



Uso de algoritmos de extração de características na geração vetores de movimento atmosférico

Use of feature extraction algorithms to produce atmospheric motion vectors



Artigo

Submetido em 26.06.16 | Aceito em 06.04.17 | Disponível!Disponível on-line em 25.04.18

Jonas Augusto Galvão Xavier* e Aida Araújo Ferreira
Instituto Federal de Pernambuco | *jonas.agx@gmail.com

RESUMO

Este trabalho avalia o uso de algoritmos de extração de características, ORB, SURF e SIFT, para gerar vetores de movimento atmosférico a partir de imagens de satélite. Um quarto algoritmo de controle foi usado, chamado NEGRI, baseado em métodos clássicos. Foram realizados dois experimentos. O primeiro avalia a extração das características pela quantidade e tempo gasto para encontrá-las. O segundo experimento compara os vetores gerados pelos diferentes algoritmos. Os algoritmos de extração apresentaram vantagens na geração dos vetores, são elas: menor tempo de processamento e maior robustez aos diferentes tipos de nuvens.

Palavras-chaves: *processamento de imagem, extração de características, vetores de movimento atmosférico.*

ABSTRACT

This paper evaluates the use of feature extraction algorithms, ORB, SURF and SIFT, to make Atmospheric Motion Vectors from satellite pictures. A fourth reference algorithm, called NEGRI, based on classic techniques was also used. Two experiments were performed. The first evaluates the detection of features based on the quantity and time spent searching for them. The second experiment compares the vectors made by each algorithm. The feature extraction algorithms presented advantages over to the control one, such as: faster processing time and robustness to different kinds of clouds.

Keywords: *image processing, feature extraction, atmospheric motion vectors.*

1. Introdução

Modelos meteorológicos dependem de vetores de movimento atmosférico, ou campos de ventos, Marshall (1998) e Leese et al. (1971). Esses vetores descrevem a direção, sentido e velocidade de uma nuvem, ou parte dela. Através dessa informação é possível prever temperatura, umidade, tempestades, entre várias outras propriedades e fenômenos climáticos. A precisão nesses vetores depende do quão bem representam o deslocamento de uma nuvem. A precisão também envolve o tamanho das nuvens em movimento, um mapa de vetores pode, por exemplo, conter apenas o movimento de nuvens maiores que um valor definido, ignorando nuvens de área menor o que se chama escala do mapa.

Aumentar a escala desses vetores pode fornecer informações valiosas sobre a velocidade de ventos em diferentes camadas atmosféricas.

Nuvens podem mudar de formato, tamanho, posição e orientação ao longo de uma série histórica de imagens. Existe também o ruído inerente à representação da informação. É importante que o algoritmo de detecção e extração de características seja robusto para lidar com a diversidade das imagens de satélite.

A abordagem clássica para geração de mapas de movimento atmosférico consiste em comparar a similaridade de regiões de imagens em uma série histórica. A detecção de áreas de interesse acontece pela busca de pixels individuais cujo valor está dentro de um intervalo conhecido. Cada região de interesse de uma imagem é

comparada às regiões da imagem seguinte na série em busca da mais similar. Essa similaridade entre matrizes é calculada pela correlação de Pearson.

Este trabalho se propõe a comparar o desempenho de algoritmos de extração de características com o método clássico de geração de vetores. As imagens usadas são do projeto GOES Noaa (2017), sobre o oceano Pacífico ao oeste da América central. Três algoritmos de extração de características foram usados, são eles SIFT (*Scale-invariant feature transform*, Lowe (1999)), SURF (*Speeded Up Robust Features*, Bay et al. (2008)) e ORB (*Oriented FAST and Rotated BRIEF*, Rublee et al. (2011)). Um quarto algoritmo de controle foi usado, este último é baseado no trabalho de Negri e Machado (2008) e serve como referência comparativa de método clássico.

A seção 2 trata do problema de reconhecimento de padrões em nuvens. O método clássico é apresentado, assim como algoritmos de extração são apresentados e discutidos. Os experimentos realizados estão descritos na seção 3. Logo após são apresentados os resultados e então a conclusão do trabalho.

