

Algoritmo de geração de imagens de previsão De Campos de nebulosidade a partir de imagens de satélite

Eduardo dos Santos Pereira (INPE) - eduardo.santos@inpe.br

André Rodrigues Goncalves (INPE) - andre.goncalves@inpe.br

Rodrigo Santos Costa (INPE) - rodrigo.costa@inpe.br

Enio Bueno Pereira (INPE) - enio.pereira@yahoo.com.br

Resumo:

Ao se realizar a previsão de produção de energia fotovoltaica, uma estratégia consiste na utilização de processos de extração do campo de velocidade da nebulosidade a partir das imagens de satélite. Neste trabalho é proposta uma metodologia que não somente estima o campo de velocidades, mas que também é capaz de construir imagens sintéticas de previsão, equivalentes as imagens de satélite futuras. Para tal tarefa, foi desenvolvido um algoritmo de processamento em linha, também conhecido como pipeline. Imagens de satélite sequências são segmentadas, utilizando um controlador Fuzzy, a fim de se extrair o campo de nebulosidade e a partir disto, utilizou-se o algoritmo block matching para determinar o campo de velocidade. Utilizando um método de análise multirresolução, para definir o grau de similaridade da posição de nuvens dos dados sintéticos, foram realizadas comparações com intervalo de previsão de trinta minutos, uma hora, duas horas e quatro horas, em que foi observado que os picos probabilidade de similaridade ocorreram em 70%, para previsões de quatro horas, aumentando em intervalos mais curtos, chegando a 90% de similaridade para trinta minutos, indicando robustez do modelo para previsões de curto prazo.

Palavras-chave: *Imagens de satélite, Previsão de Curto Prazo, Lógica Fuzzy.*

Área temática: *Radiação Solar*

Subárea temática: *Recursos Solares e Meteorologia da Radiação Solar*

ALGORITMO DE GERAÇÃO DE IMAGENS DE PREVISÃO DE CAMPOS DE NEBULOSIDADE A PARTIR DE IMAGENS DE SATÉLITE

Eduardo S. Pereira – eduardo.santos@inpe.br

André Rodrigues Gonçalves – andre.goncalves@inpe.br

Rodrigo Santos Costa – rodrigo.costa@inpe.br

Enio Bueno Pereira – enio.pereira@inpe.br

Instituto Nacional de Pesquisas Espaciais, Centro de Ciências dos Sistemas Terrestre.

1.2. Outros dados meteorológicos aplicados a energias renováveis

Resumo: Ao se realizar a previsão de produção de energia fotovoltaica, uma estratégia consiste na utilização de processos de extração do campo de velocidade da nebulosidade a partir das imagens de satélite. Neste trabalho é proposta uma metodologia que não somente estima o campo de velocidades, mas que também é capaz de construir imagens sintéticas de previsão, equivalentes as imagens de satélite futuras. Para tal tarefa, foi desenvolvido um algoritmo de processamento em linha, também conhecido como pipeline. Imagens de satélite sequências são segmentadas, utilizando um controlador Fuzzy, a fim de se extrair o campo de nebulosidade e a partir disto, utilizou-se o algoritmo block matching para determinar o campo de velocidade. Utilizando um método de análise multirresolução, para definir o grau de similaridade da posição de nuvens dos dados sintéticos, foram realizadas comparações com intervalo de previsão de trinta minutos, uma hora, duas horas e quatro horas, em que foi observado que os picos probabilidade de similaridade ocorreram em 70%, para previsões de quatro horas, aumentando em intervalos mais curtos, chegando a 90% de similaridade para trinta minutos, indicando robustez do modelo para previsões de curto prazo.

Palavras-chave: Imagens de satélite, Previsão de Curto Prazo, Lógica Fuzzy.

1. INTRODUÇÃO

Entender o campo de nebulosidade futura é de extrema relevância para a previsão de produção de energia fotovoltaica (Pelland et al. 2013). Através do uso de sequências de imagens de satélite é possível realizar previsões do posicionamento de nuvens numa escala de tempo de até 6 horas (Lorenz et al. 2004, 2007; Heinemann et al. 2006, 2006b, Perez et al. 2010). Neste trabalho, o objetivo principal é o de apresentar o algoritmo de geração de imagens sintéticas de satélite para a previsão de curto prazo do campo de nebulosidade. A vantagem do método apresentado aqui é que, modelos diagnósticos, que usam dados de satélite para estimar a radiação solar recebida em solo, poderão utilizar os dados gerados pelo nosso modelo para realizar previsões em escala de tempo variável.

Em sensoriamento remoto, lógica Fuzzy foi utilizada para classificar elementos como gelo, nuvem e oceano (Simpson e Keller, 1995). Henzmann (1993) utilizou Fuzzy para classificar nuvens como sendo baixas, médias, de convectividade profunda e cirros. Já Goswami et al. (2012, 2014) utilizaram um modelo neuro-fuzzy para extrair nuvens a partir de imagens de satélite, na banda do infravermelho. Fuzzy também tem sido aplicada na previsão de produção de energia renováveis (Suganthi et al., 2015 e Morsy et al., 2002).

No presente trabalho pretende-se ir além do que foi coletado a partir da literatura, criando imagens sintéticas de satélite e não somente estimando o campo de velocidades de nuvens. O produto gerado nesse trabalho será acoplado a um modelo de transferência radiativa.

O artigo está estruturado da seguinte forma: Na seção 2 é apresentada a metodologia, sendo que o processo de extração do campo de nuvens, usando lógica Fuzzy é descrito na subseção 2.1. A subseção 2.2 trata do mecanismo de extração do campo de velocidades. A metodologia para avaliar a qualidade da previsão, definida a partir do grau de similaridade entre imagens sintéticas e observacionais, é apresentada na seção 2.3. Na seção 3 são apresentados os resultados. Já as considerações finais são detalhadas na seção 5. Para esse trabalho foram utilizadas imagens do satélite GOES-13 na banda do espectro visível da radiação.

