

Interpolación de Imágenes de Sensado Remoto Utilizando VMCA

Sharolyn Anderson¹ Mark A. Fonstad² Claudio Delrieux³

¹Department of Geography — University of Denver — Denver, CO 80210 — sander24@du.edu

²Department of Geography — Texas State University at San Marcos
San Marcos, TX 78666 — mfonstad@txstate.edu

³Depto. Ing. Eléctrica y Computadoras — Universidad Nacional del Sur, Av. Alem 1253 — (8000)
Bahía Blanca, ARGENTINA — claudio@acm.org (Parcialmente financiado por SECyT-UNS)

Resumen

El *voter model cellular automata* (VMCA) es un modelo sencillo y efectivo que puede ser utilizado para la interpolación de información perdida en imágenes (nubes en imágenes satelitales, ruido en imágenes fotográficas, etc.). En este trabajo se presentan los resultados de la interpolación resultante para varios tipos de imágenes de sensado remoto, y se demuestra que la utilidad del método es significativa para la mayor parte de los usos probables en diversos contextos.

1. Interpolación en imágenes y datos geográficos

Las imágenes satelitales son uno de los medios más abundantes, prácticos y útiles para generación de datos en diversas áreas, como el sensado remoto, GIS, ciencias de la tierra, y muchas otras disciplinas [12, 17]. Sin embargo, la mayor parte de las tecnologías de generación de imágenes satelitales actuales son susceptibles a pérdida de información por razones climáticas, especialmente la existencia de nubes en las áreas geográficas sensadas.

La información perdida no es fácilmente recuperable por varias razones. Por un lado, el uso de dos o más imágenes del mismo sector geográfico, suponiendo que sea posible conseguirlas para fechas relativamente próximas, duplica el costo de la fuente de información. Por otro, la fusión de datos de dos imágenes diferentes es lejos de ser sencilla, ya que siempre son obtenidas con órbitas y condiciones de iluminación diurna muy disímiles, lo cual lo torna en una tarea supervisada y muy compleja. Por ello es que algún mecanismo que permita interpolar o recuperar de alguna manera los datos perdidos sería de gran utilidad.

La interpolación espacial en sí misma es además útil en otro tipo de situaciones, básicamente cuando es necesario un *upsampling* del conjunto de muestras de referencia para fusionar dos o más conjuntos de información geográfica en una misma área, pero con diferentes tasas de muestreo. Todo esto hace atractiva la idea de contar con un modelo de interpolación local, que utilice información disponible dentro un contexto reducido para generar una aproximación plausible en los puntos perdidos.

Sin embargo, es necesario notar que la interpolación espacial en geografía es muy diferente a la interpolación en imágenes digitales tradicionales [9, 7]. En imágenes digitales, como en su caso unidimensional, la señal digital, la interpolación se asume como un proceso de reconstrucción, y por lo tanto se asimila a un caso particular de aplicación de funciones polinomiales de reconstrucción (lineal, cuadrática, Gaussiana, etc.). Este modelo es inadecuado en la interpolación espacial en geografía, dado que los patrones geométricos subyacentes en la gran mayoría de los escenarios geográficos exhiben una naturaleza fractal o cuasi-fractal [2, 4, 13, 19], la cual no es ni cercanamente aproximable con funciones polinomiales de reconstrucción [7, 8].

Por lo tanto, un modelo local de interpolación debe combinar tanto la lógica y esperable uniformidad global en áreas geográficas cercanas, con la existencia de variaciones locales de naturaleza fractal presentes en todo tipo de contextos geográficos. En este trabajo estudiamos el uso de un autómata celular bidimensional no determinístico, denominado *voter model* (VMCA) para la interpolación de datos clasificados como nubes en imágenes de satélite. El VMCA combina estocásticamente los valores de datos existentes en los puntos vecinos, y por lo tanto provee la necesaria combinación de patrones fractales discontinuos en pequeña escala, pero manteniendo al mismo tiempo un nivel razonable de autocorrelación espacial en escalas mayores.

En la próxima Sección describimos en detalle el VMCA y sus posibles variaciones, en la Sección 3 se muestra la aplicación del VMCA a la interpolación de datos perdidos por nubes en imágenes satelitales, se interpolan imágenes satelitales reales con nubes ficticias, con el objeto de comparar los resultados de la interpolación con la información verdadera, y determinar el error en el que se incurre durante el proceso. En la Sección 4 se discuten los resultados, las conclusiones, y las líneas de investigación futura.