2. Reconhecimento de nuvens

Nuvens são aglomerados de vapor e outros gases condensados, flutuando em alguma camada atmosférica. Elas podem mudar de formato, tamanho, posição e orientação ao longo do tempo. A área de uma nuvem depende da precisão do instrumento de observação. No canal visível da luz é necessária uma densidade mínima para que o vapor de água reflita a luz, do contrário a luz passará através do vapor sem refletir uma quantidade perceptível de luz. Por isso satélites fotografam nuvens a partir de diferentes frequências de onda. As frequências mais comuns além da luz visível são infravermelho e ultravioleta. Essas frequências mostram propriedades que a luz visível não capta com precisão, como a temperatura no caso do infravermelho.

A quantidade de variações visuais numa nuvem é proporcional ao intervalo das observações, ou seja, são menores quanto menor

for o intervalo entre as observações feitas. Usando essa premissa é possível construir sistemas capazes de identificar uma mesma nuvem ao longo de uma série de imagens, dado que o intervalo entre essas imagens seja suficientemente curto, Leese et al. (1971).

Dadas duas imagens, F_0 e F_1 , como selecionar e identificar padrões presentes nas duas imagens? A abordagem clássica, usada por Marshall (1998), Leese et al. (1971) e Negri e Machado (2008) compara a similaridade de grandes pedaços de imagens. A região de uma foto F_0 é comparada às diversas regiões da foto F_1 em busca da região mais similar. A similaridade é calculada pela correlação de Pearson das regiões, Pearson (1895). Além da correlação é possível usar soma dos quadrados das diferenças, correlação canônica, entre outros. Para essa classe de métodos de similaridade não importa o tamanho das matrizes comparadas, apenas que elas tenham as mesmas dimensões. Soluções baseadas nessas técnicas são algoritmos simples e de fácil implementação. As teorias estatísticas nas quais se fundamentam são clássicas e foram validadas diversas vezes para vários problemas. Karl Pearson, por exemplo, desenvolveu essa técnica de correlação a partir de uma ideia introduzida por Francis Galton em 1886. Na época Galton estudava a tendência à média na altura da população, Galton (1886), Pearson (1895)

O uso desses métodos deixa em aberto duas questões, a primeira é: como selecionar as áreas de interesse? Trabalhos passados, Negri e Machado (2008) e Laurent (2002), usaram heurística para selecionar áreas, por exemplo, regiões ao redor de pixels com um certo tom de cinza, ou valores maiores que a média da imagem. Nesses casos, assim como neste trabalho, as imagens usadas cobrem uma região oceânica, isso facilita a diferenciação entre nuvem e objetos ao fundo. Sirmacek e Unsalan (2009) abordam com detalhes como identificar nuvens em imagens de áreas urbanas. A segunda pergunta é: como buscar em F_1 uma região extraída em F_0 ? Machado (1998) e Laurent (2002) propõem uma solução de busca por proximidade. Isso significa iniciar a busca em áreas de coordenadas similares em F_1 , explorando áreas cada vez mais afastadas da

origem ao longo da busca. O tamanho da área ao redor da posição original da nuvem é definido experimentalmente.

Outra abordagem possível para gerar mapas de vetores de nuvens é dividir o problema de reconhecimento em duas partes: seleção de características e reconhecimento. Para isso, uma abstração é introduzida no problema: a característica, Nixon e Aguado (2012). Métodos, assim, buscam partes de uma imagem com características raras e de simples identificação. Após detectar características singulares, é necessário descrever cada uma delas, essa parte se chama extração. Elas podem ser extraídas separadamente, inclusive de forma paralela. Cada característica é descrita como um vetor de n atributos. A similaridade entre duas características é calculada como a distância em um espaço n -dimensional.

2.1 Extração de característica

Uma característica (também chamada *feature*) é uma representação de uma parte em um conjunto de dados, Kumar e Bhatia (2014). Uma certa representação funciona bem se permitir fácil classificação, e se for sensível o suficiente para diferenciar partes muito parecidas. O quão simples deve ser a classificação, ou o rigor dos padrões representados variam conforme o contexto do problema.

Um descritor, ou extrator, de características é responsável por selecionar e representar numericamente a característica encontrada numa imagem. Um descritor de propósito geral deve permitir o reconhecimento mesmo sob mudanças de escala, orientação, formato e iluminação, Bay et al (2008). Invariância em relação à escala significa que mesmo com tamanhos diferentes uma característica pode ser reconhecida. Orientação diz respeito às mudanças na posição do ponto de interesse na imagem. Manter a robustez mesmo sob mudanças de formato é uma das garantias mais complexas, assim como alterações de iluminação, porque mudanças alteram a quantidade de informação presente numa imagem, Nixon e Aguado (2012).