2. METODOLOGIA

Para esse trabalho foram utilizados dados do satélite GOES-13 para o mês de janeiro de 2016, com resolução temporal de 30 minutos para horários entre 12 e 19 UTC. Os dados abrangem a América do Sul, entre as latitudes -45° e 13° e longitudes -8.3° e -29.5°. O mês de janeiro foi escolhido por ser um período tipicamente chuvoso para maior parte da região avaliada e, portanto, com maior probabilidade de serem verificados sistemas meteorológicos relevantes.

De forma geral, o processo de previsão adotado segue um processamento em linha (pipeline), em que, primeiramente, imagens são segmentadas, separando os campos de nuvens utilizando um classificador Fuzzy. Em seguida, as imagens resultantes são analisadas em sequência temporal, com a finalidade de extração do campo de velocidades das nuvens. O movimento das nuvens é estimado a partir de sequência de imagens, para isso, utilizou-se o algoritmo chamado block matching (BM), que consiste em comparar pequenos blocos de uma imagem, no instante de tempo t_{i-1} dentro de janelas, com blocos de outra imagem no instante de tempo seguinte, t_i (Cuevas et al. 2013, Peng et al. 2016;). O BM foi amplamente utilizado na estimativa de campos de velocidade a partir de imagens de satélite (Brad, Letia, 2002; André 2019; Perez et al., 2010, Lorenz et al. 2007, 2004, Cros et al. 2014, 2014b, Heinemann et al. 2006, 2006b). Uma visão geral sobre o uso de tal algoritmo para estimar vetores de movimento é apresentada por Khawase et al. (2017). Cada nuvem é tratada de forma individual, sendo realizado o deslocamento das mesmas, de acordo com seu vetor de movimento próprio. Finalmente, as camadas individuais de nuvens são combinadas, formando uma imagem sintética de previsão.

2.1 Segmentação Fuzzy de imagens de satélite

A lógica difusa, também conhecida como lógica Fuzzy ou nebulosa, é considerada como uma das áreas de inteligência artificial e computacional. Sua principal motivação está em estender os conceitos da lógica binária, levando em conta uma melhor compreensão da percepção humana com relação a realidade no qual estamos imersos. A sua formalização teórica é atribuída ao trabalho de Zader (1965), em que o autor estabelece os conceitos de conjunto Fuzzy e de função de pertinência.

Na lógica binária, ou booleana, os elementos fundamentais são os conceitos absolutos e excludentes de verdadeiro ou falso. Nesse caso, um ente irá pertencer de forma integral a uma dada classe. Já na lógica Fuzzy, um ente pode ser classificado como pertencendo parcialmente a uma ou mais classes. Por exemplo, o elemento x poderá pertencer em sessenta por cento a classe F e quarenta por cento a classe J . Estas porcentagens não representam probabilidades de x estar contido em F ou J , mas sim que x pertence, dentro do chamado grau de pertinência, à ambos F e J de forma simultânea. Neste trabalho estamos interessados em estimar o campo de velocidades das nuvens, assim, serão utilizadas três classes: Fundo (“*Background*” - B); Fumaça e outros aerossóis (“*Gray*” - G); e Nuvens (“*Cloud*” - C).

Uma vez definido o número de classes a ser utilizado, o próximo passo é o de realizar o pré-processamento dos dados. Primeiramente, as imagens de satélite são convertidas em escala de cinza. Para isso, aplicamos uma conversão linear de 8 bits, que leva em conta os valores máximos e mínimos de dados válidos para uma imagem específica. Para garantir que as nuvens fiquem em tons de branco e o fundo em tons de cinza, utilizou-se uma inversão lógica de negação. Para ressaltar as diferenças entre nuvens e fundo, realizou-se um procedimento de equalização via histograma, o qual consiste em ajustar o contraste da imagem a partir da modificação da intensidade da distribuição de seu histograma.

O passo seguinte é o de criar as funções de pertinência para cada classe. Nesse caso, foi observado que não existe um limiar bem definido entre uma classe e outra, em função dos diferentes brilhos observados entre solo e cobertura de nuvem. A partir da lógica Fuzzy podemos tratar melhor essas regiões de incerteza, conseguindo separar de forma clara cada componente.

Na Fig. 1 são apresentadas as funções de pertinência para as três classes utilizadas neste trabalho. O eixo y , dado por μ , representa o grau de pertinência da classe. A intensidade do pixel representa valores em escala de cinza, que variam de 0 (preto) a duzentos e cinquenta e cinco (branco), representados no eixo x . Verifica-se que o limite entre as classes não é algo bem definido, logo, um limiar fixo e único não seria capaz de representar, de forma adequada, os componentes da imagem. Em cenário de incerteza como esse é que se encontra o verdadeiro potencial de uso de sistema de classificação Fuzzy.

Ao final, um dado pixel poderá ter um grau de pertinência à várias classes, contudo, no resultado final, um pixel será considerado como pertencente a classe em que o mesmo tenha o maior grau de pertinência. Logo, se este estiver a 30% na classe G e 70% na classe C , então será assumido que ele pertence ao conjunto definido pela classe C . Esse retorno para a representação em um único conjunto é chamado de defuzzificação. O controlador Fuzzy deste trabalho foi construído utilizando a biblioteca, na linguagem Python, chamada *skfuzzy*, disponível em <https://pythonhosted.org/scikit-fuzzy/>.

Na Fig. 2, a imagem do lado A foi obtida a partir do dado observacional, para o horário de 12 horas do dia 1 de janeiro de 2017, latitude central de -15.96 e longitude central de -49.81 com dimensões de 1000km x 1000km para a banda do visível do GOES 13. O lado B representa apenas o campo de nuvens, obtido usando o controlador Fuzzy. Podemos observar que os resultados são compatíveis com os obtidos por Goswami et al. (2012), que trabalharam com imagens de satélite na banda do infravermelho.