2. *Voter model cellular automata*

El modelo original del VMCA es un autómata no determinístico extremadamente simple, estudiado para modelar comportamientos electorales [10]. Dada una configuración inicial arbitraria, es decir, el estado actual de cada votante (su preferencia electoral), el modelo supone que cada votante es extremadamente impresionable por la opinión de sus vecinos, y por lo tanto su próximo estado reflejará la distribución de las preferencias electorales de éstos en el estado actual. Representado en una grilla rectangular, el autómata simplemente elige su próximo valor aleatoriamente entre los valores de sus vecinos [10, 18].

Es notable el efecto de una regla tan simple. Si el modelo tiene solo dos posibles elecciones, es decir, es equivalente a un modelo de Ising [6], entonces, es posible mostrar que la iteración de este modelo durante la cantidad necesaria de estados sucesivos produce una *percolación* de la distribución espacial de la configuración inicial. Esta percolación, pese al no determinismo inherente al autómata, está lejos de ser un arreglo completamente aleatorio. Más bien, produce una configuración fractal con conglomerados autocorrelacionados y dependientes de la escala, la cual, además, no es estática sino que varía si se sigue iterando, pero con propiedades fractales y estadísticas similares y dependientes exclusivamente de la configuración inicial. En particular, la distribución de elecciones finales es estacionaria, estadísticamente idéntica a lo largo de las iteraciones. Lo único que varía en cada iteración es la distribución espacial.




Figura 1: Iteración del autómata con la regla de la mayoría (izq. a der.): configuración aleatoria inicial, 2, 5 y 10 iteraciones, y transformada de Fourier de la última imagen.




Figura 2: Iteración del VMCA (izq. a der.): configuración aleatoria inicial, 2, 5 y 10 iteraciones, y transformada de Fourier de la última imagen.

Esta percolación es también diferente a otras encontradas por autómatas determinísticos (por ejemplo, el de la *elección de la mayoría*). En este último autómata, al iterar la configuración arriba a un punto fijo estable, con estructuras macroscópicas caóticamente dependientes de la configuración inicial. En la Fig. 2 se ilustran estos conceptos. Dada una configuración inicial aleatoria (una imagen binaria con 50% de mayoría rápidamente llega a un punto fijo, en el cual la energía en alta frecuencia prácticamente fue eliminada. Esto se observa en la transformada de Fourier (blanco indica mayor energía), donde luego de llegar al punto fijo, la mayor parte de la energía está en un disco de radio aproximado de $\frac{1}{3 \text{ pixel}}$. En cambio, el VMCA (ver Fig. 2) continúa evolucionando, con configuraciones en las cuales, si bien hay un énfasis en bajas frecuencias, las altas frecuencias siguen estando presentes.

Como en todos los autómatas celulares locales, existen diversas variaciones al VMCA. Específicamente, cuando en vez de dos posibles estados el autómata puede asumir varios, pueden existir autómatas VMCA que se acercan a la regla de la mayoría. También se pueden plantear diversas variantes para situaciones en las que el conjunto de estados es escalar vez de ser binario o discreto. Estas diferentes reglas de transición generan variantes en los resultados, pero siempre manteniendo las similitudes estructurales en los patrones que emergen a lo largo de las iteraciones.

Estas características hacen interesante al VMCA para interpolación de datos geoespaciales. La técnica usual de interpolación basada en el método de Kriging¹ ha sido criticada por desconocer que las distribuciones geoespaciales exhiben un equilibrio entre una autocorrelación global y los patrones locales fractales o cuasi fractales debidos

¹Llamada así por haber sido propuesta por Danie Krige.

a complejos fenómenos de equilibrio entre diversos procesos [11, 1]. Por dicha razón el VMCA fue utilizado exitosamente para el modelado de patrones de distribución de vegetación, en situaciones de ausencia total de datos [3].

El primer uso reseñado del VMCA para procesamiento de imágenes es el trabajo de Sprott [18], donde se modifica el modelo original para aplicarlo a la interpolación de pixels perdidos o corruptos en una imagen binaria o de niveles de gris. La modificación clave en este trabajo consiste en considerar que los pixels no corruptos no deben interpolarse, y que sólo la zona perdida dentro de la imagen se interpolará a partir de los vecinos no corruptos. De esa manera, el VMCA se transforma en un operador morfológico de *dilatación*, donde la figura (pixels no corruptos) se mantiene inalterada y va dilatándose sobre el fondo (pixels corruptos). A diferencia de otros operadores usuales de dilatación [5, 16], esta variante del VMCA dilata en forma estocástica, y aunque el fondo quede completamente interpolado, sucesivas iteraciones producirán variantes estocásticas en las zonas dilatadas.

