



Detecção automática de  
manchas de óleo no mar  
utilizando imagens SENTINEL 1  
RELATÓRIO DE AGOSTO

BRASÍLIA  
AGOSTO DE 2016

## SISNOLEO

---

Projeto - Oil & Gas Production and Operational Efficiency  
Reino Unido

Documento: **Relatório Mensal - Agosto**

Descrição: **Desenvolvimento de um algoritmo para detecção de derramamento de óleo no mar, que integrará um software que será utilizado pelo IBAMA e agências governamentais relacionadas.**

---

### Equipe Executora

---

#### **HEX – Tecnologias Geoespaciais**

Alexandre Corrêa da Silva

*Analista GIS / Radar*

Dagnaldo Silva

William Branco

*Analistas de Desenvolvimento*

Maristela Terto de Holanda

Evandro Roberto

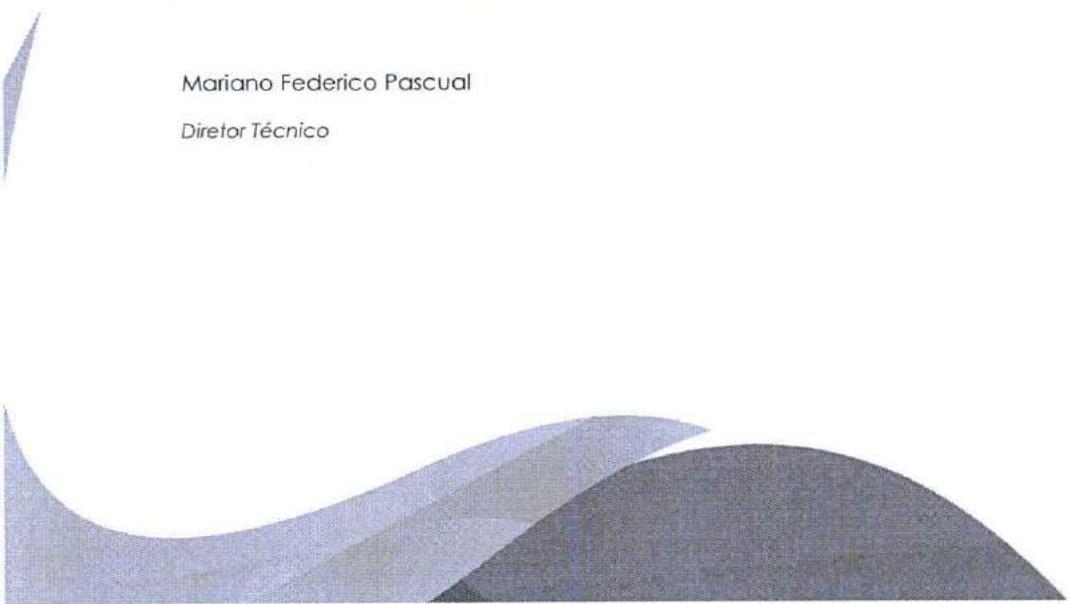
*Consultores especializados em banco de dados geográficos*

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 e Atividade 7.1 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.*

*Atividade 7.1 - Desenvolvimento de estruturas padrão para integrar a ferramenta de monitoramento SINSOLEO visando responder eficazmente aos derramamentos de óleo.*

## SUMÁRIO

---

<b>CAPÍTULO 1 - Pesquisa de Detecção de Óleo no Mar com Sentinel-1</b>	<b>5</b>
<b>1.1. INTRODUÇÃO</b>	<b>5</b>
<b>1.2. MATERIAL E MÉTODOS</b>	<b>6</b>
1.2.1 Dados Utilizados	6
1.2.2 Procedimentos	9
<b>1.3. OBSERVAÇÕES E CONCLUSÕES</b>	<b>11</b>
<b>CAPÍTULO 2 – Redes Neurais Artificiais RNAs</b>	<b>15</b>
<b>2.1. INTRODUÇÃO</b>	<b>15</b>
<b>2.2. RESULTADOS PARCIAIS</b>	<b>15</b>
2.2.1 Configuração de ambiente para testes com Faster R-CNN	15
2.2.2 Criação de script para conversão e recorte de imagem Sentinel 1A	15
2.2.3 Criação de script para ranking de previsões	16
2.2.4 Preparação de novo conjunto de imagens para treinamento da RN	16
<b>CAPÍTULO 3 – Modelagem de Dados Geográficos</b>	<b>17</b>
<b>3.1. INTRODUÇÃO</b>	<b>17</b>
<b>3.2. RESULTADOS PARCIAIS</b>	<b>18</b>
3.2.1 Diagrama de Entidade-Relacionamento	18
<b>BIBLIOGRAFIA</b>	<b>19</b>
<b>ANEXOS</b>	<b>20</b>
<b>Anexo I – Cronograma de Trabalho</b>	<b>20</b>

## CAPÍTULO 1 - Pesquisa de Detecção de Óleo no Mar com Sentinel-1

Alexandre Corrêa da Silva

### 1.1. INTRODUÇÃO

Após a geração ou aquisição e compatibilização dos dados meteoceanográficos, identificou-se a necessidade de uma análise mais profunda da representação dos dados, bem como a otimização e a disponibilidade dos dados para as áreas recobertas pelas imagens SAR que estão sendo utilizadas na pesquisa.

Nesse relatório são apresentados os procedimentos e resultados obtidos com testes dos dados de vento oceânico gerados a partir das imagens Sentinel-1.

O método para extrair a direção do vento segundo VU LA *et al.* (2016) é dividida em duas categorias, domínio espectral pela Transformada Rápida de Fourier (FFT) e domínio espacial com o Gradiente Local (LG). Ambos os métodos apresentam uma ambiguidade direcional de 180°, que pode ser removida pela observação de sombras na imagem ou pelo uso de dados meteorológicos externos<sup>1</sup>.

O algoritmo que o software SNAP utiliza para extrair o vento das imagens tem como base o modelo CMOD5, desenvolvido em cima de dados dos escaterômetros a bordo dos satélites ERS-1 e ERS-2. Esse modelo utiliza a seção transversal de RADAR normalizada (NRCS) da polarização VV da imagem para obter os resultados. Sua aplicação também é possível em imagens com polarização HH mediante uma conversão para valores de NRCS de polarização VV antes da aplicação do modelo<sup>2</sup>.

<sup>1</sup> Adaptado de: HERBACH (2003); WACKERMAN *et al.* (2003).

<sup>2</sup> Adaptado de: HERBACH (2003); WACKERMAN *et al.* (2003).

## 1.2. MATERIAL E MÉTODOS

### 1.2.1 Dados Utilizados

No presente relatório foram estudadas e testadas cinco imagens SAR (Figura 1).