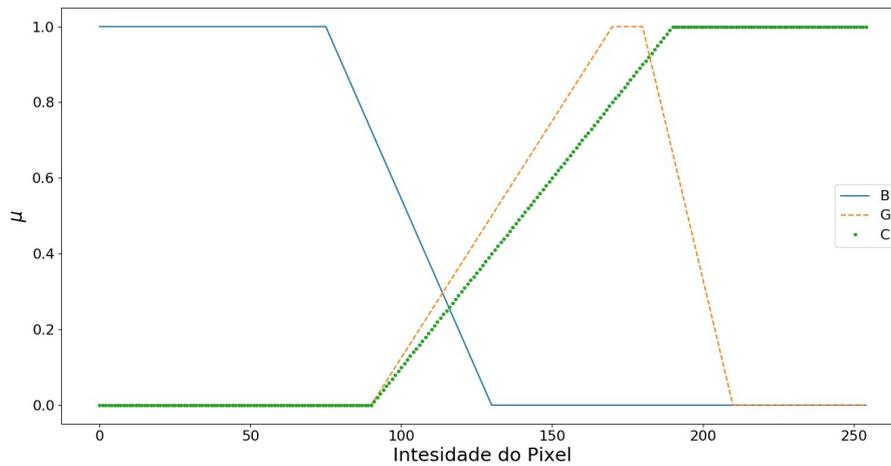


Figura 1 - Função de pertinência da intensidade do píxel para as classes B – Background, C – Cloud e G – Gray.

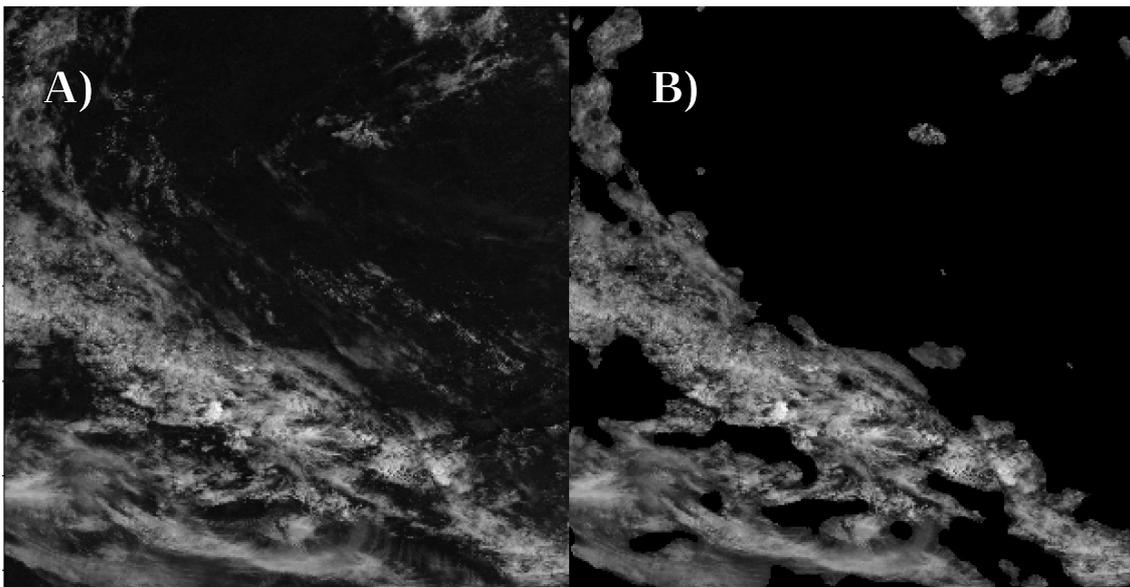


Figura 2 - Decomposição Fuzzy. Lado A representa imagem original, lado B, extração de nuvens, usando controlador Fuzzy. Imagem centrada na latitude de -15.96 e longitude de -49.81, com dimensão de 1000 km x 1000 km do dia primeiro de janeiro de 2017 e horário de 12:00 horas.

2.2 Extração do campo de velocidade de nuvens.

O próximo passo será o de usar imagens prévias para obtenção do campo de velocidades. Para realizar tal tarefa, foi considerada uma variação do algoritmo conhecido como *block matching* (BM). Tal algoritmo tem como base a utilização de duas imagens em tempos diferentes, uma no tempo t_{i-1} e outra em t_i , com i variando de 1 a n . De acordo com Cuevas (2013) e Perez et al. (2010), uma imagem pode ser dividida em blocos. Para cada bloco, no instante de tempo t_i , procura-se o bloco com maior grau de similaridade na imagem no instante de tempo anterior, t_{i-1} . O grau de similaridade é determinado pelo processo de minimização da soma absoluta das diferenças, ponto a ponto, entre os blocos nos intervalos de tempo distintos. Na Fig. 3 está representada uma exemplificação do funcionamento do algoritmo BM.

No presente trabalho, a similaridade entre duas regiões é determinada utilizando a diferença absoluta entre um recorte, provenientes da imagem em t_{i-1} , dentro de um recorte maior, na imagem no tempo t_i , o tamanho desse recorte é duas vezes o tamanho do recorte da imagem anterior. Essa restrição impõe um limite para a busca, indicando que esperamos transições suaves entre uma imagem e outra. Dessa forma, o intervalo de tempo entre uma imagem e outra não deverá ser grande. Por exemplo, se estamos analisando uma imagem de trânsito de automóveis, o intervalo de tempo $dt = t_i - t_{i-1}$ deverá ser de frações de segundos. Para o caso de imagens de satélite, contendo movimento de nuvens em mesoescala, o intervalo de tempo entre imagens poderá ser de 15 a 60 minutos.