En imágenes clasificadas, con un numero bajo de clases (como por ejemplo un mapeo de clasificación del uso de suelo en sensado remoto), esta modificación del VMCA sería aplicable en forma directa. La única diferencia es que la distribución de pixels corruptos en el trabajo de Sprott es muy diferente a la esperable en las nubes u otros factores que pueden requerir interpolación de datos en imágenes satelitales, particularmente porque la configuración espacial de las nubes conforma áreas conexas de gran tamaño, por lo que la incertidumbre en el interior de estas áreas es mucho mayor. Por otro lado, la correlación geométrica en imágenes es crítica para su calidad, mientras que en imágenes temáticas utilizadas con fines estadísticos, obtener las frecuencias relativas con buena precisión es el objetivo más importante, sin que interese específicamente si las localizaciones de los datos interpolados se corresponde con mucha precisión a los datos reales.

Una consideración adicional es la noción subyacente de vecindad, entre las que se cuentan las más usuales de Von Neumann (4 vecinos separados por las aristas de los pixels) y de Moore (8 vecinos). El efecto neto de la vecindad es la manera en la que avanza la frontera de dilatación, asociándose a norma 1 (distancia de Manhattan) en el primer caso, y a norma infinito en el segundo. Si bien Spott no consideró estos casos, en nuestro trabajo incorporamos la posibilidad de modificar la vecindad para manejar diferentes alternativas.

3. Aplicando VMCA en imágenes satelitales

La aplicación del VMCA modificado en imágenes satelitales temáticas es directa. En un primer paso se clasifican los puntos en la imagen de acuerdo con su radiancia espectral en las 6 bandas, de acuerdo a los clasificadores usuales (ver por ejemplo <http://www.cgia.state.nc.us/cgdb/lulc87f.html> [12, 17]). También se clasifican los puntos cubiertos por nubes. La zona de la imagen cubierta por nubes es segmentada, formando una máscara donde se permite que el VMCA dilate la frontera con los pixels vecinos. Cada punto de esta máscara consultará si hay pixels vecinos con un valor asignado, y entre ellos elegirá uno al azar. De esa forma, a lo largo de las iteraciones, la frontera de la zona original oscurecida va retrocediendo hasta desaparecer (ver Fig. 3).




Figura 3: Imagen LANDSAT con nubes sintéticas, y luego de 10, 20 y 40 iteraciones del VMCA.




Figura 4: Nubes sintéticas sobre una imagen LANDSAT: (a) Dimensión fractal 2.2 y cubrimiento 5%, (b) dimensión fractal 2.6 y cubrimiento 15%, (c) dimensión fractal 2.2 y cubrimiento 5%, (d) dimensión fractal 2.6 y cubrimiento 15%.

Es necesario remarcar que la máscara original segmentada como cubierta por nubes sigue siendo la misma, y que dentro de ella, en cada iteración, todos los pixels eligen como nuevo valor el valor de alguno de sus vecinos. Por lo tanto, aún cuando la zona oscurecida por nubes ha sido interpolada, continuar iterando continúa modificando la interpolación, dado que el VMCA no alcanza nunca un punto fijo.

Para contrastar el error incurrido en esta interpolación, la estrategia utilizada aquí fue utilizar imágenes sin nubes, agregándoles nubes sintéticas generadas con algoritmos *ad-hoc*, para luego evaluar el error RMS y porcentual de la zona interpolada respecto de la original. El algoritmo generador de nube se basa en el método del desplazamiento aleatorio del punto medio [15, 14], y permite elegir, en cada experimento, la dimensión fractal de las nubes (entre 2 y 3). Los valores generados para cada pixel de la imagen por medio de este algoritmo son umbralizados, lo cual permite determinar el porcentaje de cubrimiento de las nubes sobre la imagen original (ver Fig.4).

3.1. Interpolación de imágenes clasificadas

El resultado de aplicar VMCA a la interpolación de imágenes satelitales clasificadas es más que satisfactorio. Aplicamos este método a imágenes LANDSAT rurales y urbanas. El propósito de estas pruebas es contrastar la calidad de la interpolación en

áreas de diferente heterogeneidad espacial. En la Fig. 5 se puede apreciar el resultado de interpolar sobre nubes sintéticas en una imagen clasificada de la zona rural de Ratón (New Mexico), pertenecientes al programa NALC (North American Landscape Classification) de la USGS (United States Geological Survey)². En la figura se muestra la imagen original, la artificialmente oscurecida, la interpolada, y el histograma de distribución de clases en la zona oscurecida, tanto para la imagen original como para la interpolada. Se observa que, si bien hay diferencias en la clasificación punto por punto entre la interpolada y la original, el histograma de distribución es casi idéntico, lo cual muestra que la imagen recuperada es utilizable para usos estadísticos de porcentajes de utilización del suelo.