Figura 1 – Localização das imagens SAR.

A descrição de cada uma delas segue abaixo:

**Imagem 1:** Nomenclatura "S1A\_IW\_GRDH\_1SDV\_20160720T081332\_20160720T081357\_012229\_012FD9\_DC7C"

Dados da Imagem	
Tipo de produto	GRD
Horário de início do sensoriamento	20-JUL-2016 08:13:32.110262
Horário de parada do sensoriamento	20-JUL-2016 08:13:57.108833
Missão	SENTINEL-1A
Modo de aquisição	IW
Passagem	DESCENDING
Track	82
Órbita	12229

**Imagem 2:** Nomenclatura "S1A\_IW\_GRDH\_1SDV\_20160720T081357\_20160720T081422\_012229\_012FD9\_2D51"

Dados da Imagem	
Tipo de produto	GRD
Horário de início do sensoriamento	20-JUL-2016 08:13:57.110315
Horário de parada do sensoriamento	20-JUL-2016 08:14:22.108887
Missão	SENTINEL-1A
Modo de aquisição	IW
Passagem	DESCENDING
Track	82
Órbita	12229

**Imagem 3:** Nomenclatura "S1A\_IW\_GRDH\_1SDV\_20160811T083025\_20160811T083050\_012550\_013A78\_764B"

Dados da Imagem	
Tipo de produto	GRD
Horário de início do sensoriamento	11-AUG-2016 08:30:25.545886
Horário de parada do sensoriamento	11-AUG-2016 08:30:50.544522
Missão	SENTINEL-1A
Modo de aquisição	IW
Passagem	DESCENDING
Track	53
Órbita	12550

**Imagem 4:** Nomenclatura "S1A\_IW\_GRDH\_1SDV\_20160811T083050\_20160811T083115\_012550\_013A78\_64D0"

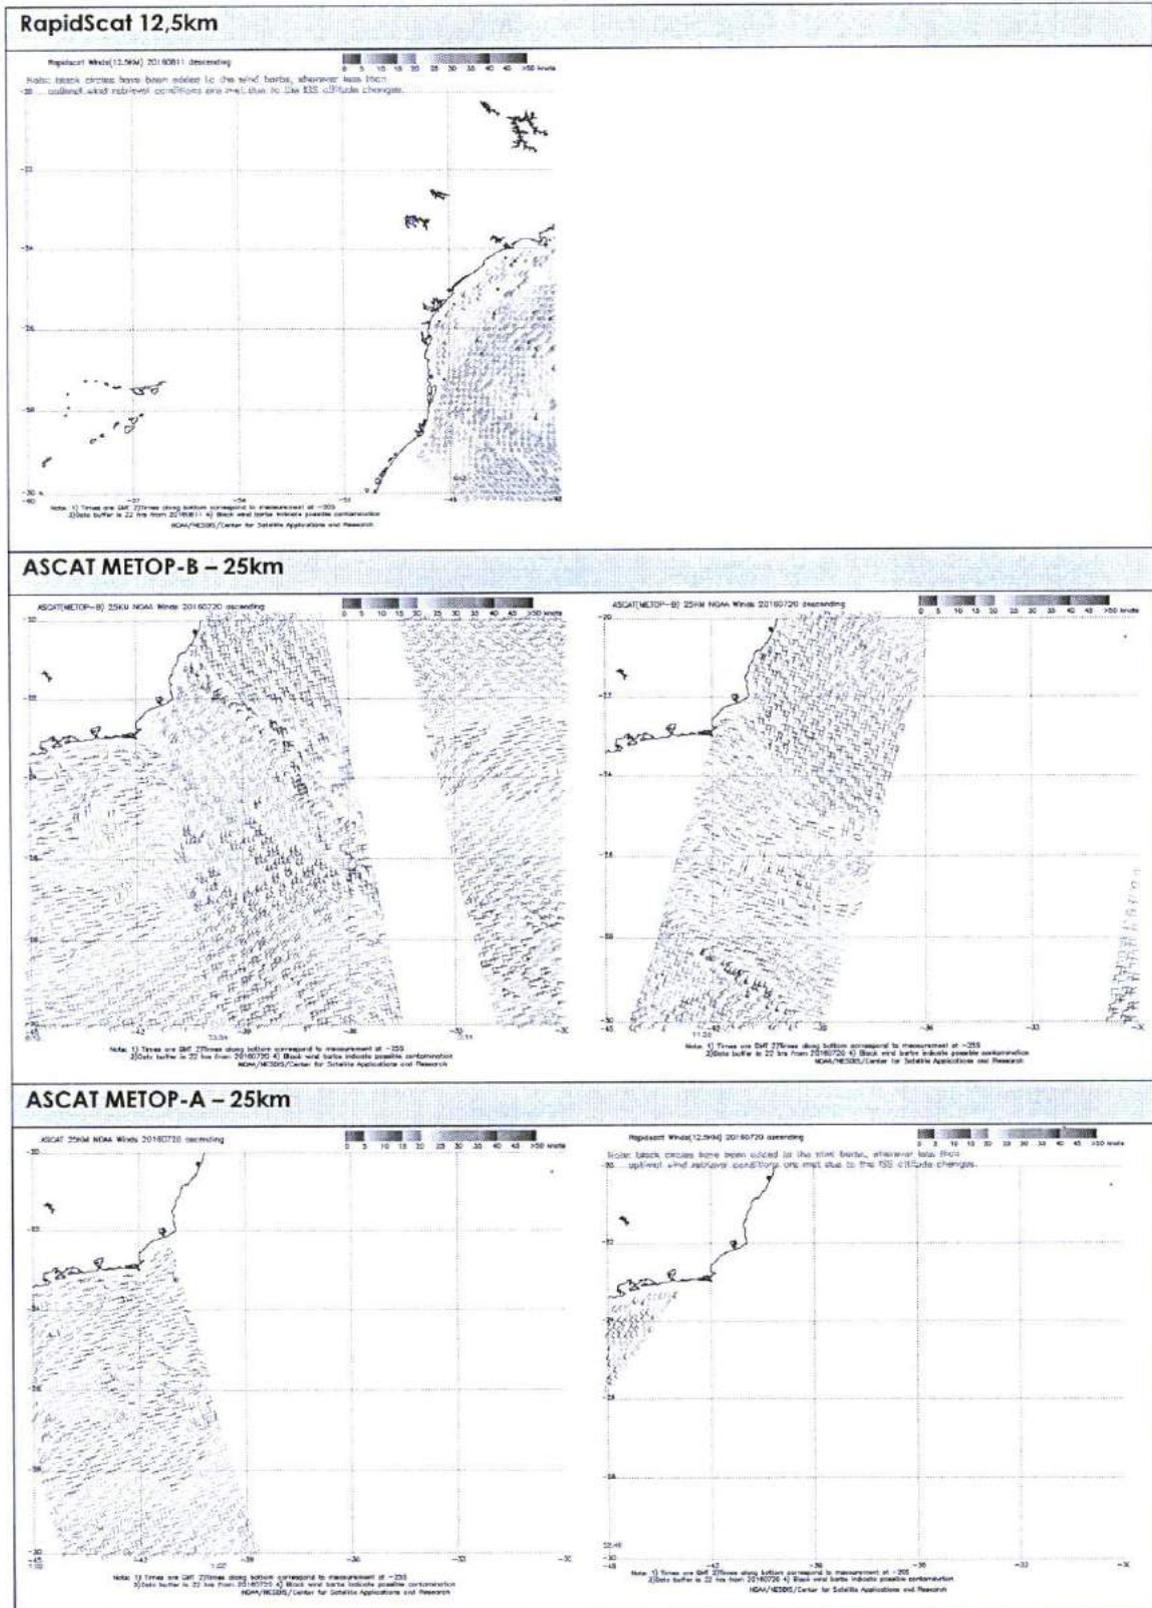
Dados da Imagem	
Tipo de produto	GRD
Horário de início do sensoriamento	11-AUG-2016 08:30:50.546004
Horário de parada do sensoriamento	11-AUG-2016 08:31:15.544640
Missão	SENTINEL-1A
Modo de aquisição	IW
Passagem	DESCENDING
Track	53
Órbita	12550