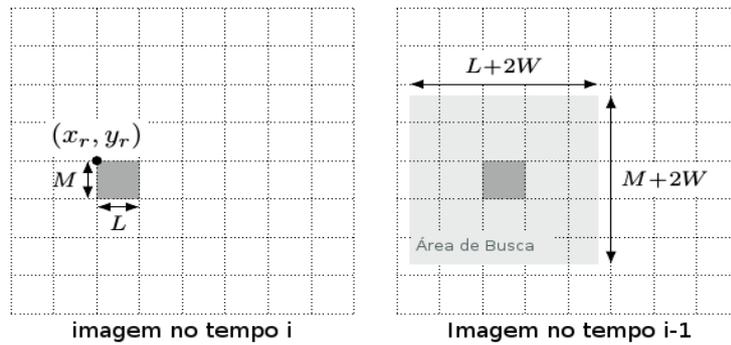


Figura 3 - Busca de similaridades entre blocos de duas imagens.

Em t_i é definido um bloco a ser analisado, em t_{i-1} a janela de busca é definida a partir do tamanho da aresta do bloco em t_i . FONTE: Adaptado de Zaher et al. 2017.

O campo de velocidades é construído, usando como ponto de partida para cada vetor o centro do recorte na imagem em t_{i-1} . Já a ponta do vetor será dada pelo centro do recorte que minimiza as diferenças, no instante de tempo t_i . A partir do campo de velocidades, os pontos contendo vetores não nulos são convertidos em nós de um grafo. Se um dado ponto no campo de velocidades for imediatamente próximo a um vizinho, cria-se um vértice entre os dois nós. Dessa forma, nuvens serão representadas por grafos conexos determinados a partir do campo de velocidades. Com isso, a velocidade típica da nuvem será dada pela velocidade mediana do grafo conectado. Em uma imagem teremos vários grafos conectados, e cada um irá representar uma nuvem.

Na Fig. 4 é apresentado o campo de velocidades para uma região centrada na latitude de -15.96 e longitude de -49.81, a partir do centro, a imagem se estende por uma distância máxima de 500 km, a partir do centro (1000kmx1000km). O campo foi extraído a partir de duas imagens do dia primeiro de janeiro de 2016, sendo uma em $t_i = 12:30$ horas e a outra em $t_{i-1} = 12:00$ horas. As nuvens estão representadas em cinza e em amarelo os vetores do campo de velocidades.

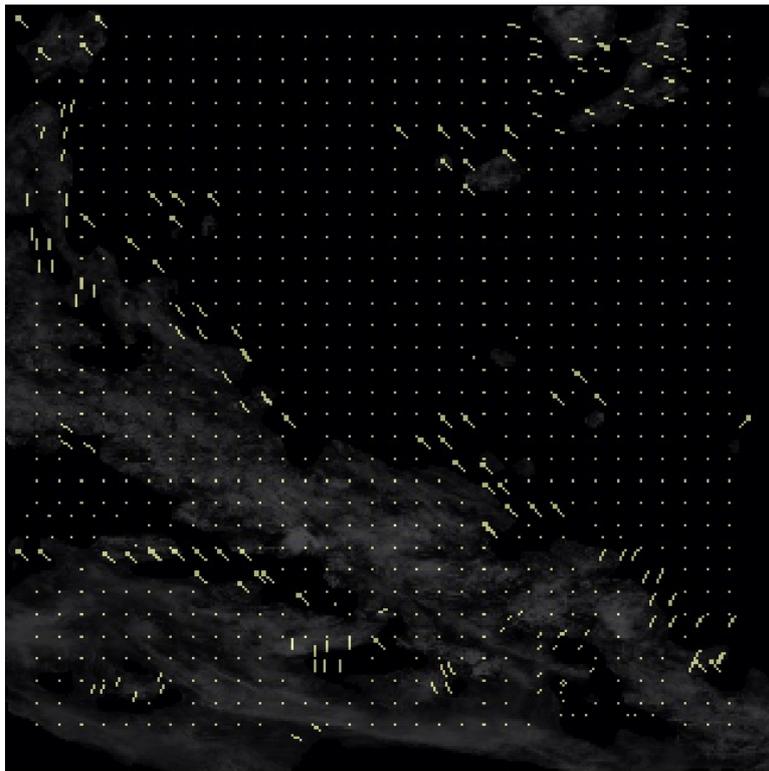


Figura 4 - Campo vetorial centrado na latitude de -15.96 e longitude de -49.81, dimensão de 1000 km x 1000 km, produzido a partir de duas imagens do dia primeiro de janeiro de 2016, em $t_i = 12:30$ horas e $t_{i-1} = 12:00$ horas. As nuvens estão representadas em cinza e em amarelo os vetores para o campo de velocidades.

Uma vez determinada a velocidade de cada nuvem, a imagem é subdividida em camadas, em que cada camada representa uma nuvem. A posição futura de cada camada é estimada a partir da velocidade, em pixels por segundo, multiplicado pelo tempo, em segundos, que se deseja realizar a previsão. Cada camada é movimentada de forma individual para a posição correspondente e em seguida, todas as camadas são combinadas, formando uma imagem única. Na imagem resultante é aplicado um filtro espacial de médias moveis, com o intuito de suavizar as bordas e sobreposições de nuvens.

Como a imagem sintética contém até este momento apenas nuvens, o próximo passo é o de adicionar o fundo correspondente ao horário de previsão. Este fundo é determinado para cada horário e é construído a partir da média climatológica dos mínimos obtidos, a partir de imagens de satélite, de um dado mês. Com isso, é gerado uma imagem sintética.

Na Fig. 5 é apresentada a imagem de real, lado A, e a imagem de previsão, lado B, para o intervalo de 30 minutos. As imagens são formadas apenas pelas nuvens, sem as classes de fundo (B) e cinza (G), abrangendo a América do Sul, para o dia primeiro de janeiro de 2016 as 13 horas.