Un segundo ejemplo son las imágenes urbanas, donde los patrones geométricos inherentes a las actividades humanas son dominantes. Se utilizó una imagen clasificada del programa CAP-LTER (Central Arizona, Phoenix Long-Term Ecological Research), de la Arizona State University³. En la Fig. 6 se muestra la misma secuencia de imágenes que en el ejemplo anterior. Como era previsible, en la imagen interpolada la coherencia geométrica se pierde casi por completo. Sin embargo, los histogramas de distribución de uso del suelo siguen siendo casi idénticos, por lo que la calidad de la interpolación es igualmente satisfactoria. Actualmente estamos trabajando en aplicar VMCA en imágenes satelitales de otros tipos (hiperespectrales, multiespectrales sin clasificar, IKONOS, SAR), siendo los resultados preliminares muy alentadores, aunque sin haber establecido aún los parámetros de evaluación del error.

3.2. Interpolación de imágenes de fotografías aéreas

Los resultados de aplicar VMCA a la interpolación de otro tipo de tecnologías de sensado remoto requieren consideraciones particulares. Probablemente el segundo tipo de imágenes más utilizado en sensado remoto sean las imágenes de fotografías aéreas. Dependiendo del tipo de tecnología y uso, éstas pueden ser de luminancia (niveles de gris) o pancromáticas. En la Fig. 7 se puede observar el efecto de la interpolación de una imagen en niveles de gris de una zona agrícola al este de Austin (Texas).

En nuestro caso, utilizamos imágenes del programa NAPP (National Aerial Photography Program of the United States Geological Survey)⁴. Estas imágenes son de alta calidad y representan un desafío desde el punto de vista de la coherencia espacial, dado que su resolución es de un metro. El esquema utilizado fue similar al empleado en imágenes temáticas: se contrastó el resultado de la interpolación tanto en zonas rurales como urbanas.

Es importante tener en cuenta que para imágenes en niveles de gris existen por lo menos dos maneras de evaluar el error. Por un lado, se trabajó con el error cuadrático por pixel (representado en un mapa independiente), y también el RMS acumulado en toda la zona interpolada. La otra evaluación importante consiste en comparar los histogramas de luminancia para determinar si las distribuciones de la imagen de referencia y de la interpolada exhiben comportamientos similares.

²Ver <http://edc.usgs.gov/products/satellite/nalc.html>. Se utilizó esta fuente para garantizar un testeo con imágenes reales de alta calidad.

³Ver <http://caplter.asu.edu>.

⁴Ver http://mcmcweb.er.usgs.gov/status/napp_stat.html.

