



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

BRASÍLIA
OUTUBRO DE 2016

SISNOLEO

Projeto - Oil & Gas Production and Operational Efficiency
Reino Unido

Documento: **Relatório Mensal - Outubro**

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 a 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 SISNOLEO visando responder eficazmente aos derramamentos de óleo.



SUMÁRIO

CAPÍTULO 1 - Pesquisa de Detecção de Óleo no Mar com Sentinel-1	5
1.1. INTRODUÇÃO	5
1.2. MATERIAL E MÉTODOS	6
1.2.1 Dados Utilizados	6
1.2.2 Procedimentos	6
1.3. CONCLUSÕES E OBSERVAÇÕES	12
CAPÍTULO 2 – Modelagem de Dados Geográficos	18
2.1. INTRODUÇÃO	18
2.2. RESULTADOS PARCIAIS	19
1.2.3 Diagrama de Entidade-Relacionamento	19
a) Formulários do Plano Nacional de Contingência	19
b) Incidente	20
BIBLIOGRAFIA	21
ANEXOS	22
Anexo I – Cronograma de Atividades	22

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

Alexandre Corrêa da Silva

1.1. INTRODUÇÃO

Prosseguindo com o cronograma de desenvolvimento após as especificações da geração dos polígonos resultantes da segmentação de manchas escuras nas imagens SAR é necessário uma filtragem dos dados através de algum procedimento para que as manchas possam ser classificadas como óleo ou *look-alike*.

Nesse relatório é descrito o procedimento adotado para se chegar a limpeza e classificação pelas informações de vento, intensidade e geometria de amostras selecionadas com elevado potencial de serem manchas de óleo.

1.2. MATERIAL E MÉTODOS

1.2.1 Dados Utilizados

As imagens SAR utilizadas de insumo, bem como seus parâmetros de processamento foram definidos com base no relatório de setembro, as mesmas 14 imagens Sentinel-1 IW da costa do Brasil, com a retirada da correção de borda e detecção de embarcações, uma vez que a correção de borda degradava a radiometria das imagens nas regiões próximas as bordas e a detecção de embarcações ainda não teve seus parâmetros testados e comparados com dados reais da posição de embarcações para configurar seus parâmetros de forma consistente. O multilook de 40 m foi adotado e os parâmetros de processamento para a segmentação ficaram especificados em 672px, 1.4dB e 0.10 km² entretanto para as áreas de recortes conforme mostrado no relatório setembro, para as imagens inteiras foi necessário um ajuste de 0.2dB para obter resultados similares. Portanto foram utilizadas as 14 imagens segmentadas com parâmetros de 672px, 1.4dB, 0.10 km² e 672px, 1.6dB, 0.10 km².

1.2.2 Procedimentos

Segundo Brekke e Soberg (2005) a velocidade do vento se relaciona com a assinatura das manchas conforme no quadro a seguir:

VELOCIDADE DO VENTO	ASSINATURAS DAS MANCHAS
0 M/S	Sem retorno da superfície do mar
3 M/S	Sem impacto de vento nas manchas de óleo
3 A 7-10 M/S	Alta probabilidade de manchas de óleo e look-alikes Menos alarmes falsos de áreas locais de baixo vento
>7-10M/S	Manchas de óleo continuam visíveis e homogêneas Somente óleo espesso Óleos finos não serão visíveis Óleos grossos podem ser visíveis acima de 10 m/s

Regiões com velocidade do vento inferior a 3 m/s devem ser filtradas. Para isso a informação do vento precisa ser extraída da imagem SAR.

O SNAP possui um processo de extração de vento utilizando o algoritmo CMOD5, conforme especificado no Relatório de Agosto. Esse processo foi utilizado a partir das imagens imediatamente após a calibração das imagens, processamento descrito no Relatório de Setembro.

Abaixo podemos ver o gráfico do processo de extração de vento das imagens SAR:



Conforme descrito nas informações a seguir, é possível extrair vento de 1x1 km de imagens SAR Sentinel-1 EW e EW. Então, para o processo *Wind-Field-Estimation* foram testados tamanhos de janela a partir de 1,0 km e chegou-se a um valor padrão de 1,5 km para esse projeto.