**Imagem 5:** Nomenclatura "S1A\_IW\_GRDH\_1SDV\_20160811T083115\_20160811T083140\_012550\_013A78\_D8E7"

Dados da Imagem	
Tipo de produto	GRD
Horário de início do sensoriamento	11-AUG-2016 08:31:15.546121
Horário de parada do sensoriamento	11-AUG-2016 08:31:40.544756
Missão	SENTINEL-1A
Modo de aquisição	IW
Passagem	DESCENDING
Track	53
Órbita	12550



Os dados ASCAT e RapidScat podem ser visualizados a seguir:





### 1.2.2 Procedimentos

O procedimento para a geração do vento foi descrito nos relatórios anteriores. Para esse estudo, foram utilizadas três variações dos parâmetros do processo: 5 km; 12,5 km; e 25 km. Esses valores foram escolhidos para comparar com os dados dos escaterômetros.

Os campos gerados pelo processo são:

- lat: Latitude of the central point in the window.
- lon: Longitude of the central point in the window.
- speed: Estimated wind speed in m/s.
- dx: X component of the estimated wind vector.
- dy: Y component of the estimated wind vector.
- ratio: In estimating wind direction, the spectrum of a given window is matched with a 2D polynomial (like  $f(x,y) = ax^2 + bxy + cy^2 + dx + ey + f$ ). The ratio in the report is the ratio of the minor semi axes over the major semi axes of the 2D polynomial. Generally speaking, the smaller the ratio value, the more reliable the estimated wind direction.

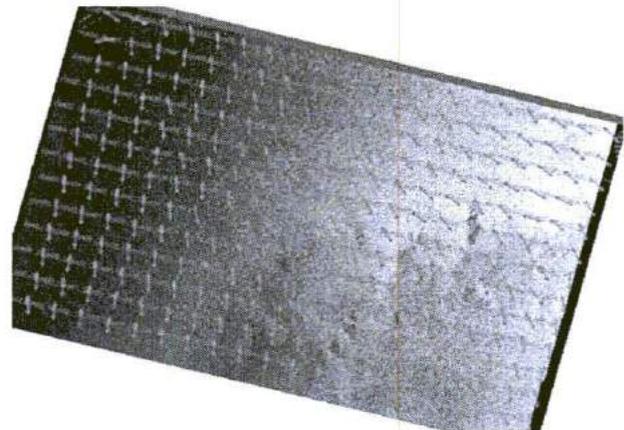
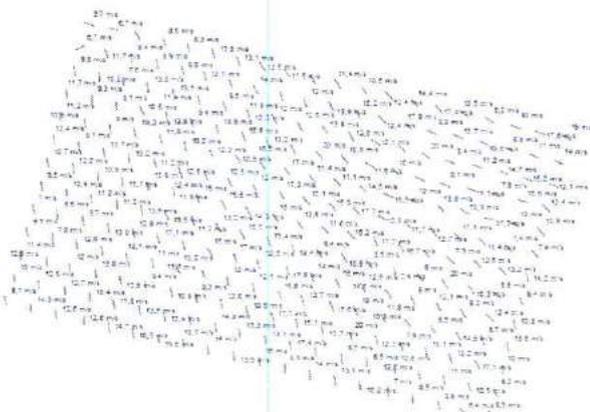
Após formatar o arquivo de texto e gerar um arquivo de vetor, as seguintes fórmulas precisam ser aplicadas:

Velocidade do vento em Nós*:	<code>round( 1.9426 * "SPEED" , 1 )</code>
Inclinação da seta em graus*:	<code>degrees( atan( "DX" / "DY" ) )</code>

\* Obs.: Fórmulas formatadas para utilização no Quantum GIS

As imagens ASCAT e RapidScat do vento oceânico foram obtidas do site do NOAA e georreferenciadas pelas coordenadas do grid, presente na imagem, esse procedimento pode ser executado em qualquer software que tenha essa função apresentando resultados bem similares, por isso e pela ausência de processamentos mais complexos, essa parte não é detalhada nesse relatório.

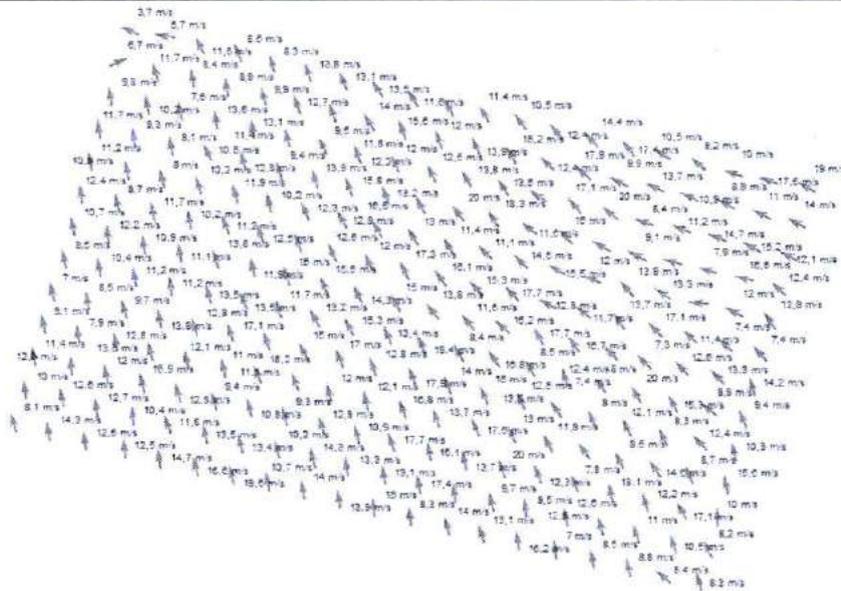
Abaixo segue comparação da representação do vetor de pontos com a visualização no SNAP:



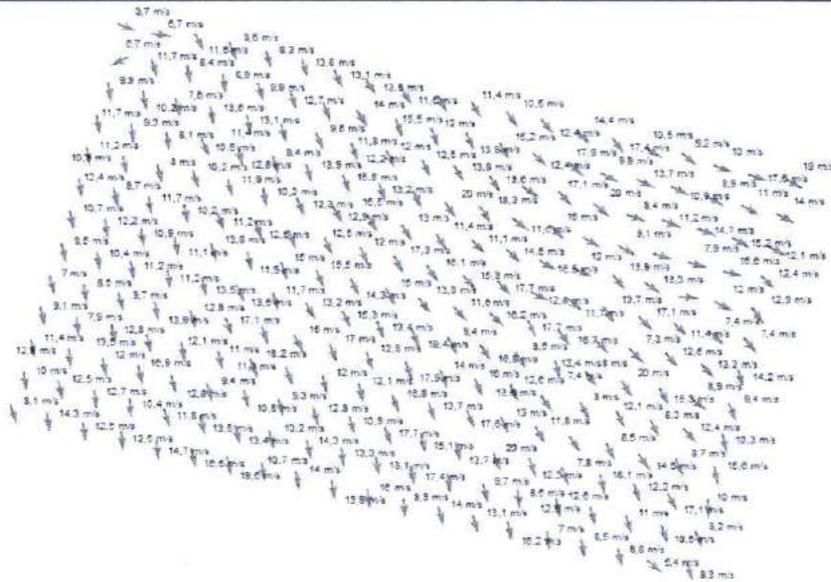


Visualização da ambiguidade no sentido do vetor:

Representação do  
vento sentido  
oceano-continente



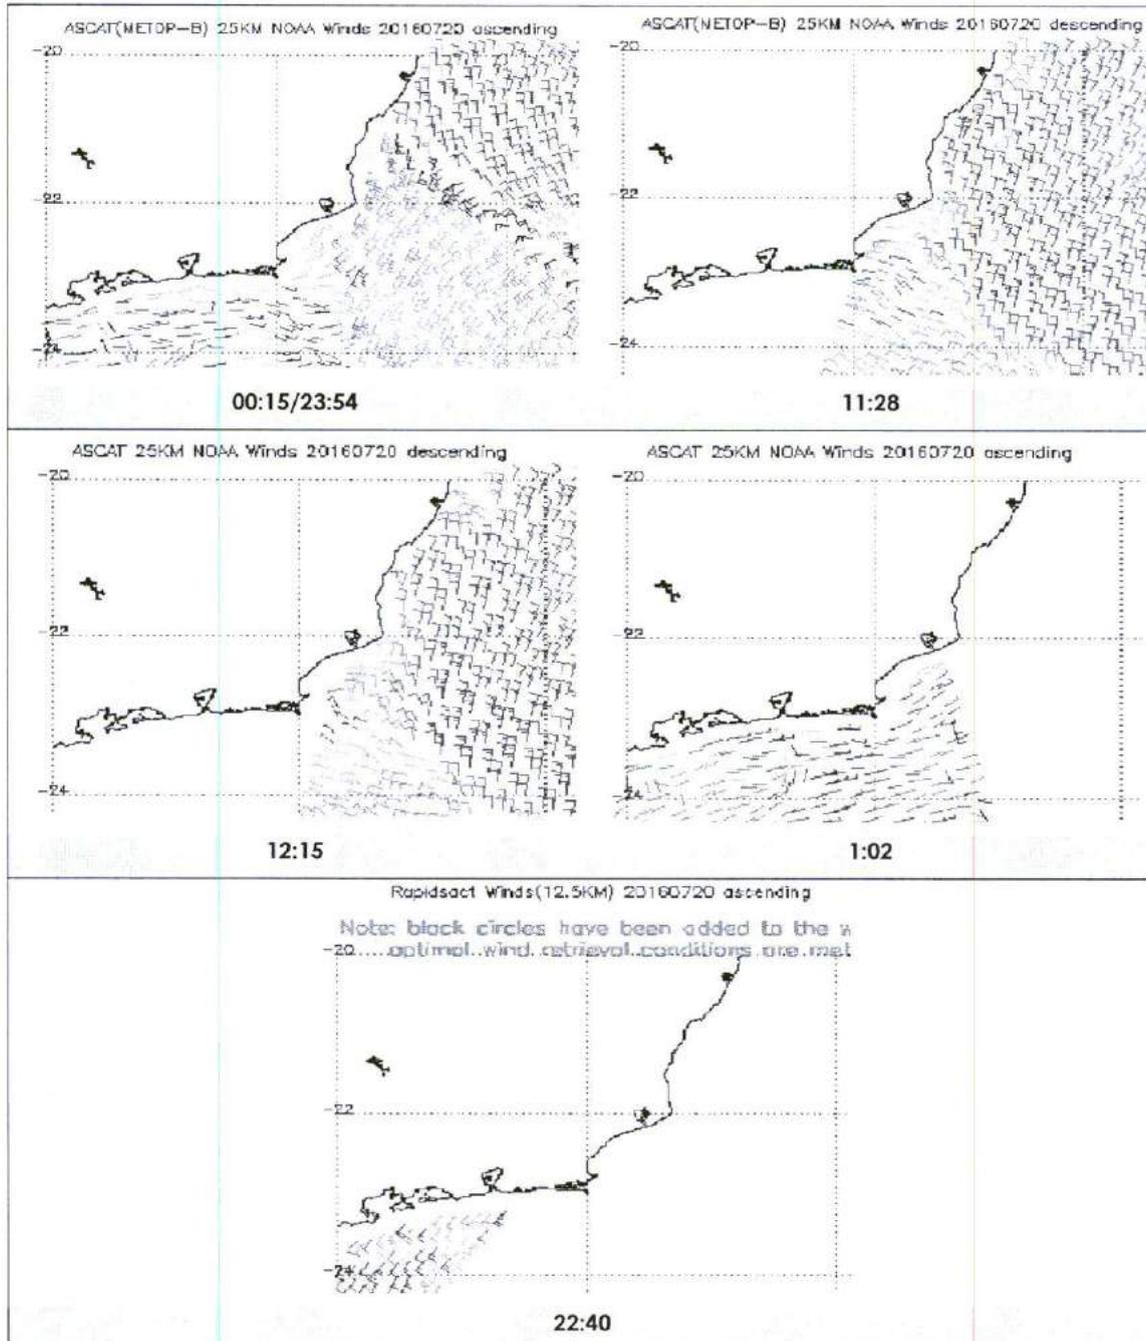
Representação do  
vento sentido  
continente-oceano