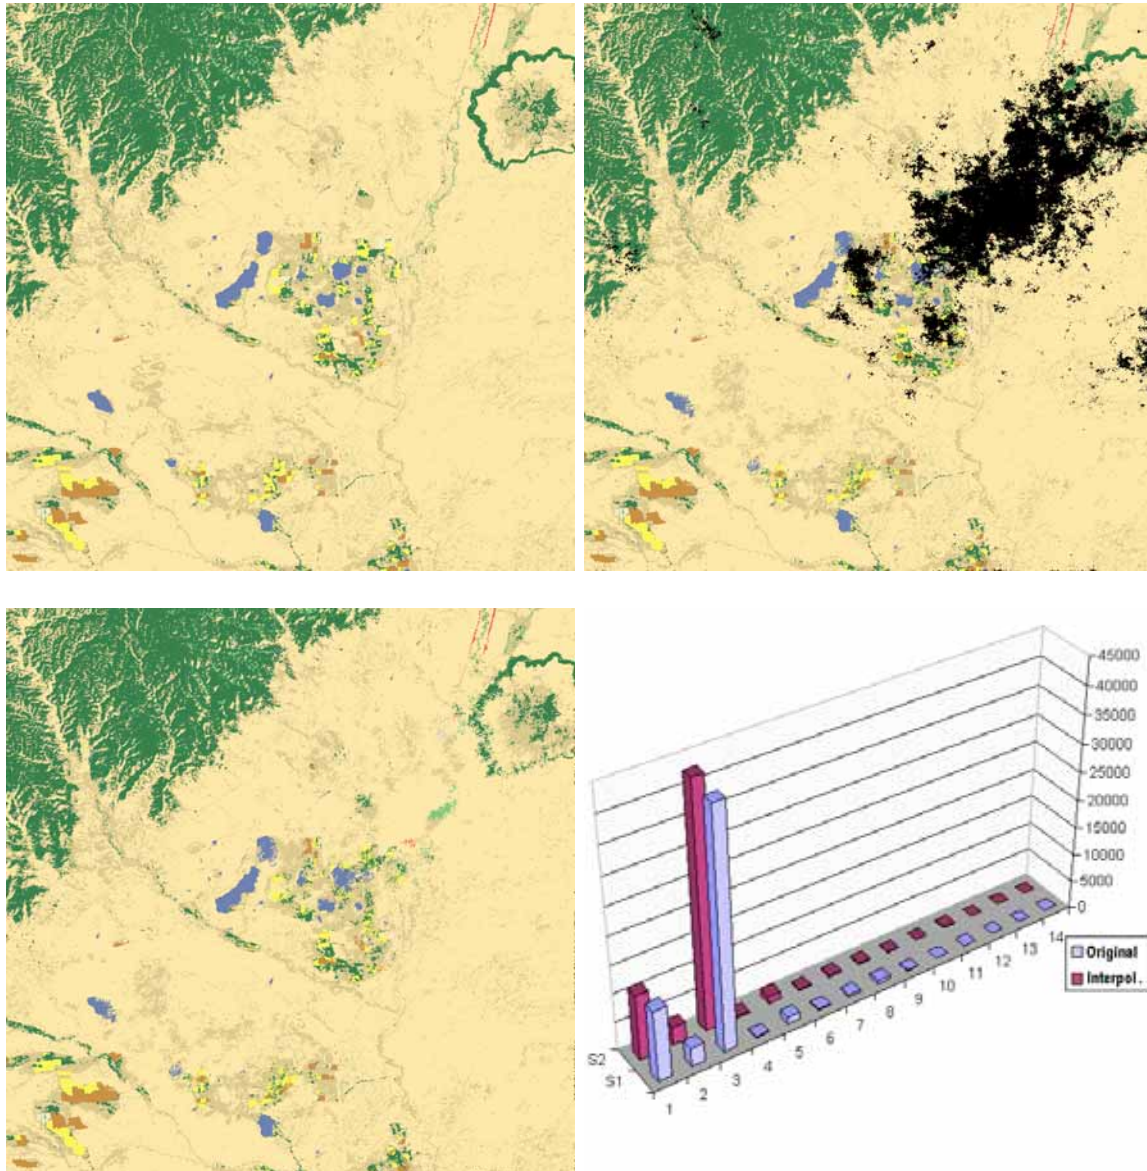


Figura 5: Interpolación en una imagen rural clasificada: (a) Imagen original de la zona rural de Ratón (NM), (b) agregado de nubes sintéticas (cubrimiento 10%, dimensión fractal 2.4), (c) imagen interpolada luego de 50 iteraciones, y (d) histogramas de la distribución de clases en la zona interpolada.

En imágenes urbanas (tomamos como fuente zonas urbanas dentro de Austin, Texas), la correlación espacial es muy grande con este nivel de resolución (ver Fig. 8) lo cual se observa específicamente en el mapa de error por pixel. Sin embargo, tanto el error RMS de la zona interpolada, como la comparación de los respectivos histogramas de luminancias muestran valores que se podrían considerar adecuados.

4. Conclusiones y trabajo futuro

Se presentaron los resultados de aplicar VMCA para interpolar zonas oscurecidas por nubes en imágenes de sensado remoto. Estos resultados son útiles no solo para