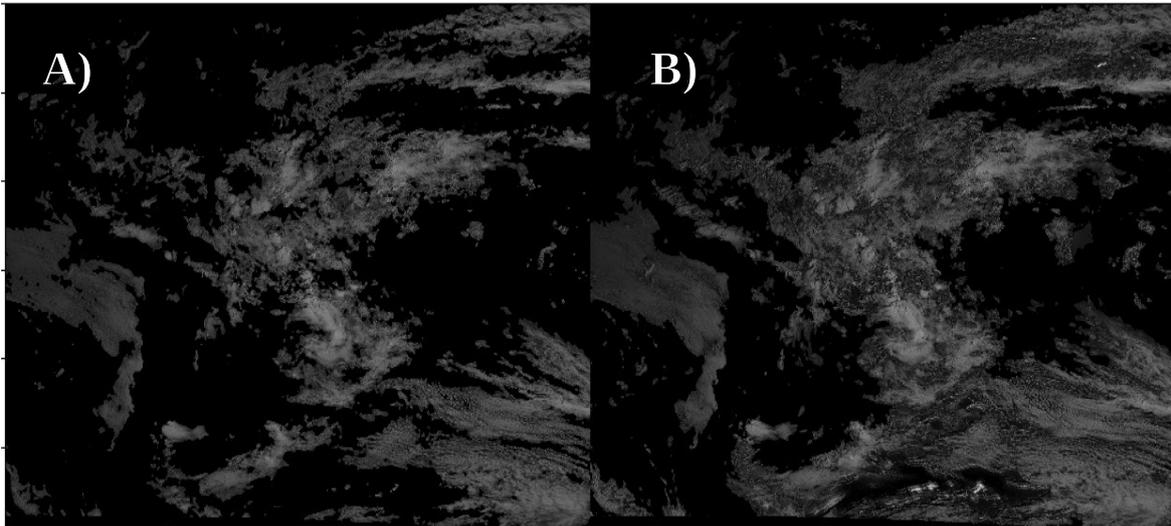


Figura 5 - Dados de observação (Lado A) e imagem sintética (Lado B) para América do Sul, das 13 horas do dia primeiro de janeiro de 2016.

2.4 Determinação de grau de similaridade entre imagens e a qualidade de previsão

Mesmo que o movimento de nuvens possa ser previsível, dentro de uma dada escala de tempo, o processo de evolução desse tipo de sistema possui caráter estocástico. Dessa forma, a mera comparação pixel a pixel entre duas imagens não será suficiente para determinar a qualidade da previsão. Para esse tipo de problema, Costanza (1989) afirma que para avaliar, qualitativamente, o ajuste de um modelo com relação a realidade é necessário confrontar os dados sintéticos contra os dados observado em escalas variáveis, sejam elas temporais ou espaciais. Com isso, podemos ter uma melhor visão sobre a confiabilidade do modelo de forma mais ampla.

Ao se tratar de uma imagem, podemos agrupar classes em termos de intervalos de cor. Por exemplo, numa imagem em escala de cinza, pode-se considerar que pixels com valores entre 0 e 10 pertençam a mesma classe. Logo, ao invés de avaliar a similaridade entre duas imagens, ponto a ponto, podemos criar janelas e verificar a ocorrência de classes do mesmo tipo, dentro de cada janela.

Ao avaliar imagens usando esse esquema de escala diferentes, podemos criar um sistema de comparação mais geral. No caso de imagens de satélite, poderemos ver a qualidade do ajuste, ou grau de similaridade entre imagens, levando em conta não somente variações locais como também em mesoescala.

Costanza (1989) propõe a seguinte equação para verificar o ajuste de dados, dentro uma janela de largura w :

$$F_w = \frac{\sum_{s=1}^{t_w} \left[1 - \frac{\sum_{i=1}^p |a_{1i} - a_{2i}|}{2w^2} \right]}{t_w} \quad (1)$$

Na equação anterior, t_w é o total de classes contidas na janela, w é a largura da janela, a_{1i} é a quantidade de elementos (pixels) da classe i na primeira imagem e a_{2i} é a quantidade de elementos da mesma classe i na segunda

imagem. O ajuste global, que irá definir quantitativamente o grau de similaridade entre duas imagens, assumindo todas as escalas consideradas na análise, será dado por uma média ponderada exponencialmente (Costanza, 1989):

$$F_t = \frac{\sum_{w=1}^n F_w e^{-k(w-1)}}{\sum_{w=1}^n e^{-k(w-1)}}, \quad (2)$$

sendo k um parâmetro livre. Ao se assumir valores de k próximos de 1 estamos dando maior peso para janelas de maior dimensão, enquanto valores próximos de zero indicam maior peso para janelas de menor dimensão. Valores intermediário tendem a dar pesos mais próximos a janelas de escalas diferentes.

Para este projeto foi desenvolvido uma biblioteca, na linguagem Python, chamada “*Multiple Resolution Goodness of Fit*” o qual está disponível para instalação via comando “*pip install multiresolutionfit*”, e acessível em <https://pypi.org/project/multiresolutionfit/>.

3. RESULTADOS

Para avaliação da qualidade de previsão serão assumidas apenas as classes nuvens e não nuvens, confrontando os mapas binários das imagens sintéticas e observacionais. Os tamanhos das janelas utilizadas, para determinar o grau de similaridade entre os dados, dado pela Eq. 2, obedecem a sequência de Fibonacci. A escolha dos tamanhos das janelas é arbitrária e, adotou-se como meta-heurística a proporção áurea, buscando-se dessa forma ter uma boa representatividade do problema, ao mesmo tempo em que foi possível reduzir o custo computacional da análise.