Um descritor de propósito específico é apresentado por Negri e Machado (2008). Um descritor matricial cuja função é apenas representar parte de uma nuvem nos cálculos de correlação. Lowe (1999) propõe SIFT, um descritor de característica capaz de representar elementos visuais de qualquer imagem. Fora o descritor de Negri e Machado (2008), os três algoritmos de extração testados neste trabalho são de propósito geral. A literatura com os usos desses últimos abrange muitas aplicações. Sirmacek e Unsalan (2009) usaram SIFT para detecção de áreas urbanas através de imagens de satélite. Geng et al. (2015) compara o uso de descritores de propósito geral no reconhecimento de conteúdo pornográfico na Internet. Identificação de nuvens expõe esse tipo de algoritmo a um contexto onde os objetos de interesse têm variância no formato. O uso de extratores de propósito geral pode beneficiar na geração de vetores de movimento atmosférico. Assim como servir como teste para esses descritores.

Descritores de propósito geral devem lidar com características de tamanho variável mantendo o tempo de processamento invariável. Soluções clássicas são sensíveis às mudanças no tamanho da matriz descritora, pois essas mudanças afetam tempo de processamento e a capacidade de reconhecimento. Esse problema se torna mais perceptível conforme a qualidade e o tamanho das imagens de satélite aumentam. O algoritmo de Negri e Machado foi usado como referência nos experimentos deste trabalho.

Os três algoritmos de extração de características usados foram:

- SIFT (Scale Invariant Feature Transform) é um algoritmo de visão computacional publicado por Lowe (1999) e patenteado nos EUA pela University of British Columbia. Esse descritor é usado para um grande número de propósitos em visão computacional. O descritor SIFT é invariante em relação a translações, rotações e transformações de escala, sendo robusto para mudanças de perspectiva e iluminação. Na sua formulação original, SIFT é formado por

um método de detecção de pontos de interesse a partir de uma imagem em tom de cinza, na qual estatísticas de gradientes locais de direção são calculados para sumarizar diferentes estruturas na imagem, segundo Lindeberg (1994). Esses gradientes são usados para representar a vizinhança dos pontos de interesse.

- SURF (Speeded-Up Robust Features) é um detector e descritor de características invariante em relação à escala e rotação, proposto por Bay et al. (2008). Sua principal característica é a eficiência, pois computa pontos de interesse e vetores de características cerca de dez vezes mais rápido que SIFT e com precisão próxima. Tanto o detector, como o descritor usam a técnica de imagem integral, em que cada pixel de uma imagem recebe um valor igual à soma dos pixels à sua esquerda e acima, incluindo o próprio, em tempo linear.
- ORB (Oriented FAST and Rotated BRIEF) é um algoritmo proposto por Rublee et al. (2011) como candidato para substituição do SIFT em ambientes de baixo poder de processamento ou que necessitem de processamento em tempo real. ORB é invariante à orientação e robusto ao lidar com ruídos. O algoritmo usa dois outros algoritmos (FAST e BRIEF) introduzindo melhorias. FAST é um algoritmo de detecção de pontos de interesse num imagem, e BRIEF é um descritor de características. Um dos principais problemas segundo o autor do algoritmo é a falta de robustez diante de variações de escala. Além da rapidez, esse é o único algoritmo, dos três testados neste trabalho, sem patente e cujo uso comercial é gratuito.

3. Experimentos

Os experimentos realizados tentam avaliar o desempenho dos algoritmos extratores em diferentes situações em torno da geração de

vetores de movimento atmosférico. Um quarto algoritmo de controle chamado NEGRI, baseado no trabalho de Negri e Machado (2008), também foi usado. Foram realizados dois experimentos, descritos nas subseções a seguir.

As implementações dos algoritmos ORB, SURF e SIFT fazem parte do pacote beta da biblioteca OpenCV (*Open Computer Vision*). O algoritmo de controle baseado no trabalho de Negri e Machado (2008) foi implementado pelos autores na linguagem de programação *Python*. Os experimentos foram realizados num computador Intel Core i5 2450M CPU 2.50GHz x 4, com 5.8GiB de memória RAM, usando Debian GNU/Linux 8 (Jessie) 64-bit.