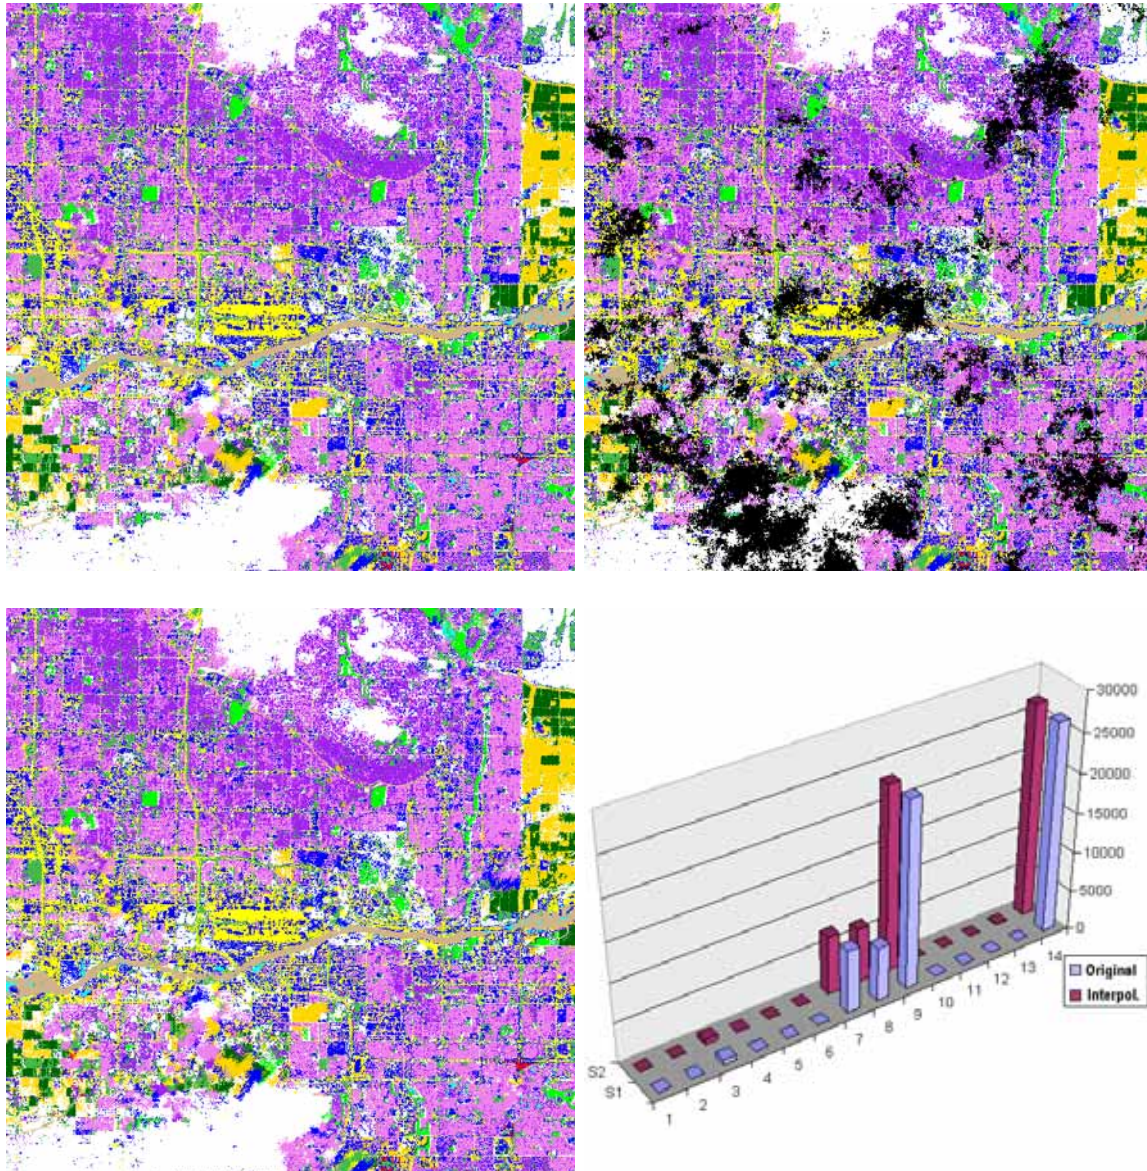


Figura 6: Interpolación en una imagen urbana clasificada: (a) Imagen original de Phoenix (AZ), (b) agregado de nubes sintéticas (cobrimiento 10 %, dimensión fractal 2.4), (c) imagen interpolada luego de 50 iteraciones, y (d) histogramas de la distribución de clases en la zona interpolada.

obtener una mejor visualización, sino también para obtener datos estadísticamente significativos. Dado que el VMCA genera percolaciones con distribuciones estacionarias, los resultados de la interpolación son estadísticamente indistinguibles de los originales, y por lo tanto, como se mostró en este trabajo, estos resultados son adecuados para la mayor parte de los propósitos usuales en sensorado remoto. Si bien en puntos particulares la clasificación no siempre es correcta, el efecto estadístico puede asimilarse al error usual de clasificación.