Na Fig. 6 é apresentado um exemplo de mapa binário, nuvem e não nuvem, para a imagem observada (lado A) e imagem sintética (lado B) abrangendo a América do Sul para o dia primeiro de janeiro de 2016, às 13 UTC. A imagem sintética representa uma previsão de 30 minutos, usando como base imagens das 12 horas e 12:30 UTC. O grau de similaridade obtida entre os dois campos binários é de 80%.

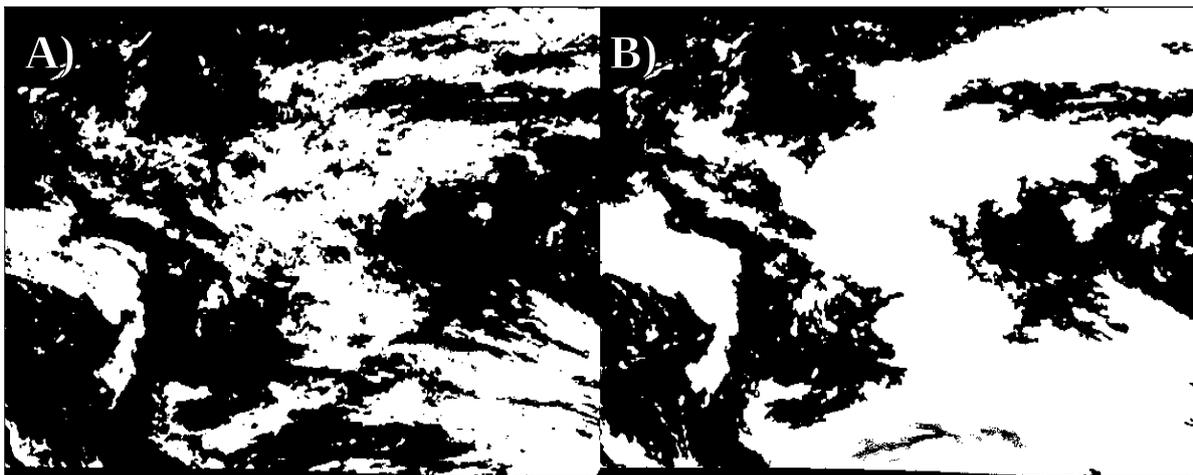


Figura 6 - Campo binário de nuvens (branco) e não nuvens (preto). A imagem do lado A foi gerada a partir da observação de satélites, a do lado B a partir de imagens de previsão. Dados abrangem a América do Sul para o dia primeiro de janeiro de 2016 as 13 horas. A imagem sintética representa uma previsão de trinta minutos, usando como base imagens das 12 horas e 12:30 horas. O grau de similaridade obtida entre os dois campos binários é de 80%.

Na Tab. 1 é apresentado um exemplo da evolução do grau de similaridade entre dados sintéticos e observacionais, para intervalos de previsão de trinta minutos, uma hora, duas horas e quatro horas. Em todos os casos, as imagens sintéticas foram geradas, tendo como base, os horários de 12 horas e 12:30 horas. O grau de similaridade representa o nível de elementos, ou classes, em comum entre duas imagens, considerando todas as janelas adotadas na análise em multirresolução.

Tabela 1 – Grau de similaridade entre dados observacionais e sintéticos de previsão para previsões de trinta minutos, uma hora, duas horas e quatro horas. Imagens sintéticas foram geradas com dados de 12 horas e 12:30 horas do dia 1 de janeiro de 2016.

Intervalo de Previsão (Horas)	Grau de Ajuste com Observação (porcentagem)
0.5	80
1	77
2	72
4	65

Como foi considerado apenas a cinemática das nuvens, vemos que o grau de similaridade tende a cair a medida que aumentamos o tempo de previsão. Ainda assim, para esse caso, o nível de similaridade entre dado sintético e observado foi maior que 60% para previsão de 4 horas.

Na Fig. 7 são apresentados os histogramas para a distribuição do grau de similaridade entre mapas binários sintéticos e observacionais, para o mês de janeiro de 2016 e intervalos de previsão de trinta minutos, uma hora, duas horas e quatro horas. Na Fig. 8 são apresentadas as curvas de máxima verossimilhança da densidade de probabilidade das ocorrências de graus de similaridade. A partir da Fig. 8 é possível realizar uma melhor comparação da qualidade do resultado obtido em diferentes intervalos de previsão. Foram realizadas trezentas comparações em cada caso. Foram realizadas trezentas comparações para dados de trinta minutos e uma hora, para duas horas, são realizadas duzentas e noventa e sete comparações, enquanto que para quatro horas foram realizadas duzentas e oito comparações.

Para trinta minutos de previsão, observou-se que o grau de similaridade com maior probabilidade foi próximo de 85%. Embora exista uma pequena dispersão de probabilidades para valores menores que 70%, é possível notar que a concentração das ocorrências é estreita, dentro do intervalo que vai entre 80% a 95%.

Para previsões de uma hora, observou-se um deslocamento do pico para regiões próximas a 80% de similaridade. Contudo, a maioria dos casos ocorreram no intervalo de 80% a 90% de similaridade. Processo similar, de deslocamento dos picos aconteceram para previsões de duas e quatro horas. Para duas horas, o pico se deslocou para a região de 80% e para quatro horas o pico ficou próximo de 70%. A medida que se aumenta o intervalo de previsão, a distribuição torna-se mais larga e bimodal.