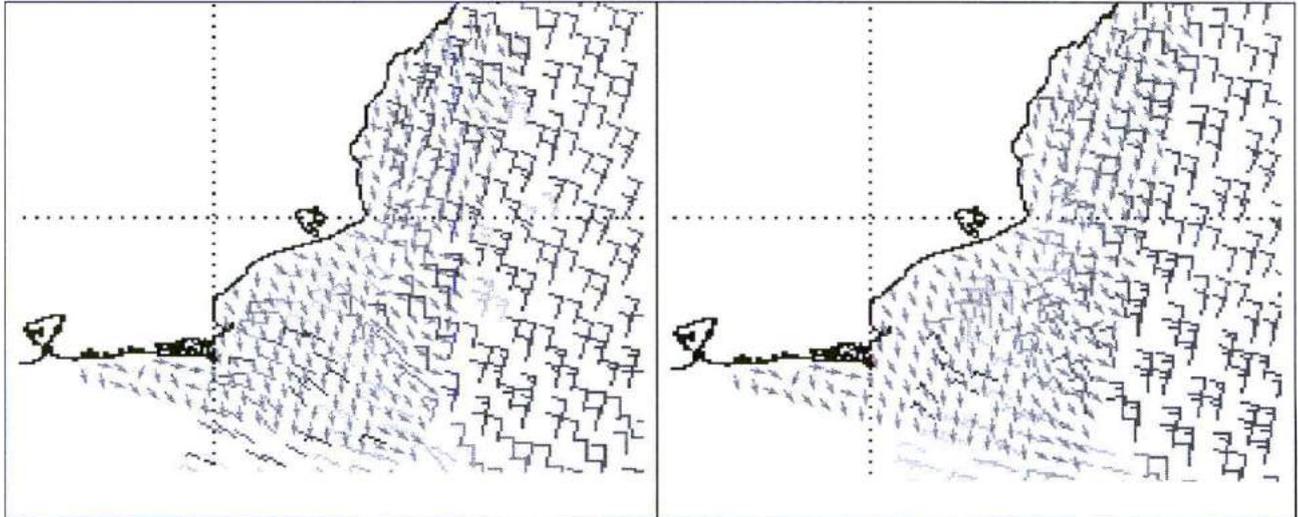
### 1.3. OBSERVAÇÕES E CONCLUSÕES

Existe uma considerável variação nos dados de direção e intensidade do vento ao longo do dia. No site do NOAA não existe uma disponibilidade grande de horários, o que dificulta uma análise caso o vento e a imagem SAR estejam em horários diferentes, tornando imprescindível a obtenção do dado de vento diretamente das imagens SAR.

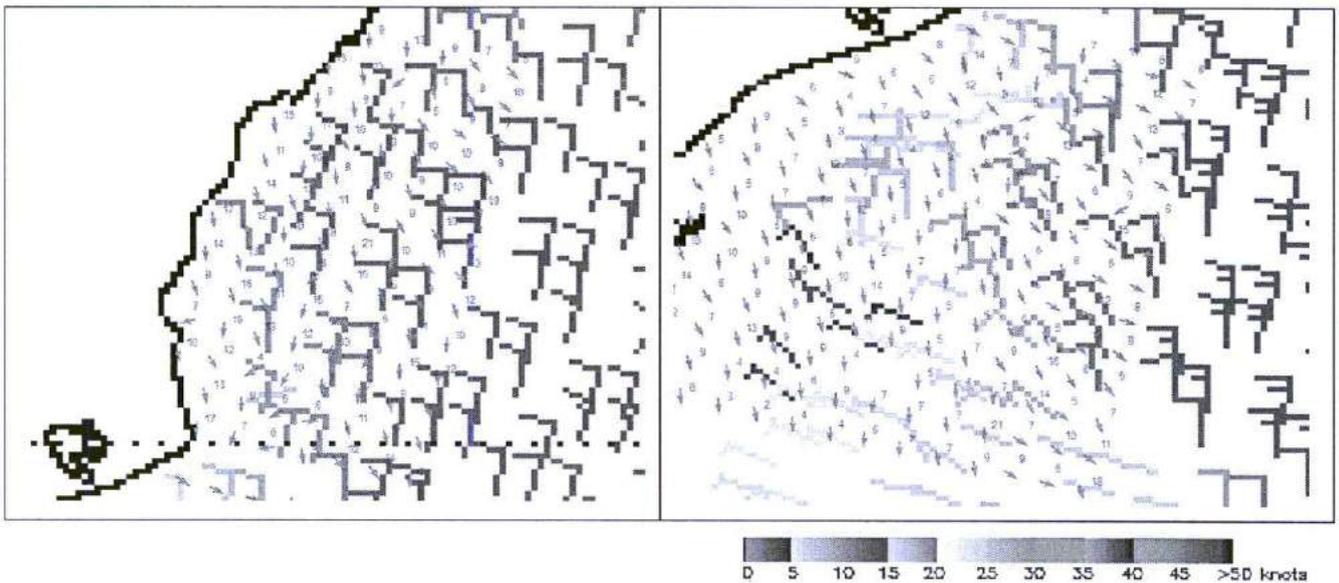
A seguir podemos ver a diferença na direção do vento conforme o horário:



