

SENINLEO

# Detecção automática de manchas de óleo no mar utilizando imagens SENTINEL 1

RELATÓRIO DE JUNHO

BRASÍLIA  
JUNHO DE 2016

## SISNOLEO

---

Projeto - Oil & Gas Production and Operational Efficiency  
Reino Unido

Documento: **Relatório Mensal - Junho**

Descrição: **Pesquisa de detecção automática de manchas de óleo com imagens Sentinel-1**

---

### Equipe Executora

---

#### HEX – Tecnologias Geoespaciais

Alexandre Corrêa da Silva

*Analista GIS / Radar*

Dagnaldo Silva

William Branco

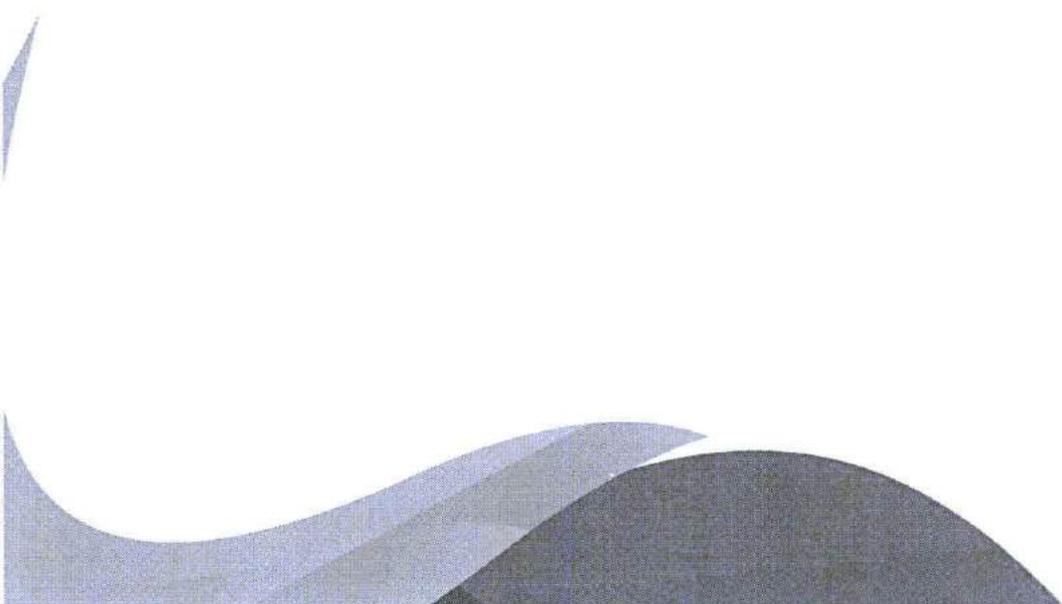
*Analistas de Desenvolvimento*

Thaise Rachel Sarmento

*Analista GIS / Gestora Administrativa*

Mariano Federico Pascual

*Diretor Técnico*





## SUMÁRIO EXECUTIVO

Um dos desafios que a indústria brasileira de petróleo e gás enfrenta é a gestão de derramamento de óleo. Conforme a legislação atual, as empresas petrolíferas devem fornecer uma série de medidas de monitoramento ambiental para cumprir com a lei 9.966 / 2000. No entanto, estas medidas não são interligadas e o Plano Nacional de Contingência, publicado em 2013, exige e abordagem integrada do governo e setores privados. Assim, há uma necessidade de melhorar a eficiência operacional na resposta a derramamentos de óleo.

O projeto '*Oil & Gas Production and Operational Efficiency*' apresenta um componente, liderado pelo IBAMA, que irá desenvolver uma ferramenta padrão (**SISNOLEO**) para monitorar, identificar e gerenciar os vazamentos de óleo no Brasil. Proporcionará ao governo o acesso rápido aos dados de derramamento de óleo, reduzindo os custos de monitoramento e aumentando a eficiência operacional e a rentabilidade. O IBAMA reconhece a necessidade de aperfeiçoar seu sistema de resposta nacional para vazamentos de óleo. Atualmente, as empresas informam sobre os incidentes, mas os dados ambientais prestados não estão integrados às agências governamentais competentes, levando a um atraso na resposta a este tipo de impacto.