Acquisition Mode	L2 OCN Product Component	Input L1 Product
SM	OWS	SLC
	OWI	GRD
	RVL	SLC
IW	OWI	GRD
	RVL	SLC
EW	OWI	GRD
	RVL	SLC
WW	OSW	SLC
	OWI	SLC
	RVL	SLC

Fonte: <https://earth.esa.int/web/sentinel/technical-guides/sentinel-1-sar/products-algorithms/level-2-algorithms>

OWI Characteristics	
Coordinate System	Ground Range
Incidence angle [°]	S1: 22.3 S2: 25.6 S3: 31.2 S4: 36.4 S5: 41.0 S6: 43.8 IW1: 32.9 IW2: 38.4 IW3: 43.1 EW1: 23.7 EW2: 30.9 EW3: 36.2 EW4: 40.9 EW5: 44.5 WV1: 23 WV2: 36.5
Ocean Wind Field Spatial Resolution [km x km]	SM: 1x1 Product splits 170km x 80km SM image into 170x80 images of 1km x 1km for OWI estimation. IW: 1x1 Product splits 170km x 250km IW image into 170x250 images of 1km x 1km for OWI estimation. EW: 1x1 Product splits 400km x 400km EW image into 400x400 images of 1km x 1km for OWI estimation. WV: 20x20
Ocean Wind Field Grid Dimension [azimuth cell x ground range cell]	SM: 170x80 IW: 170x250 EW: 400x400 WV: 1x1
Wind Speed [m/s]	± [0,25], RMSe < 2.0
Wind Direction [degh]	± [0,360], RMSe < 30

Fonte:

<https://earth.esa.int/web/sentinel/ocean-wind-field-component>

Após esse processo os resultados no formato xml criados na pasta "C:\Users\\.snap\var\log" devem ser padronizados para posteriormente serem convertidos em vetores no QGIS.

Exemplo da formatação:

Antes (conforme escrito pelo programa)

```
<?xml version="1.0" encoding="UTF-8"?>
<Detection>
  <windFieldEstimated bandName="Sigma0_VV">
    <windFieldInfo lat="-22.69" lon="-43.09" speed="2.6" dx="-50.0" dy="0.0" ratio="0.99" />
    <windFieldInfo lat="-22.7" lon="-43.04" speed="1.7" dx="-32.94" dy="-37.62" ratio="0.96" />
    <windFieldInfo lat="-22.69" lon="-43.1" speed="1.3" dx="-16.28" dy="-47.28" ratio="0.98" />
  </windFieldEstimated>
</Detection>
```

Depois (cabecalho, sem informações desnecessárias e espaços substituídos por tabulação)

LON	LAT	SPEED	DX	DY	RATIO
-22.69	-43.09	2.6	-50.0	0.0	0.99
-22.7	-43.04	1.7	-32.94	-37.62	0.96
-22.69	-43.1	1.3	-16.28	-47.28	0.98



No QGIS o arquivo formatado é carregado pelo comando:

- Camada
- Adicionar camada
- A partir de um texto delimitado...

Especificando o arquivo no campo "Nome do Arquivo", um nome para a camada a ser criada, codificação UTF-8 e configurando os parâmetros para:

- ✓ Delimitadores personalizados
- ✓ Tabulação
- ✓ Número de linhas de cabeçalho a descartar 0
- ✓ Primeiro registro tem nomes de campos
- ✓ Coordenadas de ponto
- ✓ Campo X LON
- ✓ Campo Y LAT

Após esses passos é preciso especificar o Sistema de coordenadas de referência (SRC), para esse caso deve ser utilizado o WGS84 – EPSG:4326

Par a criação de um Raster no QGIS utilizando os pontos deve se utilizar a ferramenta de interpolação que pode ser selecionada em:

- Raster
- Interpolação
- Interpolação

Selecionar a camada vetorial dos pontos com os dados de vento e selecionar o atributo de interpolação SPEED para adicionar. O método de interpolação utilizado é o de Peso pelo inverso da distância (IDW)

- ✓ Célula X 0,015
- ✓ Célula Y 0,015

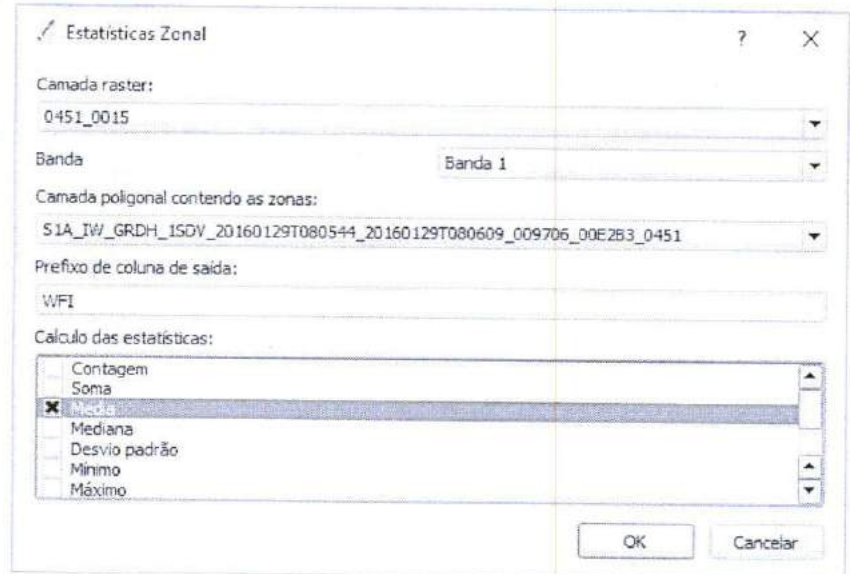
Especificar arquivo de saída em TIFF.

