

Resenha: A new geostatistical approach for filling gaps in Landsat ETM+ SLC-off images

Rafael de Andrade Moral ¹

1 Artigo

ZHU, X., LIU, D. & CHEN, J. (2012). A new geostatistical approach for filling gaps in Landsat ETM+ SLC-off images. *Remote Sensing of Environment* **124** 49-60.

2 Resumo do trabalho

Este trabalho teve como objetivos criar um novo método para preencher pixels vazios de imagens coletadas pelo satélite Landsat baseado na teoria geoestatística e comparar a sua precisão com os já existentes. A motivação para o trabalho foi o fato de que o método com base na teoria geoestatística utilizado era o de krigagem ordinária (PGM), levando em conta apenas a própria imagem. Isso resultava em alguns problemas decorrentes da suavização (*e.g.*, pixels de ruas eram preenchidos por florestas e pixels de rios preenchidos por terrenos). O método usado ativamente era o chamado NSPI (*Neighborhood Similar Pixel Interpolator*), que traz bons resultados, porém não é baseado na teoria geoestatística e, portanto, não pode informar a incerteza de predição.

Os autores, então, desenvolveram um novo método chamado GNSPI (*Geostatistical Neighborhood Similar Pixel Interpolator*), que possui um algoritmo similar ao NSPI, porém traz a incerteza de predição, bem como predições mais precisas em comparação aos demais métodos. Foi utilizada uma imagem do satélite Landsat na qual os autores removeram pixels, para os quais era conhecida a reflectância, para testar a precisão dos métodos em preencherem os pixels perdidos. A utilização desses métodos é muito importante em sensoriamento remoto, pois o sensor ETM+ do satélite Landsat 7 apresentou, em 2003, uma falha em seu sistema SLC (*scan-line corrector*), ocasionando em imagens com aproximadamente 22% de pixels perdidos.

3 Metodologia geoestatística e resultados

O método utiliza, além da imagem para a qual se quer prever pixels perdidos, uma imagem em um tempo anterior da mesma paisagem, na qual os pixels não estão perdidos no mesmo local. O método GNSPI consiste de 6 passos, discutidos brevemente a seguir.

¹LCE - ESALQ/USP. e-mail: rafa_moral2004@yahoo.com.br

1. Os pixels da imagem são classificados em diferentes classes, baseadas na similaridade espectral dos mesmos, já que pixels com maior similaridade espectral apresentam padrão de mudança temporal mais parecido.
2. O relacionamento temporal para cada classe entre a imagem antiga e a atual é modelado linearmente, tendo como variável resposta a reflectância dos pixels na imagem atual. Assim, as relações temporais para cada classe de pixel são utilizadas para prever a reflectância dos pixels perdidos, bem como estimar os valores esperados para os pixels não-perdidos.
3. Um mapa de resíduos é gerado, para que a suposição de estacionariedade seja atendida. Então, semivariogramas são obtidos pra cada classe de pixels, a partir da seleção aleatória de 1000 pixels em cada classe, já que a utilização de todos os pixels ocasionaria em um tempo computacional impraticável. Aos semivariogramas, modelos são ajustados (*e.g.*, modelo exponencial).
4. Pixels de reflectância conhecida no entorno dos pixels perdidos são selecionados para predizê-los. Dos pixels que pertencem à mesma classe, são selecionados, nas duas imagens, pixels "similares". Essa similaridade é dada pelo cálculo da raiz quadrada da média do desvio ao quadrado entre as reflectâncias dos pixels; se esse valor for menor que um limite definido, os pixels são considerados similares. Dos pixels que são considerados similares nas duas imagens, são escolhidos M pixels amostrais para predição. Os autores indicam que o valor ótimo para M seria 20.
5. Krigagem ordinária é utilizada para estimar o valor residual do pixel perdido.
6. A reflectância do pixel perdido é obtida ao utilizar o valor predito pela krigagem como resíduo do modelo linear ajustado para as tendências temporais, em cada classe. São também obtidos intervalos de confiança de 95% para a predição.

A precisão das predições foram calculadas a partir do índice RMSE (*root mean square error*). Os resultados indicaram que o método GNSPI apresentou a maior precisão de predição, em relação ao NSPI e PGM, bem como menor incerteza de predição. Os autores indicam que o GNSPI apresente três vantagens principais em relação ao NSPI:

- Como os pesos utilizados para predição pelo GNSPI são calculados a partir da teoria geoestatística e, portanto, incorporam a dependência espacial da imagem, o método é mais robusto em paisagens variadas;
- O GNSPI seleciona melhor os pixels utilizados nas vizinhanças do pixel perdido para predizê-lo;
- O GNSPI utiliza uma abordagem geoestatística que traz a informação da incerteza da predição, enquanto o NSPI é uma abordagem determinística.

Os autores apresentaram como desvantagem do método a questão da exigência de um tempo computacional maior que os demais métodos. Porém, afirmaram que isso é compensado pela maior precisão nas predições.

4 Algumas considerações

- Essa é uma abordagem interessante de como a geoestatística pode ser utilizada em aplicações diferentes das convencionais (*e.g.*, gerar mapas de interpolação espacial para diversas variáveis biológicas/químicas).
- Os autores não detalham qual software utilizaram para implementar o método GNSPI. Seria interessante uma implementação em um software livre, como por exemplo, o R. A otimização da programação do método poderia resolver, em parte, o problema do tempo computacional.