Este projeto terá dois produtos principais que, uma vez alcançados serão a base para todas as atividades de desenvolvimento, implantação e operação de SISNOLEO e, portanto, as atividades de monitoramento que deverá sustentar. Sendo eles:

1. Algoritmo de Processamento Digital de Imagens de Satélite / Radar – SISNOLEO desenvolvido. Ele identificará feições suspeitas na superfície do oceano, para informar o setor de petróleo e gás no Brasil (por exemplo, governo, indústria e sociedade civil);
2. Modelagem dos 4 módulos que compreendem SISNOLEO, incluindo mapeamento de processos e fases de: (i) registro da base de dados; (ii) medidas de prevenção; (iii) preparação e resposta; e (iv) comunicação.

No presente documento serão tratadas informações referente a Atividade 6.1 do contrato **PPF BRB 000010**:

*Atividade 6.1 - Desenvolvimento de um algoritmo para detecção de derramamento de óleo, que integrará um software que será utilizado pelo IBAMA e agências governamentais relacionadas.*

## SUMÁRIO

---

1. INTRODUÇÃO	5
2. MATERIAL E MÉTODOS	6
2.1. Dados Utilizados	6
2.2. Software utilizado – SNAP	7
2.3. Processamento das Imagens	7
a) Pré-processamento	8
b) Criação de Máscara	9
c) Extração do Vento	9
d) Detecção de objetos	10
e) Suavização do ruído	10
f) Detecção de manchas escuras	11
2.4. Outros parâmetros de teste	12
2.5. Falsos positivos	12
3. CONCLUSÕES	13
4. BIBLIOGRAFIA	14
5. ANEXOS	15
Anexo I – Cronograma de Atividades	15

## Lista de Figuras

---

Figura 1 - Mapa de localização da imagem da ESA que captou manchas de óleo da aeronave EgyptAir desaparecida.	6
Figura 2 - Gráfico das etapas de processamento de imagens no software SNAP-ESA.	7
Figura 3 - Área da provável detecção de mancha.	8
Figura 4 - Extração do Vento, Etapa Wind-Field-Estimation.	9
Figura 5 - Detecção de objetos, Etapa Object-Discrimination.	10
Figura 6 - Suavização de Ruído Speckle.	11
Figura 7 - Detecção de pixel escuros na etapa Oil-Spill-Clustering.	12
Figura 8 - Exemplos de falsos positivos.	12

## Lista de Tabelas

---

Tabela 1 - Informações da Imagem da ESA que captou manchas de óleo da aeronave EgyptAir desaparecida.	6
---	---



## 1. INTRODUÇÃO

---

A produção de petróleo tem sido um componente essencial para a indústria moderna, sendo utilizado em uma diversidade de processos. A maior parte deste material é transportada por mares e oceanos e durante o transporte podem ocorrer vazamentos de óleo. Algumas fontes poluidoras são devido a acidentes com petroleiros ou água de lastro, como também provenientes das plataformas de extração de petróleo. Uma vez que o petróleo é derramado, espalha-se rapidamente, em uma vasta área, formando uma camada fina sobre a superfície da água, conhecido como "mancha de óleo", que é altamente poluidora no meio ambiente (SHETA et al., 2012).

Atualmente, com o advento das técnicas de teledetecção, tornou-se muito promissora a identificação de vazamento de óleo e seu monitoramento usando imagens SAR (*Synthetic Aperture Radar*). As imagens SAR têm sido utilizadas desde 2001 e, dentre os recursos orbitais disponíveis, constituem a principal fonte de dados para detecção de óleo no mar e devido à possibilidade de fornecimento em tempo próximo do real, bem como, à capacidade de cobrir extensas áreas adquirindo imagens durante o dia ou à noite sem interferência de nuvens (GENOVEZ et al., 2007). Portanto, as imagens de radar oferecem uma série de vantagens em relação a outros sistemas para o processo de detecção e monitoramento de derramamento de óleo no mar (SHETA et al., 2012).

Nas imagens de radar, em áreas oceânicas, a intensidade do sinal de retorno resulta do retroespalhamento superficial produzido por ondas centimétricas geradas pela ação dos ventos. A presença de óleo ou outros fenômenos que reduzem a rugosidade superficial e atenuam o sinal retroespalhado produzem feições escuras nas imagens de radar. Florescimento de algas, óleos biogênicos, plumas de ressurgência, áreas com baixa intensidade de vento, plumas de sedimentos em suspensão, células de chuva, dentre outros, constituem exemplos de feições passíveis de serem confundidas com óleo, originando falsos alarmes (GENOVEZ et al., 2007).