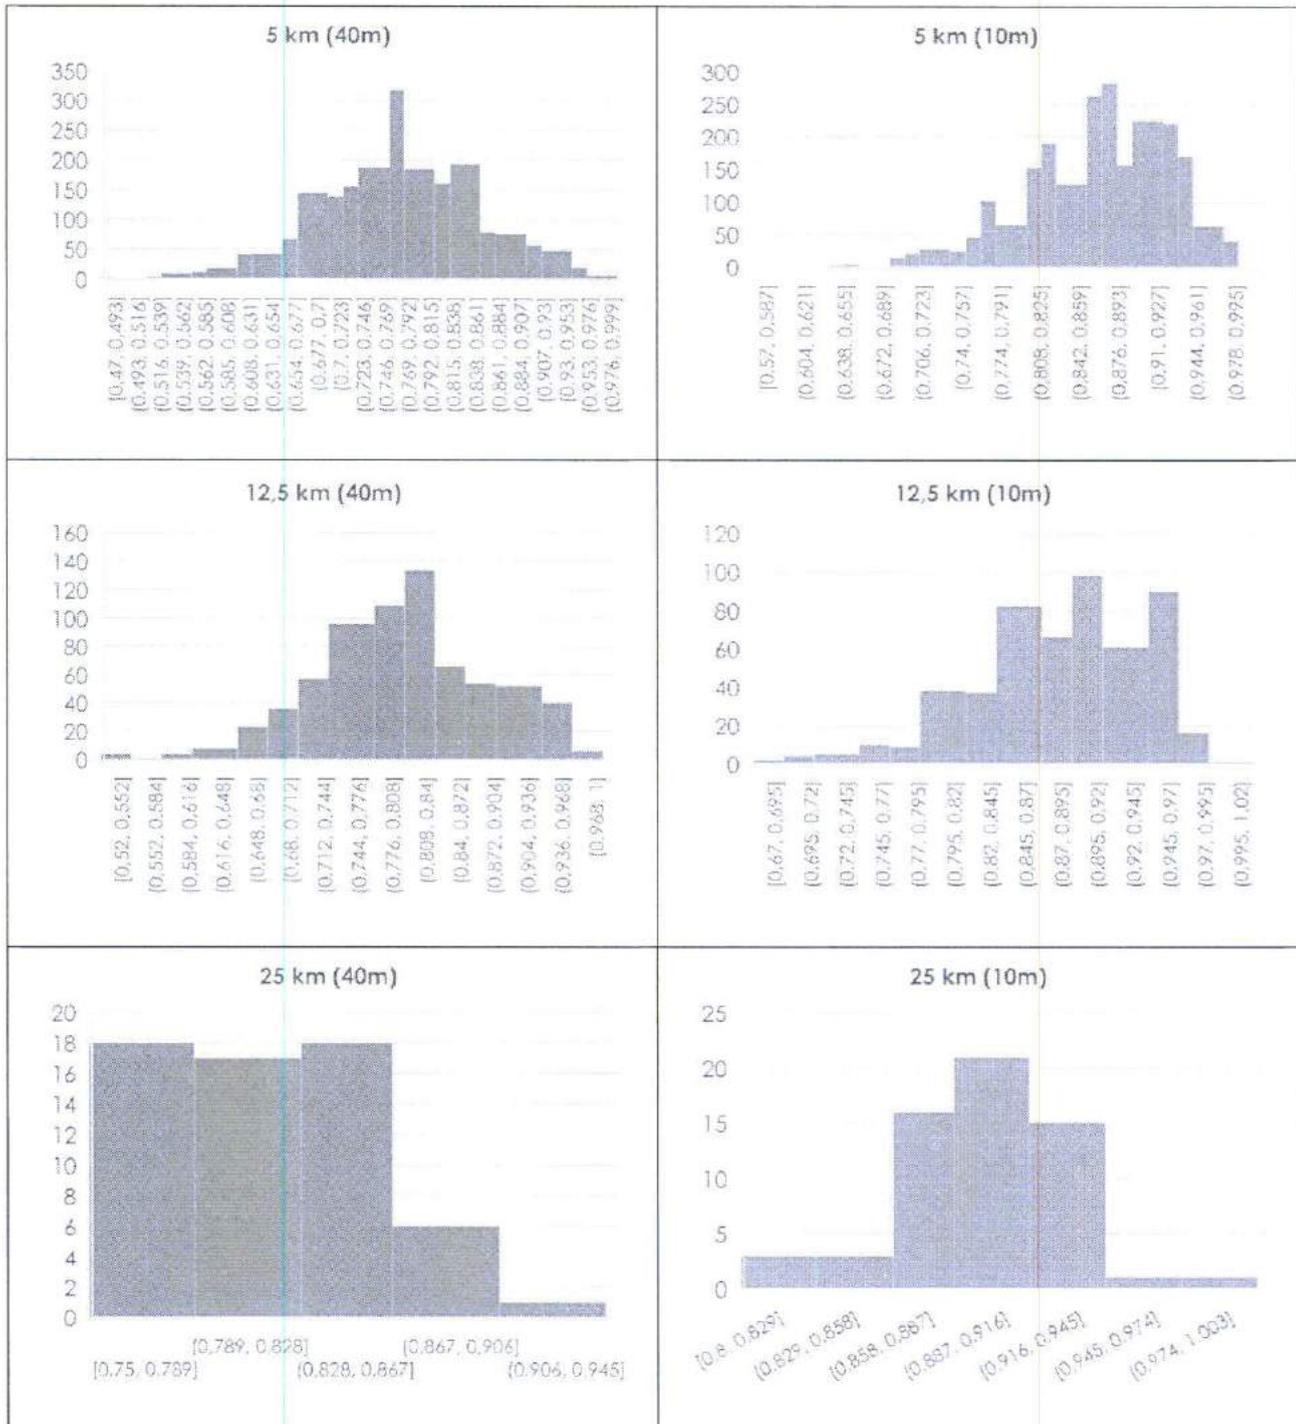
Apesar da diferença superior a 3 horas da aquisição da imagem SAR com os dados de vento, nas imagens abaixo podemos observar que existe uma coerência, em algumas regiões, na direção do vento obtido na imagem SAR e os ventos obtidos dos escaterômetros. Para uma avaliação precisa é necessário obter um par (SAR + Vento) do mesmo horário, tal pesquisa está em andamento e os resultados serão apresentados em futuros relatórios.



Podemos identificar também coerência na intensidade do vento, em nós, entretanto, conforme mencionado anteriormente, para uma avaliação precisa é necessário obter um par (SAR + Vento) do mesmo horário, tal pesquisa está em andamento e os resultados serão apresentados em futuros relatórios.



Foram testados três valores de tamanho para a janela, 5 km, 12,5 km e 25 km, para imagens IW sem reamostragem da resolução espacial (10 m) e com reamostragem (40 m), como o valor do "ratio", mencionado no procedimento, é utilizado para avaliar o dado, abaixo segue os valores de "ratio" de todas as imagens testadas. Nos gráficos da esquerda temos a distribuição do ratio para a imagem de 40 m e na direita 10 m.