Una de las ventajas más importantes de este modelo es que desde el punto de vista computacional es local y restringido. Por lo tanto su implementación es sencilla, y de ejecución mucho más rápida que cualquier otro método de restauración, con resultados muchas veces de mayor calidad. Además, la naturaleza local, escalable y paralelizable de




Figura 7: Interpolación en una imagen aérea rural: (a) Imagen aérea de la zona rural al oeste de Austin (TX), (b) agregado de nubes sintéticas (cobrimiento 10%, dimensión fractal 2.4), (c) imagen interpolada luego de 50 iteraciones, y (d) mapa del error RMS.

los autómatas celulares hacen candidato a este método a implementaciones en hardware por medio de FPGAs, software embebido, uso de GPUs, etc. Inclusive desde el punto de vista microelectrónico, podría pensarse en su inclusión dentro del mismo dispositivo sensor.

Actualmente estamos trabajando en aplicar VMCA en imágenes satelitales de otros tipos (hiperespectrales, multispectrales sin clasificar, IKONOS, SAR), siendo los resultados preliminares muy alentadores. También se busca determinar si existe algún tipo de ventaja entre utilizar VMCA con 4 u 8 vecinos, o si hay alguna mejora en diferentes contextos. En las imágenes de niveles de gris, una posibilidad consiste en perturbar el valor elegido por el VMCA con alguna cantidad aleatoria con distribución uniforme, media cero y valores extremos dependientes del contexto. Esto permitiría