A informação da velocidade do vento é associada ao vetor utilizando a ferramenta estatísticas por zona do QGIS, essa ferramenta pode ser acessada em:

- Raster
- Estatísticas por zonas
- Estatísticas por zonas

Especificar a camada raster do vento e a camada poligonal da mesma imagem SAR, estabelecer um prefixo para o nome da coluna, nesse caso WFI (*Wind Field Intensity*) e calcular as estatísticas da média.

Imagem da ferramenta utilizada para a extração da informação de vento no QGIS.



Segundo Topouzelis (2008) as formações escuras que são comumente classificadas por foto-interpretadores como potenciais manchas de óleo seguem os critérios:

- Homogeneidade escura em uma área de vento uniforme;
- Áreas escuras lineares, não extremamente largas, com curvas abruptas.

Formações escuras são comumente classificadas por foto-interpretadores como *look-alikes* de acordo com os seguintes critérios:

- Áreas de baixo vento;
- Zonas costeiras;
- Áreas escuras longas com curvas suaves em forma espiral.

Keramitsoglou et al. (2006) utilizou o número de objetos identificados na vizinhança de um objeto candidato, dentro de 5 km, variando de 0 a 100. Caso tenha muitos objetos na vizinhança menor a chance de ser uma mancha de óleo. Também relativo a área, o intervalo foi de 0 a 50 km², Konings (1996) relatou que de 283 amostras de manchas de óleo no Mar do Norte, 62% tinham menos de 1km², 18% estavam entre 1-2 km², 11% entre 2-5 km², 7% entre 5-10 km² e somente 2% eram maiores do que 10 km².

Excentricidade do objeto, pode ser descrita como a razão entre o comprimento da maior corda do objeto pela maior corda perpendicular a esta, variando de 0 a 21, manchas de óleo tem alta excentricidade.

Proximidade do objeto com a costa, 0-55 km, a probabilidade de objetos escuros próximos à costa serem óleo é baixa.



Ainda segundo Topouzelis (2008) as características comumente utilizadas para a detecção de vazamentos de óleo podem ser divididas em três categorias principais: (1) características geométricas; (2) características físicas e; (3) características relacionais.

Abaixo as 25 características mais usadas para detecção de óleo na maioria das pesquisas, segundo Topouzelis (2008):

Nº	Features	Code
1	Area	A
2	Perimeter	P
3	Perimeter to area ratio	P/A
4	Complexity	C
5	Shape factor I	SP1
6	Shape factor II	SP2
7	Object mean value	OMe
8	Object standard deviation	OSd
9	Object power to mean ratio	Opm
10	Background mean value	BMe
11	Background standard deviation	BSd
12	Background power to mean ratio	Bpm
13	Ratio of the power to mean ratios	Opm/Bpm
14	Mean contrast	ConMe
15	Max contrast	ConMax
16	Mean contrast ratio	ConRaMe
17	Standard deviation contrast ratio	ConRaSd
18	Local area contrast ratio	ConLa
19	Mean border gradient	GMe
20	Standard deviation border gradient	GSd
21	Max border gradient	GMax
22	Mean Difference to Neighbors	NDm
23	Spectral texture	TSp
24	Shape texture	TSh
25	Mean Haralick texture	THm

Características aplicadas por vários algoritmos de detecção de óleo no mar segundo Brekke e Soberg (2005):

1. Slick area (A)
2. Slick perimeter (P)
3. P/A
4. Slick complexity
5. Spreading (low for long thin slicks, high for circular shape)
6. Slick width
7. First invariant planar moment (Hu, 1962)
8. Dispersion of slick pixels from longitudinal axis
9. Object/dark area standard deviation
10. Background/outside dark area standard deviation
11. Max contrast (between object and background)
12. Mean contrast (between object and background)
13. Max border gradient
14. Mean border gradient
15. Gradient standard deviation
16. Local area contrast ratio
17. Power-to-mean ratio of the slick
18. Homogeneity of surroundings
19. Average NRCS inside dark area
20. 20 Average NRCS in limited area outside dark area
21. Gradient of the NRCS across the dark area perimeter
22. Ratio #9 to #10
23. Ratio #19 to #9
24. Ratio #20 to #10
25. Ratio #23 to #24
26. Ratio #19 to #20
27. Distance to a point source
28. Number of detected spots in the scene
29. Number of neighbouring spots