Segundo KUBAT et al. (1998), um sistema de detecção de vazamento de óleo com base em imagens de satélite poderia ser um sistema eficaz de alertas antecipados e, possivelmente, um elemento de controle e fiscalização de derramamento de óleo em mares e oceanos.

Portanto, o objetivo do presente relatório é identificar as ferramentas apropriadas para o processamento de imagens de radar, bem como definir os parâmetros iniciais de configuração das ferramentas disponíveis, visando a detecção automática de manchas de óleo em regiões de mares e oceanos.

## 2. MATERIAL E MÉTODOS

### 2.1. Dados Utilizados

Conforme noticiado pela Agência Espacial Europeia – ESA, a missão Sentinel-1 registrou, no dia 19 de maio de 2016, um possível vazamento de óleo no Mar Mediterrâneo, que poderia indicar a posição da aeronave do voo MS804 da EgyptAir, desaparecida na mesma data (Figura 1).

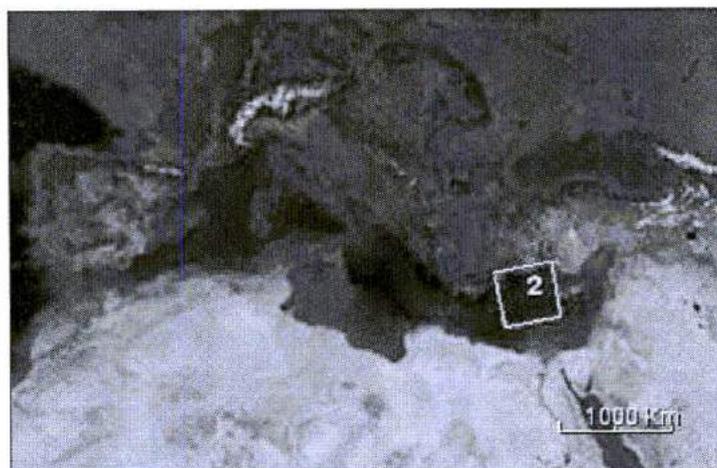


Figura 1 - Mapa de localização da imagem da ESA que captou manchas de óleo da aeronave EgyptAir desaparecida.

De acordo com a ESA, na imagem de satélite o vazamento estava localizado a 33° 32' Norte e a 29° 13' Leste (Tabela 1). Esses dados foram utilizados como insumo para essa pesquisa com o objetivo de detectar automaticamente a mancha escura nessas coordenadas e definir os parâmetros iniciais de configuração das ferramentas disponíveis pelo software SNAP da ESA para imagens Sentinel-1 EW com polarização HH.

A primeira imagem a detectar a mancha, de acordo com a Agência Espacial Europeia possui a seguinte nomenclatura:

**"S1A\_EW\_GRDM\_1SDH\_20160519T155720\_20160519T155820\_011330\_011303\_176C"**

Tabela 1 - Informações da imagem da ESA que captou manchas de óleo da aeronave EgyptAir desaparecida.

Dados da Imagem	
Tipo de produto	GRD
Horário de início do sensoriamento	19-MAY-2016 15:57:20.296124
Horário de parada do sensoriamento	19-MAY-2016 15:58:20.291238
Missão	SENTINEL-1A
Modo de aquisição	EW
Passagem	ASCENDING
Track	58
Órbita	11330

## 2.2. Software utilizado – SNAP

A ESA desenvolveu um software gratuito de código aberto para a exploração científica das missões de observação da Terra, o SNAP - *Sentinel's Application Platform*. O SNAP é uma ferramenta para o processamento de imagens de satélite SAR, podendo resultar num processo totalmente automatizado.

## 2.3. Processamento das Imagens

O procedimento adotado para a detecção da mancha, no SNAP, consiste em seis etapas:

- a) Pré-Processamento
- b) Criação de Máscara
- c) Extração do Vento
- d) Detecção de objetos
- e) Suavização do ruído
- f) Detecção de Manchas Escuras

Uma sétima etapa de pós-processamento pode ser adicionada para transformar as coordenadas da imagem em coordenadas elipsoidais, de modo que possam ser utilizadas em outros softwares (Figura 2).