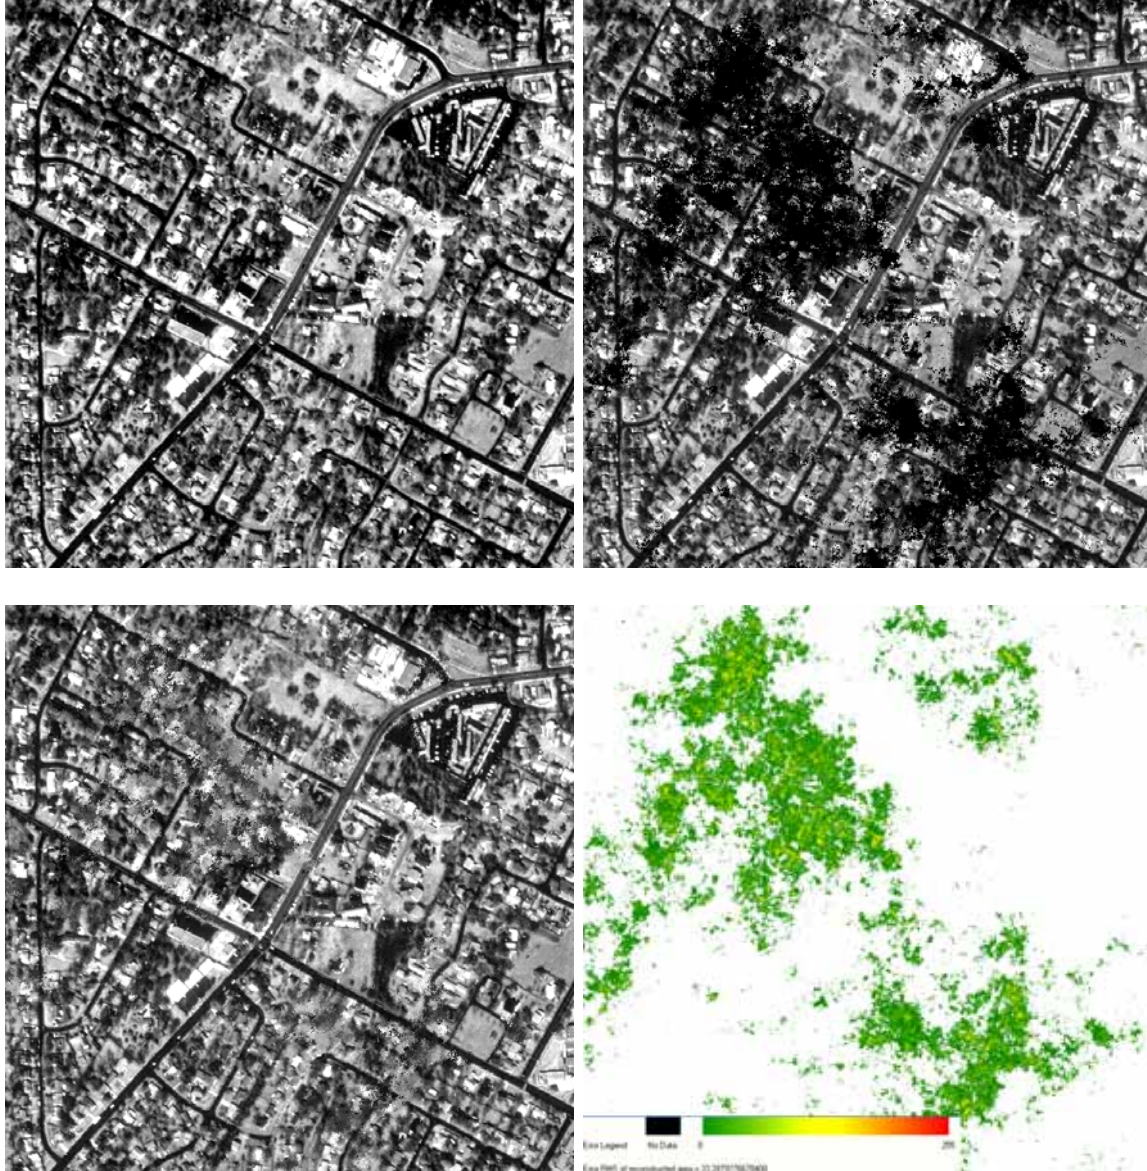


Figura 8: Interpolación en una imagen aérea urbana: (a) Imagen aérea de Austin (TX), (b) agregado de nubes sintéticas (cubrimiento 10%, dimensión fractal 2.4), (c) imagen interpolada luego de 50 iteraciones, y (d) mapa del error RMS.

variaciones más sutiles entre pixels de valores conocidos, probablemente mejorando el realismo de la interpolación.

Referencias

- [1] M. Armstrong and N. Champigny. A Study on Kriging Small Blocks. *CIM Bulletin*, 82(923), 1988.
- [2] Tang C. Bak, P. and K. Wiesenfeld. Self-organized criticality: an explanation of $1/f$ noise. *Physical Review Letters*, 59(4):381–384, 1987.

- [3] J.C. Bolliger, J. Sprott and Mladenoff. Self-organized criticality and complexity in historical landscape patterns. *Oikos*, (6):541–553, 2003.
- [4] S. Casey and N. Reingold. Self-Similar Fractal Sets: Theory and Procedure. *IEEE Computer Graphics and Applications*, 14(3):73–82, 1994.
- [5] K. Castleman. *Digital Image Processing*. Prentice-Hall, New York, 1989.
- [6] Cyrano de Dominicis. *Random Fields and Spin Glasses*. Cambridge University Press, Cambridge, MA, 2006.
- [7] Andrew Glassner. *Principles of Digital Image Synthesis*. Morgan Kaufman, San Francisco, 1995.
- [8] Jonas Gomes and Luiz Velho. *Image Processing for Computer Graphics*. Springer, New York, 1997.
- [9] Rafael González and Richard Woods. *Digital Image Processing*. Addison-Wesley, Wilmington, USA, 1996.
- [10] R. Holley and T.M. Liggett. Ergodic theorems for weakly interacting particle systems and the voter model. *Annals of Probability*, 3:643–663, 1975.
- [11] N.S. Lam. Fractals and scale in environmental assessment and monitoring. In E. Sheppard and B. McMaster, editors, *Scale & Geographic Inquiry: Nature, Society, and Method*, pages 23–40. Blackwell Publishing, Malden, 2004.
- [12] T. Lillesand and R. Kiefer. *Remote Sensing and Image Interpretation (4th. ed.)*. Willey & Sons, New York, 2000.
- [13] B. Mandelbrot. *The Fractal Geometry of Nature*. W. H. Freeman, New York, 1983.
- [14] K. Musgrave, C. Kolb, and R. Mace. The Synthesis and Rendering of Eroded Fractal Terrain. *ACM Computer Graphics*, 23(3):41–48, 1989.
- [15] H.-O. Peitgen and D. Saupe. *The Science of Fractal Images*. Springer-Verlag, New York, 1986.
- [16] J. C. Russ. *The Image Processing Handbook*. CRC Press, Boca Raton, FL, 1989.
- [17] Robert Schowengerdt. *Remote Sensing Models and Methods for Image Processing (2th. ed.)*. Academic Press, San Diego, 1997.
- [18] J.C. Sprott. A method for approximating missing data in spatial patterns. *IComputers and Graphics*, (28):113–117, 2004.
- [19] Donald L. Turcotte. *Fractals and Chaos in Geology and Geophysics*. Cambridge University Press, Cambridge, 1992.