Utilizando as informações presentes nos artigos citados, especificamente as definições das características presentes em Topouzelis et al. (2009), algumas características foram testadas e escolhidas

para selecionar as manchas que melhores cabem dentro do padrão de manchas de óleo. Essas características, que foram testadas até a geração desse relatório, são:

- A (Área) e P (Perímetro), calculados em km² e km respectivamente utilizando para o caso das regiões próximas a costa do Brasil a projeção Cônica Equivalente de Albers.
- PA, razão entre o Perímetro P e a Área A.
- C3, complexidade seguindo a definição de Karathanassi et al. (2006): $C = P / 4 \cdot \text{raiz}(A)$
- OMe – média da intensidade do pixel do objeto
- OSd – desvio padrão da intensidade do pixel do objeto
- Opm = OSd/OMe
- BMe - média da intensidade do pixel da imagem em um buffer de 1km dos objetos
- BSd – desvio padrão da intensidade do pixel da imagem em um buffer de 1km dos objetos
- Bpm = BSd/BMe
- ConMe = BMe - OMe
- ConMax = BMe - (menor valor de pixel do objeto)
- ConRaMe = OMe/BMe
- ConRaSd = OSd/BSd

Imagem da ferramenta utilizada para a extração da informação das imagens SAR no QGIS.

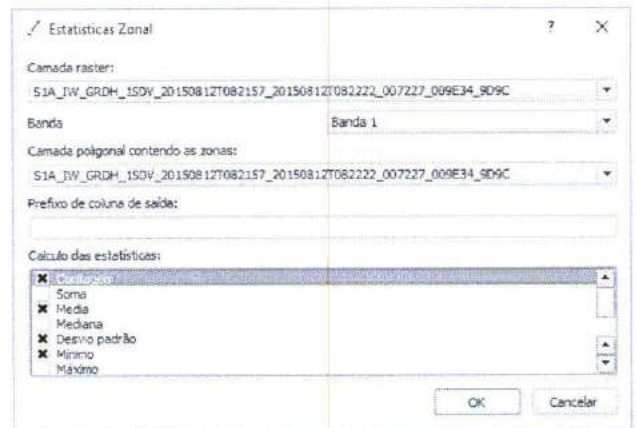
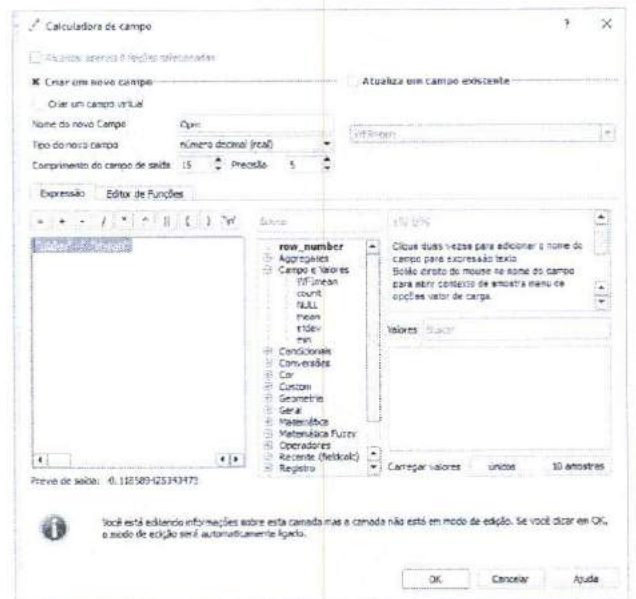


Imagem da criação de um novo campo na tabela para calcular o valor de uma nova característica:

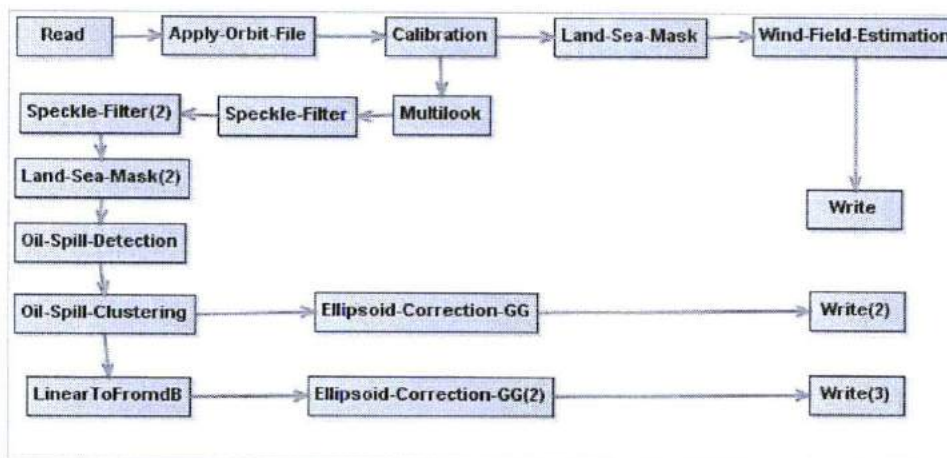


1.3. CONCLUSÕES E OBSERVAÇÕES

Com os testes realizados até o momento é possível considerar um fluxo de processamento baseado nas informações obtidas nessas pesquisas. A indicação desse fluxo do processo é apresentada abaixo:

