laut normal di sekitarnya.

Namun, interpretasi citra radar terhambat oleh tingginya derau acak (*speckle noise*) dan keberadaan objek tiruan (*oil look-alikes*) seperti zona teduh angin (*wind sheltering*) yang menghasilkan karakteristik hamburan balik rendah yang identik. Menurut [3], pendekatan konvensional melalui deliniasi manual memiliki kelemahan berupa subjektivitas operator yang tinggi, efisiensi waktu yang rendah, serta ketidakmampuan mendeteksi lapisan minyak tipis (*thin oil sheen*) di area marginal.

Guna mengatasi keterbatasan tersebut, penelitian ini mengintegrasikan algoritma pembelajaran mesin berbasis fitur tekstur spasial multi-skala. Implementasi teknik komputasi modern seperti arsitektur *Deep Neural Networks* (DNN) dan metode *Deep Learning* canggih lainnya [4] telah terbukti mampu mengenali karakteristik morfologi kompleks tumpahan minyak secara otomatis di atas citra satelit [5] serta pendekatan ensemble hybrid yang lebih mutakhir dan eksplainabel [6]. Algoritma *Random Forest Classifier* diimplementasikan dengan menyandingkan fitur intensitas asli VV bersama fitur tekstur orde pertama (*Local Mean*) dan orde kedua (*Local Standard Deviation*) menggunakan jendela penapisan 5×5 (mean5 dan std5) (Yang et al., 2024). Pendekatan ini dikombinasikan dengan metode *Random Undersampling* (RUS) untuk mengeliminasi bias ketidakseimbangan kelas perairan makro, mengacu pada studi komparatif metode deteksi tumpahan minyak otomatis dan semi-otomatis berbasis data Sentinel-1 pada kasus Provinsi Banten, Indonesia [8]. Kerangka kerja komputasi cerdas ini berhasil membangun model prediktif tangguh dengan akurasi global 92% dan *F1-Score* sebesar 0,92. Melalui tahapan *full-scene inference*, model ini mampu memetakan luasan total terdampak secara objektif hingga mencapai 19.700,84 Hektar (197,01 km²), memberikan presisi kuantifikasi dampak bencana yang valid untuk mendukung kebijakan pengelolaan risiko lingkungan laut yang responsif.

II. METODOLOGI

2.1 Area Studi (*Studi Area*)


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 $10 \text{ m} \times 10 \text{ m}$. 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 [9].

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 $\times$ 3.905 kolom dengan total populasi piksel sebesar 15.190.506 unit. Resolusi spasial citra adalah $10 \text{ m} \times 10 \text{ m}$, sehingga setiap piksel merepresentasikan luasan fisis murni sebesar 100 m² di permukaan bumi. Nilai intensitas hamburan balik (*backscatter coefficient*) dikonversi ke dalam skala logaritmik desibel (dB) untuk mempertegas kontras amplitudo objek.


2.2 Alur kerja sistem (*System Architecture*)

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 kluster 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.3.



Gambar 1. 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 2. 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. 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 $10\text{ m} \times 10\text{ m}$ dengan dimensi geometri grid 3.890 baris $\times$ 3.905 kolom (total populasi 15.190.506 piksel).

2.3 Pemrosesan Data pada VS Code (Python Environment)

2.3.1. 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 [10][11], serta reduksi derau oleh [12].

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 [13] maupun algoritma reduksi derau tiga tahap [14]:

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

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

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 [15].

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 [16], karakteristik hamburan Bragg dan non-polarisasi dari lapisan film di permukaan laut [17], mekanisme hamburan mikrogelombang non-Bragg pada permukaan laut bersih dan berlapis minyak [18], serta kajian teoretis mekanisme hamburan mikrogelombang pada sudut datang kecil [19]. 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*).

2.3.2. 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 mengurangi 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).

2.3.3. Pelatihan Model *Random Forest Classifier*

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 [20].

2.3.4. 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.

2.3.5. 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*).

2.3.6. 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.

2.4. 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*, *Recall*, 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 (2)

$$\left(\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \right) \quad (2)$$

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 (3).

$$\left(\text{Precision} = \frac{TP}{TP+FP} \right) \quad (3)$$

Recall (*Sensitivity*) digunakan untuk mengukur kemampuan model dalam mendeteksi seluruh piksel tumpahan minyak yang terdapat pada data referensi. Semakin tinggi nilai *recall*, semakin sedikit piksel minyak yang gagal terdeteksi. Persamaan *recall* ditunjukkan pada Persamaan (4).

$$\left(\text{Recall} = \frac{TP}{TP+FN} \right) \quad (4)$$

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 (5).

$$\left(\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \right) \quad (5)$$

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.


III. HASIL DAN PEMBAHASAN

3.1 Analisis Fisis dan Rekayasa Kontekstual Fitur Masukan Komposit Spasial




Gambar. 4. 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, Gambar. 5, dan Gambar. 6



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



Gambar. 6. 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*).

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

3.2.1 Karakteristik Citra Sentinel-1 VV




Gambar 7. 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.

3.2.2 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 8. 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.

3.2.3 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 9. 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.



Gambar 10. Hasil deteksi *oil spill* menggunakan *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 11. 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.

Oil Mask Threshold -24 dB




Gambar 12. Hasil deteksi *oil spill* menggunakan *threshold* -24 dB

3.2.4 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 Opening



Oil Mask After Closing





Gambar 13. 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*

3.3. 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 fisik 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%)

3.4 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.

3.5 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 pembanding (*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.

IV. 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*.

UCAPAN TERIMA KASIH

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.

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] H. A. Harahsheh, “Oil spill detection and monitoring of Abu Dhabi coastal zone using KOMPSAT-5 SAR imagery,” *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 41, no. July, pp. 1115–1121, 2016, doi: 10.5194/isprsarchives-XLI-B8-1115-2016.
- [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. Longépé, 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.



Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)