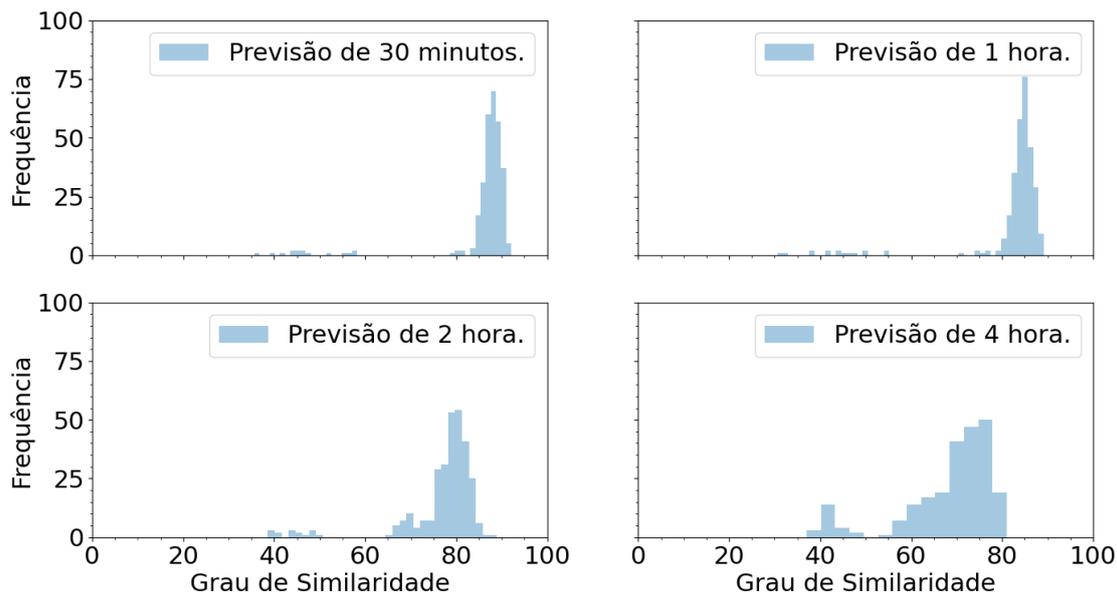


Figura 7 - Histograma das distribuições de ocorrências do grau similaridade entre mapas binários sintéticos e observacionais de previsões de trinta minutos para o mês de janeiro de 2016.

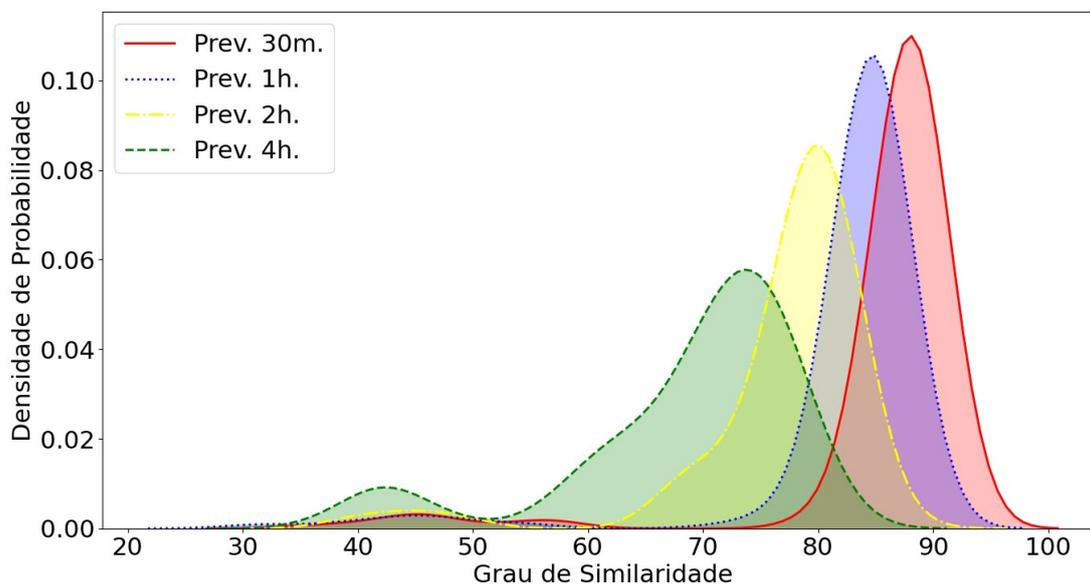


Figura 8 - Curvas de máxima verossimilhança da densidade de probabilidade das ocorrências de graus de similaridade entre mapas binários de previsão, de trinta minutos, uma hora, duas horas e quatro horas, contra dados observacionais.

4. CONSIDERAÇÕES FINAIS

Neste trabalho foi apresentado uma nova metodologia para a geração de imagens sintéticas de previsão de campos de nebulosidade, para curto prazo, a partir de imagens de satélite. Tais imagens tem sua aplicação na previsão do recurso solar empregando modelos físicos de transferência radiativa.

Para avaliar a qualidade do modelo, foram escolhidos dados do mês de janeiro de 2016, que corresponde a um período tipicamente chuvoso para a região. Foram realizadas mais de duzentas e trinta comparações de similaridade entre dados sintéticos e observacionais para previsões de trinta minutos, uma hora, duas horas e quatro horas. Notou-se que até quatro horas de previsão, temos um pico de probabilidade de acerto de 70%, chegando a 90%, para intervalos mais curtos, de trinta minutos de previsão.

A distribuição de probabilidades de acerto se torna mais larga para previsões de quatro horas, indicando uma degradação das previsões para esse período. Esse resultado é esperado, pois o modelo considera apenas a cinemática das nuvens sem levar em conta nem a dinâmica interna dos sistemas, nem o processo de fonte e sumidouro de nuvens. Ainda assim, os resultados mostram que o modelo fornece resultados robustos para previsões de até quatro horas.

Agradecimentos

Os autores agradecem ao suporte institucional e financeiro da Petrobras, através do projeto de P&D ANEEL PD-00553-0042/2016, vinculado à Chamada Estratégica n.º19/2015 – Desenvolvimento e Tecnologia Nacional de Geração Heliotérmica de Energia Elétrica. Agradecem também ao Instituto Nacional de Ciência e Tecnologia para Mudanças Climáticas (INCT-MC), através dos processos CNPq 573797/2008-0 e FAPESP 2008/57719-9.