- Carregar Imagem Compactada
- Aplicar órbita
 - Calibrar para Sigma Naught (somente copolarização)
 - Máscara Terra/Mar
 - Extrair vento 1km
 - Multilook 40m
 - Filtro Median 3x3
 - Filtro Gamma MAP 5x5
 - Máscara Terra/Mar
 - Segmentação de manchas escuras 672 1.4 0.10 para recortes ou 672 1.6 0.10 para a imagem inteira
 - Correção elipsoidal WGS84 e conversão GeoTIFF – manchas escuras
 - Conversão de Linear para dB - imagem SAR
 - Correção elipsoidal WGS84 e conversão GeoTIFF – imagem SAR


Abaixo exemplificação do gráfico do procedimento:



Para melhorar o desempenho em máquinas com menor capacidade de processamento é recomendado que o processamento seja dividido em partes, sendo essas partes:

1. Read (0) / Apply-Orbit-File / Calibration / Write (1)
2. Read (1) / Land-Sea-Mask / Wind-Field-Estimation / Write (2)
3. Read (1) / Multilook / Speckle-Filter / Speckle-Filter / Land-Sea-Mask / Write (3)
4. Read (3) / Oil-Spill-Detection / Oil-Spill-Clustering / Write (4)
5. Read (4) / Ellipsoid-Correction-GG / Write (5)
6. Read (4) / LinearToFromdB / Ellipsoid-Correction-GG / Write (6)

Com relação às características das manchas algumas áreas foram selecionadas como amostras e tiveram suas características extraídas de forma que pudessem servir de insumo para a criação de uma nota (GRADE). Abaixo podemos ver as amostras:



Estatísticas extraídas das amostras:

	A	P	WFI	Apixels	OMe	OSd
Mínimo	0,024913	0,880702	2,743871	17	-23,013	0,144304
Máximo	32,06612	92,09384	5,601263	21871	-18,5835	1,199424

	min	PA	C3	Opm	BMe	BSd
Mínimo	-25,8291	2,872	1,39493	-0,05212	-21,0956	0,459886
Máximo	-18,9867	35,35049	4,88225	-0,00676	-17,0777	1,76581



	Bpm	OpmBpm	ConMe	ConMax	ConRaMe	ConRaSd
Mínimo	-0,08794	0,12588	1,23077	1,65989	1,06228	0,13458
Máximo	-0,02654	0,93079	2,42267	6,06213	1,12472	1,0327

Com base nas estatísticas uma nota "GRADE" (0 a 20) pode ser gerada para avaliar a possibilidade de uma mancha ser de óleo ou não. No QGIS foi criado um campo na tabela do tipo Inteiro e comprimento 10, com a regra abaixo:

```
if( "WFI" >= 2.73 ,1,0) + if( "WFI" >= 3.00 ,1,0) + if( "WFI" > 10.00 ,-1,0) + if( "OMe" < -18.50 ,5,0)
+ if( "OMe" < -23.50 ,-5,0) + if( "C3" < 4.89 ,3,0) + if( "C3" < 1.00 ,-3,0)
+ if( "PA" < 35.36 ,1,0) + if( "PA" < 2.5 ,-1,0) + if( "Opm" > -0.053 ,3,0)
+ if( "ConMe" > 1.0 ,2,0) + if( "ConMe" > 2.5 ,-2,0) + if( "ConMax" > 1.6 ,1,0)
+ if( "ConMax" > 6.1 ,-1,0) + if( "OpmBpm" < 1.0 ,3,0) + if( "OpmBpm" < 0.1 ,-3,0)
```

Com o atributo GRADE é possível filtrar as feições de acordo com o valor resultante da fórmula, abaixo analisamos os resultados para o filtro: GRADE >= 19

- Imagem final 0451:
 - 216 feições iniciais, 15 após o filtro
 - Redução de 93% do número de feições
- Imagem final 2D51:
 - 1236 feições iniciais, 125 após o filtro
 - Redução de 89% do número de feições
- Imagem final 8803:
 - 248 feições iniciais, 36 após o filtro
 - Redução de 85% do número de feições
- Imagem final B5E6:
 - 5595 feições iniciais, 462 após o filtro
 - Redução de 91% do número de feições

A seguir visualização dos polígonos sobrepostos das imagens, a feição de antes (vermelho) e após (verde) o filtro, embaixo e em cima respectivamente na ordem de representação das camadas:






Imagem 0451:





Imagem B5E6:



Utilizando como referência a tabela das características mais utilizadas para a detecção de óleo no mar por Topouzelis (2008), das 25 características apenas 15 foram utilizadas para se chegar aos resultados apresentados nesse relatório, o que indica que a implementação no processo de mais características pode melhorar ainda mais o resultado.