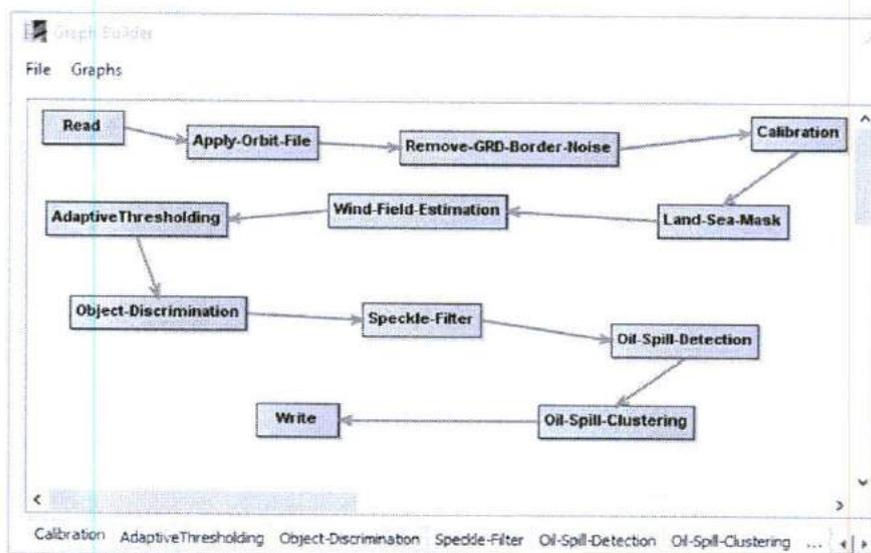


Figura 2 - Gráfico das etapas de processamento de imagens no software SNAP-ESA.

Para todo o processamento foi utilizado apenas a polarização HH, pois a mancha não aparece na polarização HV, como podemos ver na Figura 3.

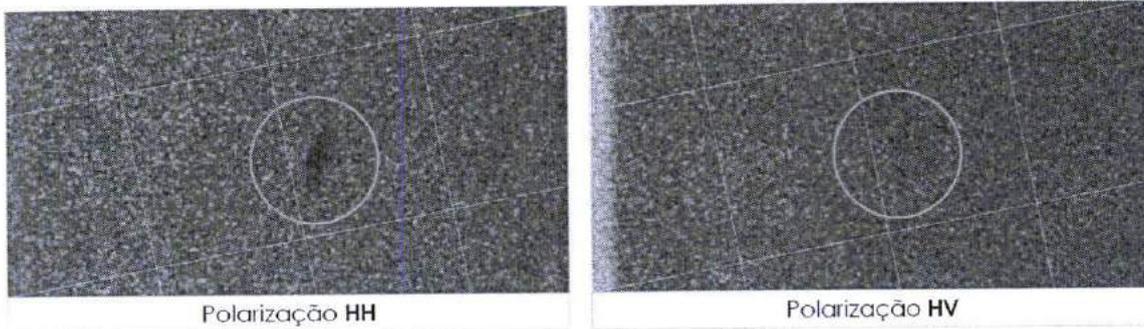


Figura 3 - Área da provável detecção de mancha.

#### a) Pré-processamento

##### Etapa - Apply-Orbit-File

Os vetores de órbita no metadado de um produto SAR geralmente não são acurados, ocasionando um erro no posicionamento da imagem. Esses dados podem ser refinados com o arquivo de órbita precisa, porém, dependendo do sensor, esse arquivo costuma demorar de dias até semanas, após a geração da imagem, para ser disponibilizado.

Para o Sentinel-1 a geração da órbita precisa demora algumas semanas. Na falta das órbitas precisas a restituída deve ser utilizada.

Parâmetros	
Orbit State Vectors:	Sentinel Restituted
Polynomial Degree:	3
Do not fail if new orbits not found:	Selecioneado

##### Etapa - Remove GRD-Border-Noise

O processamento dos arquivos brutos L0 para arquivos L1 e L2 gera ruídos nas extremidades da imagem, que podem ser minimizados com esse processamento.

Parâmetros	
Border margin limit [pixels]	500
Threshold	0.5

##### Etapa - Calibration

Essa etapa é essencial para as operações de extração do vento, detecção de embarcações e detecção de manchas escuras, pois o insumo para essas operações são os valores de retroespalhamento registrados pelo satélite. Esse procedimento converte os valores dos pixels em valores de retroespalhamento em decibéis.