3.1 Experimento I

Este experimento testa como os algoritmos lidam com a detecção de características de diferentes imagens e variadas condições meteorológicas ao longo do tempo. Foram usadas 400 imagens do canal infra-vermelho. Os algoritmos (3 extratores: ORB, SURF, SIFT e 1 de controle: NEGRI) processaram o mesmo conjunto de imagens. Os resultados são apresentados na forma de gráfico de linha. O eixo horizontal apresenta a data de cada imagem da série. O eixo vertical representa a quantidade de pontos de interesse cada algoritmo encontrou por imagem.

A partir do gráfico gerado será possível avaliar quantos pontos-chaves cada algoritmo foi capaz de extrair de cada imagem.

3.2 Experimento II

A etapa seguinte consiste em avaliar os mapas gerados pelos algoritmos extratores. Essa avaliação testa a homogeneidade dos campos de vetores, o tempo de processamento necessário, e por último a resiliência dos algoritmos aos diferentes tipos de imagens de satélite.

Vetores próximos devem ter características similares como comprimento, direção e sentido. Isso acontece, pois, esses vetores retratam o movimento de objetos próximos, submetidos à condições atmosféricas similares, como pressão, altitude e temperatura. A

homogeneidade dos vetores deve ser avaliada como critério de qualidade do mapa.

É normal que nuvens de diferentes altitudes se sobreponham nas imagens. Isso pode gerar falsos negativos, onde um vetor não se parece com seus vizinhos, sendo removidos do mapa por algum filtro. O objetivo desse trabalho não é tratar da segmentação de nuvens por altitude, Machado et al. tem um vasto trabalho sobre esse tipo de segmentação.

O tempo de processamento envolve o tempo de extração e reconhecimento das características. É importante que os algoritmos possam processar imagens de baixa e alta qualidade com pouca variação no tempo de processamento. A qualidade das imagens de satélite vem melhorando com o passar dos anos. Esse aumento na qualidade pode tornar impraticável ou extremamente custoso algumas aplicações se os algoritmos têm baixa eficiência.

A resiliência de um algoritmo de extração e reconhecimento diz se esse algoritmo é capaz de gerar bons resultados independentemente dos objetos presentes na imagem. Isso é um teste para os descritores usados por cada algoritmo, e para isso foi usado um conjunto de fotos com variadas condições atmosféricas, momentos de baixa aglomeração de nuvens seguidos por alta aglomeração de nuvens durante um período de 11 dias, totalizando 400 imagens.

3.3 Banco de imagens

As imagens usadas fazem parte do acervo do projeto NOAA (*National Oceanic and Atmospheric Administration* na sigla em inglês). Foram usadas mais de 9 mil imagens das mais diversas regiões do continente americano, muitas

delas com áreas oceânicas. Nesse banco de imagens além de diferentes regiões existem diferentes tipos de imagens. Os tipos são: canal visível, canal infra-vermelho e vapor de água.

4. Resultados e discussão

O Gráfico 1 mostra o tempo (em escala logarítmica) de detecção de pontos de interesse em um imagem. A série usada tem 400 imagens, entre os dias 22 de janeiro e 3 de fevereiro de 2017, como mostra o eixo X com as datas. O algoritmo de Negri e Machado (2008) (apresentado como NEGRI na legenda dos gráficos) levou entre 1s e 2.9s por imagem. Os algoritmos extratores levaram entre 10^{-1} s e 10^{-2} s por imagem, entre 10 e 100 vezes mais rápidos que NEGRI.

O Gráfico 2 mostra a quantidade (em escala logarítmica) de pontos de interesse por imagem ao longo da mesma série usada na geração do Gráfico 1. É possível perceber a diferença de escala entre quantos pontos de interesse os algoritmos recolhem. Negri, por um usar o valor individual de cada pixel, apresenta grandes variações na comparação com os algoritmos extratores. SURF e SIFT apresentam resultados semelhantes no Gráfico 1 e 2. SIFT, no entanto, foi o mais lento do grupo dos extratores. ORB foi o mais rápido no tempo de detecção e apresentou as menores variações na quantidade de pontos de interesse. Além disso, entre os dias 29 e 30 de janeiro, ORB detectou em um período de mínima da série a maior quantidade de pontos de interesse dentre os algoritmos extratores.

A escala logarítmica, de base 10, foi adotada por conta da grande variação entre os resultados dos algoritmos extatore e o algoritmo de controle.