Com a automatização da extração das características no procedimento, se torna mais fácil a delimitação dos parâmetros limites tanto da segmentação quanto da classificação. Desse modo, pode-se pesquisar melhor os parâmetros que melhor recobrem as manchas escuras na segmentação e após



recorrer às amostras para coletar as estatísticas para replicar para todas as imagens. É importante frisar que quanto maior o número de amostras maior será o percentual de acerto.

O ideal é que a automatização desses processos calcule automaticamente os pesos e as regras de acordo com as amostras ou que esses parâmetros possam ser modificados pelo usuário de modo que possam ser observados diferentes níveis de amostras (pouca, média ou alta chance de óleo).

A classificação por meio de nota ou percentual é uma solução para preservar as feições segmentadas e aumentar o percentual de acerto, uma vez que as feições possuem muitas características similares. Entretanto é necessário refinar o sistema de notas para que sejam especificados pesos mais precisos e parâmetros mais específicos com características exclusivas das manchas de óleo.

CAPÍTULO 2 – Modelagem de Dados Geográficos

Maristela Terto de Holanda e Evandro Roberto Mota

2.1. INTRODUÇÃO

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.

Neste relatório são apresentados os resultados parciais referentes aos seguintes temas de discussão em reuniões com IBAMA:

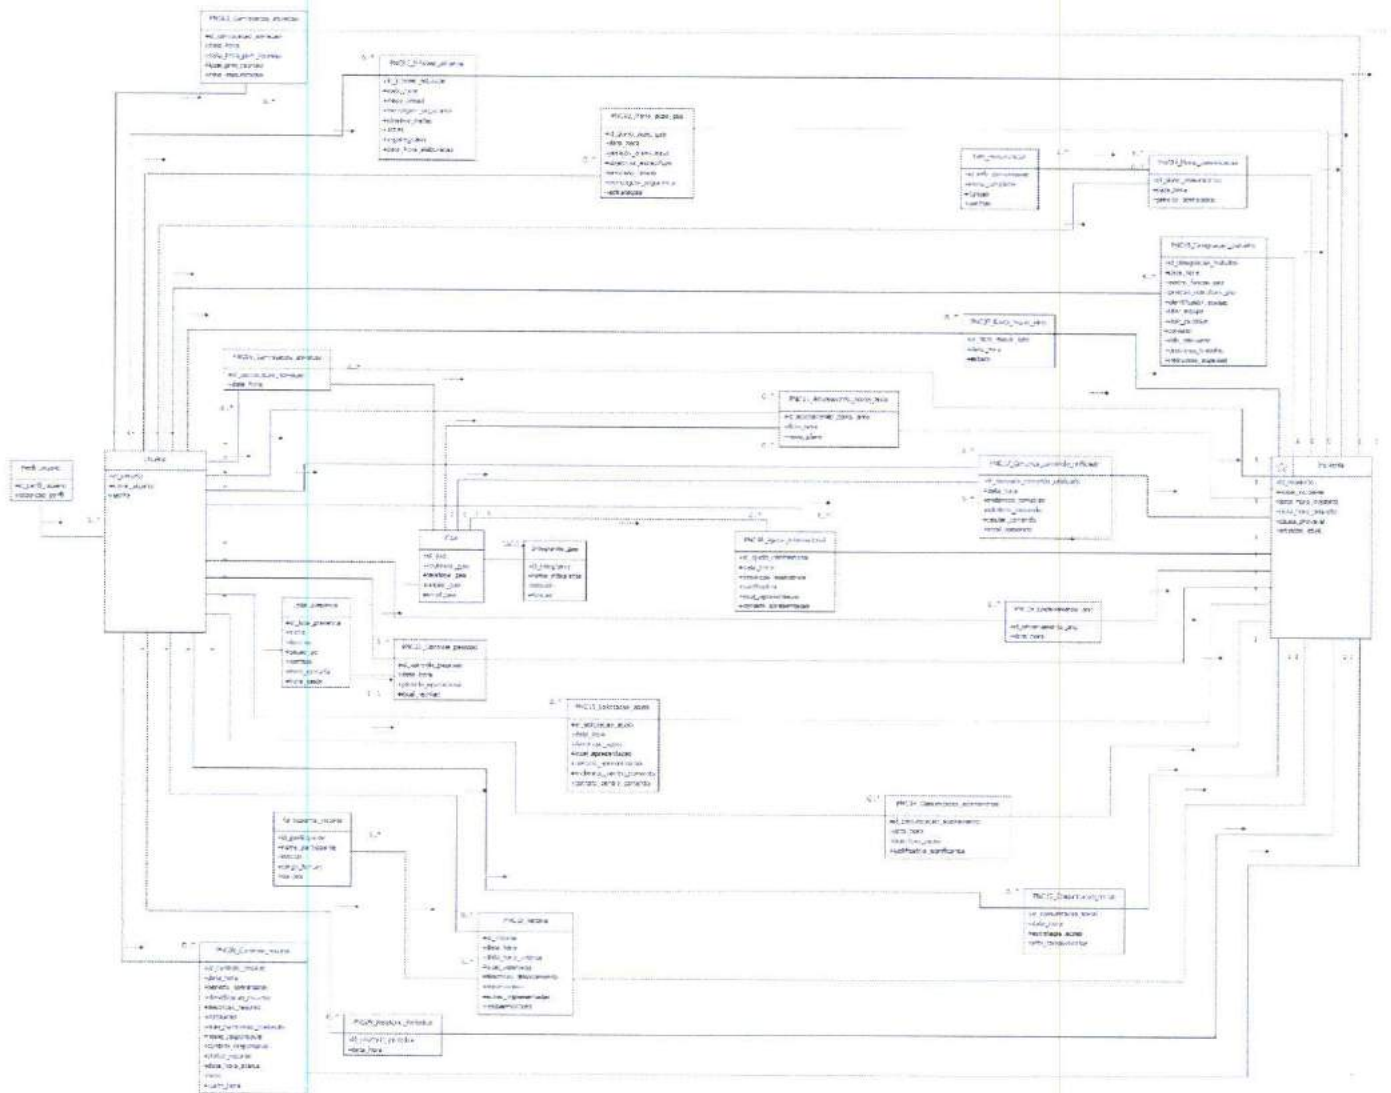
- Formulários do Plano Nacional de Contigência (PNC) e seus atributos, definindo as entidades envolvidas em sua modelagem;
- Modelagem conceitual do sistema, dividida em duas partes: gestão dos formulários e gestão do incidente, abordando cada uma das entidades do modelo para validação.
- Revisão da modelagem de dados, como a unificação das entidades de incidente e exercício simulado, bem como as cardinalidades dos formulários do PNC.