Quadro com valores de média, mediana, desvio padrão e variância do "ratio" das imagens:

	40M			10M		
	5km	12,5km	25km	5km	12,5km	25km
<b>MÉDIA</b>	0,78	0,81	0,82	0,87	0,89	0,89
<b>MEDIANA</b>	0,78	0,81	0,82	0,88	0,90	0,90
<b>DESVIO PADRÃO</b>	0,082	0,081	0,044	0,062	0,058	0,033
<b>VARIÂNCIA</b>	0,0068	0,0065	0,0019	0,0039	0,0034	0,0011

Apesar da indicação de que uma janela de 5 km com imagens suavizadas pelo multilook produzem melhores resultados, mais pesquisas precisam ser realizadas antes de qualquer conclusão. Métodos probabilísticos estão sendo pesquisados e novas fontes de dados para validar os dados. Os resultados serão incluídos em relatórios futuros.

Quanto ao processamento do dado na pesquisa, a escolha é de 40 metros para reamostragem das imagens SAR e 12,5km de janela de processamento para o vento para ser possível a continuidade da comparação dos dados com os dados de escaterômetros existentes.

A compatibilização dos dados de vento gerados pelo SNAP se mostrou eficaz e sua representação nos softwares de geoprocessamento representa fidedignamente a representação feita no próprio software SNAP.

A resolução da ambiguidade de 180° de forma automatizada está sendo pesquisada no momento, com a possibilidade da utilização de dados de estações disponíveis no link <http://www.ndbc.noaa.gov/>.

## CAPÍTULO 2 – Redes Neurais Artificiais RNAs

William Branco e Dagnaldo Silva

### 2.1. INTRODUÇÃO

No capítulo 2, serão apresentados os resultados parciais (obtidos em agosto de 2016) referentes aos testes com redes neurais artificiais para a detecção automatizada de manchas de óleo no mar.

### 2.2. RESULTADOS PARCIAIS

#### 2.2.1 Configuração de ambiente para testes com Faster R-CNN

O Faster R-CNN (<https://github.com/rbgirshick/py-faster-rcnn>) é um framework para detecção de objetos em imagens baseado em *deep convolutional networks* (utilizando o CAFFE), que inclui uma *Region Proposal Network* (RPN) e uma *Object Detection Network*. Entretanto, não foi possível testar o framework, pois a máquina disponível tem GPU Nvidia GeForce GT 620M OEM com compute capability de 2.1, quando o mínimo necessário é 3.0 (<https://developer.nvidia.com/cuda-gpus>).

<b>Erro:</b>	Check failed: status == CUDNN_STATUS_SUCCESS (6 vs. 0) CUDNN_STATUS_ARCH_MISMATCH
<b>Causa:</b>	cuDNN v3.0 supports NVIDIA GPUs of compute capability 3.0 and higher and requires an NVIDIA Driver compatible with CUDA Toolkit 7.0. <a href="https://developer.nvidia.com/rdp/assets/cudnn-library-user-guide-v3-asset">https://developer.nvidia.com/rdp/assets/cudnn-library-user-guide-v3-asset</a>
	O framework utiliza a biblioteca NVIDIA cuDNN, de primitivas para deep neural networks aceleradas por GPU. <a href="https://developer.nvidia.com/rdp/cudnn-archive">https://developer.nvidia.com/rdp/cudnn-archive</a>

O objetivo do teste foi identificar com maior precisão a localização de manchas de óleo em uma imagem do Sentinel 1A, delimitando-as por meio de um retângulo destacado na imagem.

#### 2.2.2 Criação de script para conversão e recorte de imagem Sentinel 1A

Tentativa de emular os resultados esperados do uso do framework Faster RCNN, i.e., de identificar a localização de uma mancha de óleo em uma imagem Sentinel 1A com maior precisão.

O script também será útil para que o sistema faça previsões mais precisas sobre a presença ou não de manchas de óleo, ao analisar tiles da imagem ao invés da imagem inteira em um único processamento.

Os tiles gerados aproximam-se mais das imagens utilizadas para treinamento e validação da rede neural.

### 2.2.3 Criação de script para ranking de previsões

O script ranqueia/ordena os *files* gerados a partir de uma imagem Sentinel1A convertida para JPEG, em ordem decrescente de probabilidade de existência de mancha de óleo.

O ranking é armazenado em um arquivo de texto contendo o *path* de cada *file* analisado e as probabilidades de cada um pertencer a uma determinada classe (óleo ou oceano).

Esse arquivo de texto será utilizado para determinar se a imagem Sentinel deve passar pelo processamento SNAP+GDAL ou não (de acordo com a probabilidade de presença de óleo do primeiro *tile* do ranking).

### 2.2.4 Preparação de novo conjunto de imagens para treinamento da RN

Com base nos primeiros testes com os scripts de recorte e ranking, foi decidido expandir o conjunto de treinamento da rede a fim de obtermos melhores resultados.

Adição de nova classe (*land*) para identificar manchas de terra, totalizando 3 classes possíveis.

Total: 8560 imagens, distribuídas da seguinte forma:

- 2416 imagens de manchas de óleo (2132 para treinamento, 284 para teste);
- 2856 imagens do oceano (2526 para treinamento, 330 para teste);
- 3288 imagens de terra (2854 para treinamento, 434 para teste).

## CAPÍTULO 3 – Modelagem de Dados Geográficos

*Maristela Terto de Holanda e Evandro Roberto Mota*

### 3.1. INTRODUÇÃO

O termo Sistemas de Informação Geográfica (SIG) é aplicado para sistemas que realizam o tratamento computacional de dados geográficos. A principal diferença de um SIG para um sistema de informação convencional é sua capacidade de armazenar tanto os atributos descritivos como as geometrias dos diferentes tipos de dados geográficos (CÂMARA, 2005). A partir destes conceitos, segundo CÂMARA (2005), é possível indicar as principais características de SIGs:

- Inserir e integrar, numa única base de dados, informações espaciais provenientes de meio físico-biótico, de dados censitários, de cadastros urbano e rural, e outras fontes de dados como imagens de satélite, e GPS.
- Oferecer mecanismos para combinar as várias informações, através de algoritmos de manipulação e análise, bem como para consultar, recuperar e visualizar o conteúdo da base de dados geográficos.

Por outro lado, um modelo de dados é um conjunto de conceitos que podem ser usados para descrever a estrutura e as operações em um banco de dados (ELMASRI E NAVATHE, 2004). O modelo busca sistematizar o entendimento que é desenvolvido a respeito de objetos e fenômenos que serão representados em um sistema informatizado. Os objetos e fenômenos reais, no entanto, são complexos demais para permitir uma representação completa, considerando os recursos à disposição dos sistemas gerenciadores de bancos de dados (SGBD) atuais. Desta forma, é necessário construir uma abstração dos objetos e fenômenos do mundo real, de modo a obter uma forma de representação conveniente, embora simplificada, que seja adequada às finalidades das aplicações do banco de dados (BORGES *et al.*, 2005).