Gráfico 1. Tempo de detecção de características (segundos em escala log10) ao longo de série com 400 imagens de satélite.

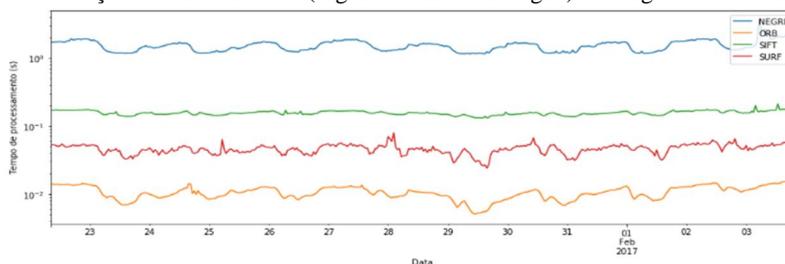
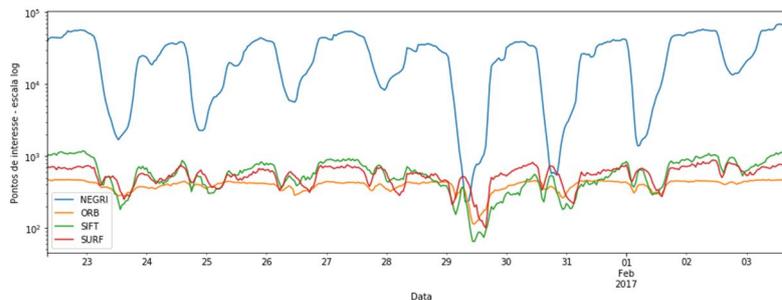


Gráfico 2. Quantidade (em escala log10) de pontos de interesse detectados ao longo de série com 400 imagens de satélite.



As fotos na Imagem 1 são do oceano Pacífico, parte oeste da América central, e fazem parte do início da série usada nos Gráficos 1 e 2. O Gráfico 3 apresenta os mapas feitos pelos diferentes algoritmos (ORB, SURF, SIFT e NEGRI) a partir dessas fotos. Os vetores desses mapas não foram filtrados, apresentando o resultado bruto dos algoritmos de extração e reconhecimento. O uso de uma sequência com mais fotos poderia gerar alta sobreposição de vetores, dificultando a visualização dos vetores.

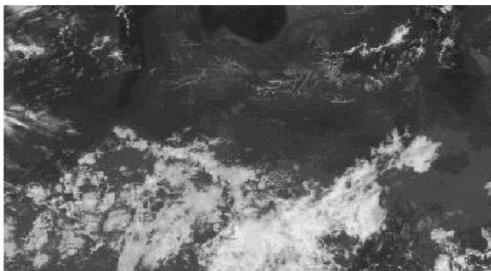
A maneira como os vetores estão dispostos em cada mapa mostra os limites de detecção de cada algoritmo. As grandes nuvens, com coloração cinza mais clara, na parte inferior

das fotos (Imagem 1) são retratadas no mapa de vetores com uma área vazia, ou de menor presença de vetores. SURF foi o algoritmo capaz de melhor representar a diversidade de nuvens presentes. Seus vetores estão uniformemente distribuídos.

Os quatro mapas compartilham um padrão no tamanho dos vetores na distribuição dos tamanhos dos vetores. O tamanho dos vetores, em espaço euclidiano, é mostrada nos histogramas do Gráfico 4. SURF, SIFT e ORB apresentam um padrão comum na distribuição dos tamanhos. NEGRI, no entanto, apresenta menos diversidade no tamanho dos vetores.

Imagem 1. Fotos do Projeto NOAA sobre o oceano Pacífico no canal infra-vermelho, ir2, com intervalo de 30 minutos entre elas.

22-01-2017 08:15 - ir2



22-01-2017 08:45 - ir2



Gráfico 3. Vetores de movimento atmosférico gerados a partir das fotos da Imagem 1.