Parâmetros	
Output sigma0 band	Selecioneado
Output gamma0 band	
Output beta0 band	
Output DN band	

## b) Criação de Máscara

### Etapa - Land-Sea-Mask

A etapa de criação de máscara é essencial para a redução de falsos positivos no resultado e contribui para a redução do tempo de processamento. Nesse processo é criada uma máscara sobre a terra ou sobre o mar transformando todos os pixels sob a máscara para pixels de valor nulo (NoData), para isso é necessário utilizar ou dados SRTM ou vetores.

Parâmetros	
Mask out the Land	Selecioneado
Mask out the Sea	
Use SRTM 3sec	Selecioneado
Use Vector as Mask	
Invert Vector	
Bypass	

## c) Extração do Vento

### Etapa - Wind-Field-Estimation

Quando venta sobre os mares e oceanos se formam na superfície ondulações que compõem um padrão de rugosidade que é relacionado à intensidade e à direção do vento. O retroespalhamento desse padrão de rugosidade pode ser utilizado para o cálculo da direção e da velocidade do vento.

Parâmetros	
Window Size (km)	20.0

Embora esse procedimento possa retornar a direção e a velocidade do vento não é possível determinar o sentido em razão da ambiguidade contida no algoritmo, portanto a representação é feita com uma seta dupla, que aponta para os dois sentidos (Figura 4). Dados externos (dados de vento ASCAT, dados de escaterômetros) podem ser utilizados posteriormente para confirmar o sentido correto do vento.

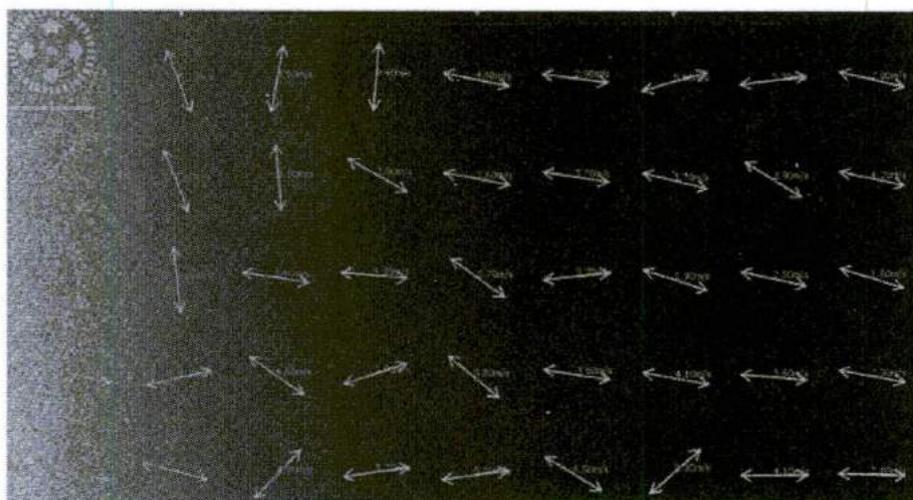


Figura 4 - Extração do Vento, Etapa Wind-Field-Estimation.

#### d) Detecção de objetos

##### Etapa – AdaptiveThresholding

Essa etapa detecta os possíveis objetos pelos parâmetros definidos pelo usuário. O tamanho mínimo do alvo a ser detectado deve ser preenchido no *Target Window Size*, o tamanho máximo no *Guard Window Size*.

Parâmetros	
<i>Target Window Size (m)</i>	75
<i>Guard Window Size (m)</i>	400.0
<i>Background Window Size (m)</i>	1000.0
<i>PFA (<math>10^{-x}</math>)</i>	6.5

##### Etapa - Object-Discrimination

Essa operação elimina os falsos positivos (objetos grandes ou pequenos demais) agrupando os pixels vizinhos detectados na etapa anterior e comparando as informações de largura e comprimento (Figura 5) juntamente com o parâmetro inserido pelo usuário.

Parâmetros	
<i>Minimum Target Size (m)</i>	120.0
<i>Maximum Target Size (m)</i>	600.0



Figura 5 – Detecção de objetos, Etapa Object-Discrimination.