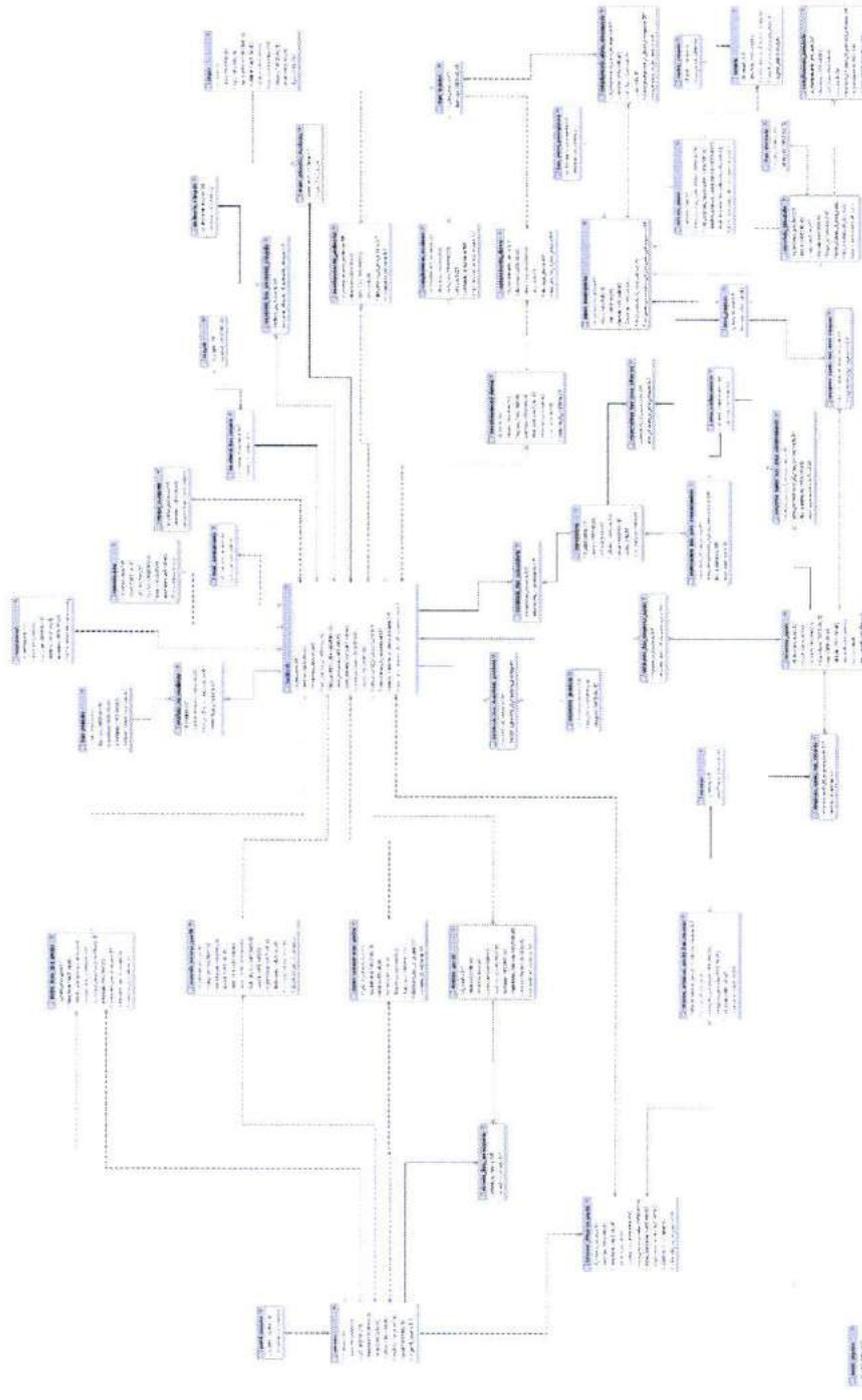
No presente capítulo serão abordados os resultados referente a Atividade 7.1 do projeto SISNOLEO, onde apresenta o desenvolvimento da modelagem do banco de dados do Sistema de Informações sobre Incidentes de Poluição por Óleo em Águas Sob Jurisdição Nacional, SISNÓLEO.



## 3.2. RESULTADOS PARCIAIS

### 3.2.1 Diagrama de Entidade-Relacionamento

A seguir, podem ser visualizados os resultados parciais do modelo de dados e seus módulos<sup>3</sup>:



<sup>3</sup> Para melhor visualização do diagrama, segue em anexo o modelo completo impresso em folha A1.



## BIBLIOGRAFIA

- BORGES, A. V.; DAVIS JR, C. A.; LAENDER, A. H. F. Capítulo 3: Modelagem conceitual de dados geográficos. Em: CASANOVA, M.; CÂMARA, G.; DAVIS, C.; VINHAS, L.; QUEIROZ, G.R. **Banco de Dados Geográfico**. Edição em papel: MundoGEO, Curitiba-PR, 2005. Disponível em: <http://www.dpi.inpe.br/livros/bdados/capitulos.html>.
- CÂMARA, G. Capítulo 1: Representação computacional de dados geográficos. Em: CASANOVA, M.; CÂMARA, G.; DAVIS, C.; VINHAS, L.; QUEIROZ, G.R. **Banco de Dados Geográfico**. Edição em papel: MundoGEO, Curitiba-PR, 2005. Disponível em: <http://www.dpi.inpe.br/livros/bdados/capitulos.html>.
- ELMASRI, R.; NAVATHE, S. **Fundamentals of Database Systems**. Pearson Education, 2004.
- HERSBACH, H. An Improved Geophysical Model Function for ERS C-Band Scatterometry. **Report of the European Centre Medium-Range Weather Forecasts (ECMWF)**, 2003.
- VU LA, T.; KHENCHAF, A.; COMBLET, F.; NAHUM, C.; GHANMI, H. Exploitation of Electromagnetic Models for Sea Wind Speed Estimation from C-Band Sentinel-1 Images. **Journal of Electromagnetic Analysis and Applications**, 2016. Disponível em: <http://www.scirp.org/Journal/PaperInformation.aspx?PaperID=65210>
- WACKERMAN, C. C.; PICHEL, W.G.; CLEMENTE-COLON, P. Automated Estimation of Wind Vectors from SAR. **12th Conference on Interactions of the Sea and Atmosphere**, 2003.



ANEXOS

Anexo I – Cronograma de Trabalho

ABRIL 2016 - MARÇO 2017											
2016											
2017											

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 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.												

DIPRO

Proc.: \_\_\_\_\_

Fis.: \_\_\_\_\_

Rub.: 123

EM BRANCO



[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