REFERÊNCIAS

- ANDRÉ, Maína et al. **Preliminary assessment of two spatio-temporal forecasting technics for hourly satellite-derived irradiance in a complex meteorological context**. Solar Energy, v. 177, p. 703-712, 2019.
- BRAD, Remus; LETIA, Ioan Alfred. Cloud motion detection from infrared satellite images. In: Second International Conference on Image and Graphics. International Society for Optics and Photonics, 2002. p. 408-412.
- CROS, S. et al. **Cloud pattern prediction from geostationary meteorological satellite images for solar energy forecasting**. In: Remote Sensing of Clouds and the Atmosphere XIX; and Optics in Atmospheric Propagation and Adaptive Systems XVII. International Society for Optics and Photonics, 2014. p. 924202.

- CROS, S. et al. **Extracting cloud motion vectors from satellite images for solar power forecasting**. In: 2014 IEEE Geoscience and Remote Sensing Symposium. IEEE, 2014. p. 4123-4126.
- CUEVAS, Erik et al. **Block matching algorithm for motion estimation based on Artificial Bee Colony (ABC)**. Applied Soft Computing, v. 13, n. 6, p. 3047-3059, 2013.
- GOSWAMI, Barnali; BHANDARI, Gupinath; GOSWAMI, Sanjay. **Mesoscale convective system tracking in satellite thermal infrared images**. In: 2014 Annual IEEE India Conference (INDICON). IEEE, 2014. p. 1-4.
- GOSWAMI, Barnali; BHANDARI, Gupinath; GOSWAMI, Sanjay. **Fuzzy min-max neural network for satellite infrared image clustering**. In: 2012 Third International Conference on Emerging Applications of Information Technology. IEEE, 2012. p. 239-242.
- HEINEMANN, Detlev; LORENZ, Elke; GIRODO, Marco. **Solar irradiance forecasting for the management of solar energy systems**. Energy and Semiconductor Research Laboratory, Energy Meteorology Group, Oldenburg University, 2006.
- HEINEMANN, Detlev; LORENZ, Elke; GIRODO, Marco. **Forecasting of solar radiation**. Solar energy resource management for electricity generation from local level to global scale. Nova Science Publishers, New York, 2006.
- HEINZMANN, Uta. **Cloud classification on the basis of NOAA-APT data using a fuzzy logic approach**. International Archives of Photogrammetry and Remote Sensing, v. 29, p. 908-908, 1993.
- KHAWASE, Sonam T. et al. **An Overview of Block Matching Algorithms for Motion Vector Estimation**. In: Proceedings of the Second International Conference on Research in Intelligent and Computing in Engineering, str. 2017. p. 217-222.
- LORENZ, Elke et al. **Short term forecasting of solar radiation based on satellite data**. In: EUROSUN2004 (ISES Europe Solar Congress). 2004. p. 841-848.
- LORENZ, E. et al. **Forecast of ensemble power production by grid-connected PV systems**. In: 20th European PV Conference. 2007. p. 3.9-7.9.
- MORSY, I.; SEOUD, AK Aboul; EL ZAWAWI, A. **On-line prediction of photovoltaic output power under cloudy skies by using fuzzy logic**. In: Proceedings of the Nineteenth National Radio Science Conference. IEEE, 2002. p. 519-526.
- PELLAND, S. et al. **Photovoltaic and solar forecasting: state of the art**. IEA PVPS Task 14, subtask 3.1. report IEA-PVPS T14-01: 2013. International Energy Agency, 2013.
- PENG, Zhenzhou et al. **A hybrid approach to estimate the complex motions of clouds in sky images**. Solar Energy, v. 138, p. 10-25, 2016.
- PEREZ, Richard et al. **Validation of short and medium term operational solar radiation forecasts in the US**. Solar Energy, v. 84, n. 12, p. 2161-2172, 2010.
- SIMPSON, J. J.; KELLER, R. H. **An improved fuzzy logic segmentation of sea ice, clouds, and ocean in remotely sensed arctic imagery**. Remote Sensing of Environment, v. 54, n. 3, p. 290-312, 1995.
- SUGANTHI, L.; INIYAN, S.; SAMUEL, Anand A. **Applications of fuzzy logic in renewable energy systems—a review**. Renewable and sustainable energy reviews, v. 48, p. 585-607, 2015.
- ZAHER, Ali et al. **Comparative study of algorithms for cloud motion estimation using sky-imaging data**. IFAC-PapersOnLine, v. 50, n. 1, p. 5934-5939, 2017.
- ZADEH, Lotfi A. Fuzzy sets. **Information and control**, v. 8, n. 3, p. 338-353, 1965.

CLLOUD FIELD FORECASTING IMAGE GENERATOR ALGORITHM FROM SATELLITE IMAGES

Abstract. *The cloud motion vector field have been used in the photo-voltaic forecasting, in the specifics models context. However, there is a gap of methodologies that are capable to generate a product, for general propose, for forecast from satellite images. In this way, in this work it is presented a pipeline to generate synthetic images. The first step of the pipeline is the satellite image segmentation, using a Fuzzy controller system, to separate clouds and background. From images, that contain only clouds, it is applied the block matching algorithm, in order to determine the cloud motion vector field. Each cloud is moved in a distinct way, based in its typical speed, in pixels by seconds. In this way, a new image is generated by the merge of moved cloud layers. From a multi-resolution analysis we observed that, in terms of cloud position, it was possible to obtain a fit of 90% for synthetic data, in relation to observed data, for forecast of 30 minutes, and, 70% if it was assumed a time range forecast for 4 hours.*

Key words: *Satellite Images, Cloud Motion Forecasting, Fuzzy.*