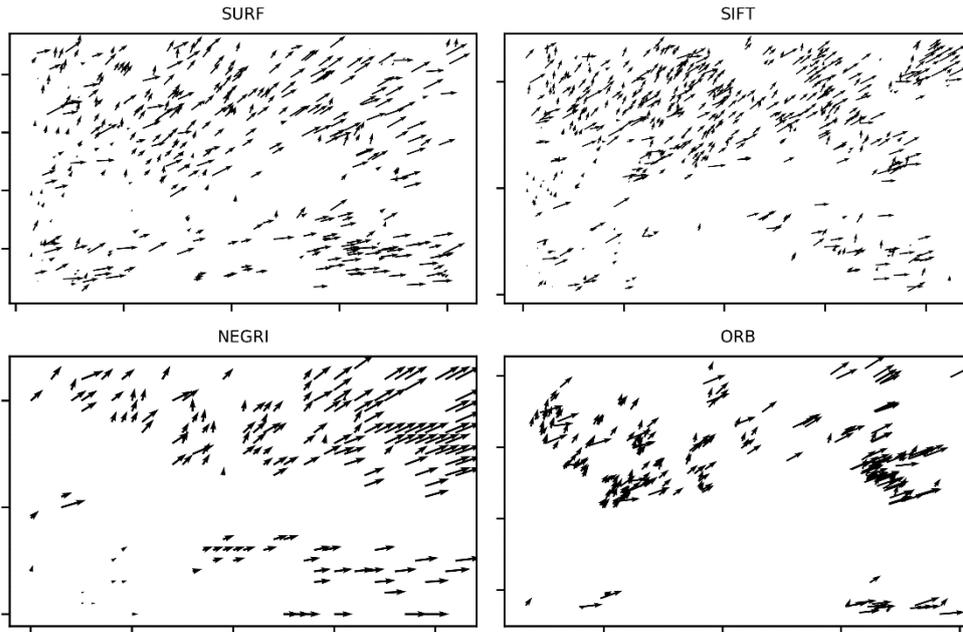
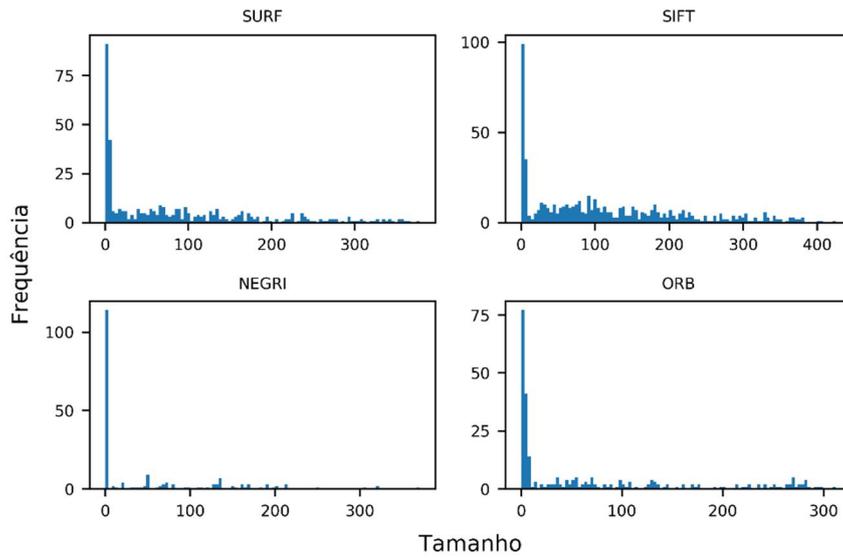


Gráfico 4. Histogramas com os tamanhos dos vetores gerados por cada algoritmo. Tamanho calculado no espaço euclidiano.



5. Conclusão e trabalhos futuros

É possível concluir que algoritmos extratores de características são capazes de apresentar vantagens sobre o método clássico na geração de mapas de campos de ventos. As vantagens são: o menor tempo de processamento, identificação de movimento em diferentes tipos de nuvens presentes numa mesma imagem de satélite. O algoritmo NEGRI mesmo com o maior número de pontos de interesse detectados por imagem não foi capaz de gerar vetores tão bem distribuídos como SURF.

Trabalhos futuros podem combinar diferentes algoritmos de extração e reconhecimento para a melhora dos mapas gerados. Além disso, um teste adicional pode avaliar a precisão das previsões meteorológicas feitas a partir de cada um dos mapas, e dessa forma verificar qual dos vetores melhor corresponde à dinâmica atmosférica. Os algoritmos extratores mostraram bons resultados em um contexto onde os objetos de interesse sofrem mudanças no formato. Existem outros problemas similares que podem se beneficiar como manchas de óleo em áreas oceânicas.