2.2. RESULTADOS PARCIAIS

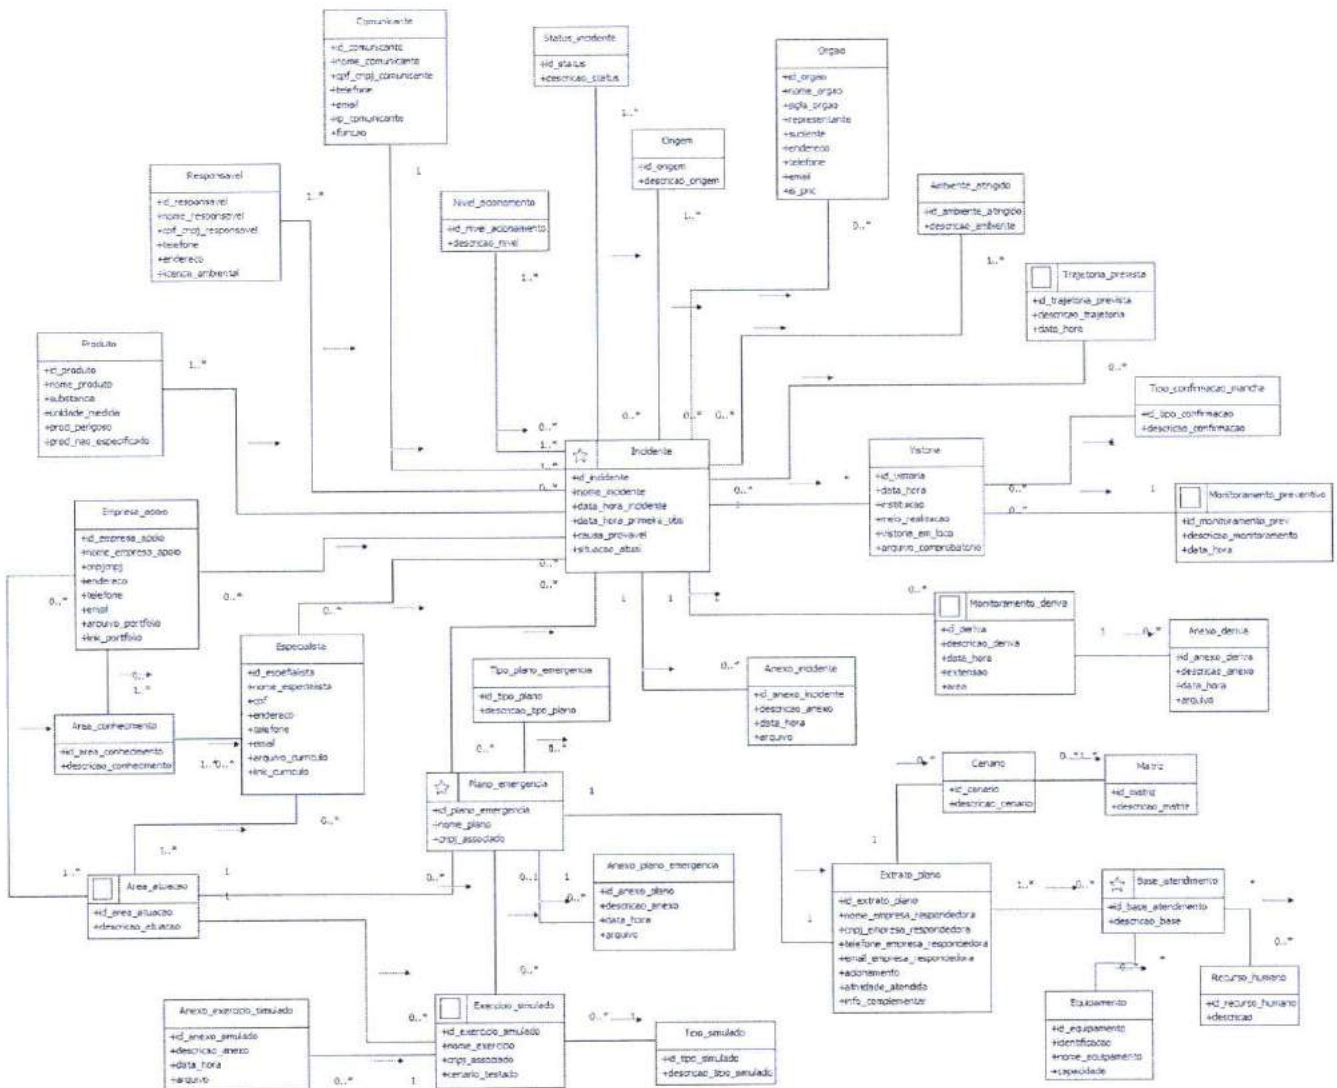
1.2.3 Diagrama de Entidade-Relacionamento

Os diagramas conceituais apresentados foram elaborados utilizando a ferramenta de modelagem starUML baseado no modelo OMT-G.

a) Formulários do Plano Nacional de Contingência



b) Incidente





BIBLIOGRAFIA

- BREKKE, C.; SOLBERG, A. Oil spill detection by satellite remote sensing. **Remote Sensing of Environment**, vol. 95, nº. 1, pp. 1–13, 2005.
- HU, M. -K. Visual pattern recognition by moment invariants. IEEE. **Transactions on Information Theory**, 8, 179–187, 1962.
- KARATHANASSI, V.; TOPOUZELIS, K.; PAVLAKIS, P.; ROKOS, D. An object-oriented methodology to detect oil spills. **International Journal of Remote Sensing**, 27, pp.5235–5251, 2006.
- KERAMITSOGLU, I., CARTALIS, C., KIRANOUDIS, C. T. Automatic identification of oil spills on satellite images. **Environmental Modelling & Software**. Volume 21, Issue 5, May, Pages 640–652, 2006.
- KONINGS, H. Oil pollution monitoring on the North Sea. Technical Note. **Spill Science and Technology Bulletin** 3, 47–52, 1996.
- TOPOUZELIS K. Oil Spill Detection by SAR Images: Dark Formation Detection, Feature Extraction and Classification Algorithms. **Sensors**, 8, 6642–6659, 2008.
- TOPOUZELIS, K., STATHAKIS, D., KARATHANASSI, V. Investigation of genetic algorithms contribution to feature selection for oil spill detection. **International Journal of Remote Sensing**. Vol. 30, No. 3, 10 February, 611-625, 2009.



ANEXOS

Anexo I – Cronograma de Atividades

ABRIL 2016 - MARÇO 2017	2017
2016	

PRODUTOS	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar
Produto 6. 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)												
Produto 7. 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.: _____
Fls.: 165
Rub.: _____

EM BRANCO



www.hexgis.com

BRASÍLIA-DF

SCN QUADRA 01 BLOCO F SALAS:1611/1614

ED. AMERICA OFFICE TOWER

CEP: 70.711-905

+ 55 61 34476213