#### e) Suavização do ruído

##### Etapa - Speckle-Filter

As imagens de SAR contêm um ruído chamado "sal e pimenta" que degrada a imagem e dificulta a interpretação. O filtro é aplicado para tentar eliminar ao máximo o ruído para melhor a interpretação (Figura 6).

Parâmetros	
	Filter Frost
Filter Size X (odd number)	3
Filter Size Y (odd number)	3
Damping Factor	2



Filtro Frost - HH



Filtro Refined Lee - HH

Figura 6 - Suavização de Ruído Speckle.

#### f) Detecção de manchas escuras

##### Etapa - Oil-Spill-Detection

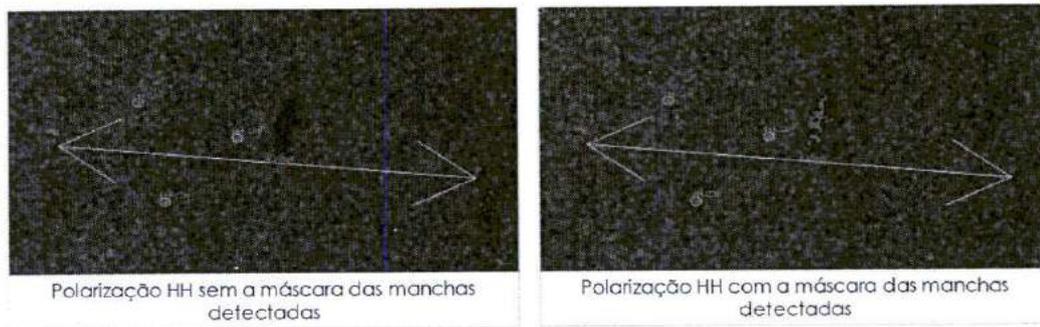
Os pixels são agrupados de acordo com o tamanho especificado da janela e é feita uma média dos valores, todos os pixels dentro da janela que estiverem abaixo do limite especificado em decibéis em relação à média são marcados como pixels escuros.

Parâmetros	
Background Window Size	30
Threshold Shift (dB)	2.0

##### Etapa - Oil-Spill-Clustering

Os pixels escuros do passo anterior são agrupados (Figura 7) e todos os grupos de pixels que não atingirem a área mínima especificada são eliminados.

Parâmetros	
Minimum cluster size (sq km)	0.1



Figura

7 - Detecção de pixel escuros na etapa Oil-Spill-Clustering.

## 2.4. Outros parâmetros de teste

### Etapa - Subset

Para a otimização dos testes nos processos foi criado um recorte nas imagens utilizando o Subset com os parâmetros listados abaixo:

Coordenadas em Pixels			
X	2941	Y	1391
Width	2024	Height	1232

## 2.5. Falsos positivos

Foram identificados falsos positivos (Figura 8) que deverão ser excluídos dos resultados da detecção automática ou posteriormente por alguma nova etapa de pós processamento.

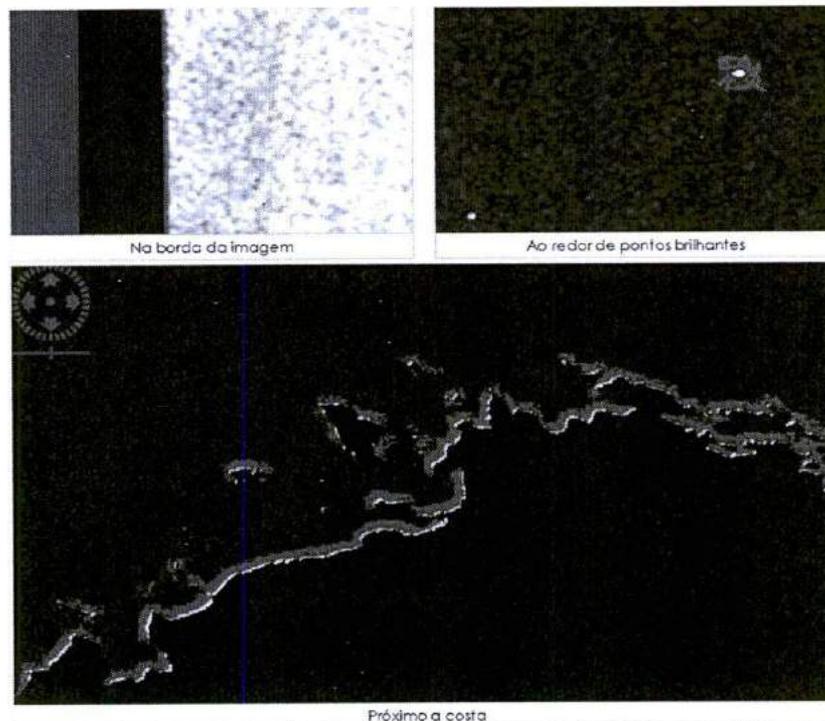


Figura 8 - Exemplos de falsos positivos.