6. Referências

- BAY, H. et al. Speeded-up robust features (surf). *Computer Vision and Image Understanding*, v. 110, n. 3, p. 346 ó 359, 2008. ISSN 1077-3142. Similarity Matching in Computer Vision and Multimedia. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1077314207001555>>.
- GALTON, F. Regression towards mediocrity in hereditary stature. *The Journal of the Anthropological Institute of Great Britain and Ireland*, [Royal Anthropological Institute of Great Britain and Ireland, Wiley], v. 15, p. 246ó263, 1886. ISSN 09595295. Disponível em: <<http://www.jstor.org/stable/2841583>>.
- GENG, Z. et al. A comparative study of local feature extraction algorithms for web pornographic image recognition. In: 2015 IEEE International Conference on Progress in Informatics and Computing (PIC). [S.l.: s.n.], 2015. p. 87ó92.
- NOAA Wind Products - 2017. Disponível em: <<http://www.ospo.noaa.gov/Products/atmosphere/wind.html>>.
- KUMAR, G.; BHATIA, P. K. A detailed review of feature extraction in image processing systems. In: 2014 Fourth International Conference on Advanced Computing Communication Technologies. [S.l.: s.n.], 2014. p. 5ó12. ISSN 2327-0632.
- LAURENT, H. et Al. Extração do vento utilizando imagens de satélite no cptec: Nova versão e avaliação com dados do wetamc/lba e dados operacionais da dsa/cptec. *International Winds Workshop*, 2002.
- LAURENT H. E; MACHADO, L. Extração do vento utilizando imagens de satélites meteorológicos. *Congresso Brasileiro de Meteorologia*, 1994.
- LEESE, J. A.; NOVAK, C. S.; CLARK, B. B. An automated technique for obtaining cloud motion from geosynchronous satellite data using cross correlation. *Journal of Applied Meteorology*, v. 10, n. 1, p. 118ó132, 1971. Disponível em: <[http://dx.doi.org/10.1175/1520-0450\(1971\)010<0118:AATFOC>2.0.CO;2](http://dx.doi.org/10.1175/1520-0450(1971)010<0118:AATFOC>2.0.CO;2)>.
- LINDEBERG, T. Scale-space theory: a basic tool for analyzing structures at different scales. *Journal of Applied Statistics*, v. 21, n. 1-2, p. 225ó270, 1994. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/757582976>>.
- LOWE, D. G. Object recognition from local scale-invariant features. In: *Computer Vision*, 1999. *The Proceedings of the Seventh IEEE International Conference on*. [S.l.: s.n.], 1999. v. 2, p. 1150ó1157 vol.2.

MACHADO, L. Extração do vento e estimativa de sistemas convectivos utilizando imagens do satélite goes. Congresso Brasileiro de Meteorologia, 1998.

MARSHALL, J. L. Cloud and water vapour motion vectors in tropical cyclone track forecasting - a review. *Meteorology and Atmospheric Physics*, p. 141-151, 1998.

NEGRI, R. G.; MACHADO, L. A. T. Estimativa do vento para os baixos níveis utilizando imagens dos canais visível e infravermelho próximo 3.9 μ m. *Revista Brasileira de Meteorologia*, scielo, v. 23, p. 206 - 218, 06 2008. ISSN 0102-7786. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0102-77862008000200008&nrm=iso

NIXON M.; AGUADO, A. S. *Feature Extraction and Image Processing for Computer Vision*. [S.l.]: Academic Press, 2012.

PEARSON, K. Note on regression and inheritance in the case of two parents. *Proceedings of the Royal Society of London, The Royal Society*, v. 58, p. 240-242, 1895. ISSN 03701662. Disponível em: <http://www.jstor.org/stable/115794>.

ROUSSEEUW, P. J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. In: *Computational and Applied Mathematics*. [s.n.], 1987. p. 53-65. Disponível em: <http://pages.gseis.ucla.edu/faculty/bates/articles/information.html>.

RUBLEE, E. et al. Orb: An efficient alternative to sift or surf. In: *2011 International Conference on Computer Vision*. [S.l.: s.n.], 2011. p. 2564-2571. ISSN 1550-5499.

SIRMACEK, B.; UNSALAN, C. Urban-area and building detection using sift keypoints and graph theory. *IEEE Transactions on Geoscience and Remote Sensing*, v. 47, n. 4, p.1156-1167, April 2009. ISSN 0196-2892.