### 3. CONCLUSÕES

---

No meio acadêmico predomina que radares que operam na banda X oferecem melhores resultados que os que operam na Banda L ou C. O Sentinel-1 opera na Banda C. Também é consenso que as imagens com polarização VV apresentam os melhores resultados. Nesse processamento também foi verificado que é possível detectar as manchas em HH.

Quanto ao dado de insumo, os dados L1 GRD são os que apresentam maior potencial de utilização, uma vez que os dados L0 RAW não são diretamente utilizáveis e necessitam de descompressão e processamento, também os programas mais conhecidos como o SNAP e o PCI Geomatica não são capazes de operar ou processar dados L0. Os dados L1 SLC poderiam ser utilizados, conforme especificado por MIGLIACO et al. (2007). Utilizando a diferença de fase co-polarizada entre as polarizações HH e VV de uma mesma imagem, entretanto, as imagens Sentinel-1 não tem polarização HH + VV.

Quanto à análise dos dados de vento, segundo FINGAS (2010), a janela de aceitabilidade para detecção de óleo é entre 1,5 m/s e 10,0 m/s, esses parâmetros iniciais podem ser utilizados, porém, modificações posteriores nesse intervalo serão necessárias.

Com relação aos falsos positivos, no caso da borda, é necessário um refinamento dos parâmetros do algoritmo ou recorte das bordas. No caso das áreas ao redor de pontos brilhantes, uma janela maior será testada e também uma relação de proximidade com objetos detectados. No caso da borda um refinamento da delimitação precisa ser testado, ou com vetores ou modelos digitais mais acurados.

#### 4. BIBLIOGRAFIA

---

FINGAS, M. **Oil spill science and technology**. Gulf professional publishing, 2010.

GENOVEZ P. C.; PALMEIRA F. L. B.; BENTZ C. M. Detecção e Monitoramento de Óleo através da Utilização Integrada de Imagens de Satélite, Verificações de Campo e Modelagem de Deriva de Óleo: Uma Abordagem Operacional. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto**, Natal, Brasil, INPE, p. 5235-5242. 25-30 abril 2009.

KUBAT, M.; HOLTE, R. C.; MATWIN, S. Machine Learning for the Detection of Oil Spills in Satellite Radar Images. **Machine Learning**, 30, 195–215, 1998.

MIGLIACCIO, M.; GAMBARDILLA, A.; TRANFAGLIA, A. SAR Polarimetry to Observe Oil Spills. **IEEE T Geosci Remote**; 506 2007.

SHETA, A.; ALKASASSBEH, M.; BRAIK, M.; AYYASH, H. A. Detection of Oil Spills in SAR Images using Threshold Segmentation Algorithms. **International Journal of Computer Applications** (0975 - 8887) Volume 57 - No. 7, November 2012.



5. ANEXOS

Anexo I – Cronograma de trabalho

ABRIL 2016 - MARÇO 2017	2017
2016	

PRODUTOS	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar
<b>Produto 6.</b> Algoritmo de Processamento Digital de Imagens de Satélite / Radar – SISNOLEO desenvolvido. Ele identificará o derramamento de óleo na superfície do oceano, para informar o setor de petróleo e gás no Brasil (por exemplo, governo, indústria e sociedade civil)												
<b>Produto 7.</b> Modelagem das 4 módulos que compreendem SISNOLEO, incluindo mapeamento de processos e fases de: (i) registro da base de dados; (ii) medidas de prevenção; (iii) preparação e resposta; e (iv) comunicação.												



[www.hexgis.com](http://www.hexgis.com)

BRASÍLIA-DF

SCN QUADRA 01 BLOCO F SALAS:1611/1614  
ED. AMERICA OFFICE TOWER  
CEP: 70.711-905  
+ 55 61 34476213