

Fusión de Imágenes basada en Sensado Compresivo

José A. Petrerena

Universidad Tecnológica de Panamá, Ciudad de Panamá, Panamá, Panamá, jose.petrerena@utp.ac.pa

Carlos Murcia

Universidad Tecnológica de Panamá, Ciudad de Panamá, Panamá, Panamá, carlos.murcia@utp.ac.pa

Desiderio Bourdet

Universidad Tecnológica de Panamá, Ciudad de Panamá, Panamá, Panamá, desiderio.bourdet@utp.ac.pa

Faculty Mentor:

Fernando Merchan

Universidad Tecnológica de Panamá, Ciudad de Panamá, Panamá, Panamá, fernando.merchan@utp.ac.pa

Formatted: Space After: 6 pt

ABSTRACT

We study the performance of a method for image fusion based in compressive sensing. This method is based in the acquisition of random measurements of images blocks of pixels of the images to fusion. These measurements are weighted based upon the randomness of the measurements blocks using information theory related metrics. The performance of this algorithm is studied in function of the size of the image blocks the, ratio of the number of measurements and the number of pixels of the image and the type of reconstruction algorithm used. A comparative study is presented in terms of computational time and the SSIM (structural similarity index metric).

Keywords: Image processing, compressive sensing, image fusion

RESUMEN

En este trabajo realizamos un estudio de un método de fusión de imágenes basada en sensado compresivo (SC). En esta técnica la fusión es realizada a partir de mediciones aleatorias realizadas por bloques de píxeles de las imágenes a fusionar. Las mediciones obtenidas son ponderadas en función de la entropía e información mutua de cada bloque de medición con el fin de darle mas relevancia a los componentes que contienen más información. El rendimiento de este algoritmo es estudiado en función de parámetros tales como el tamaño de los bloques de medición, la relación de medidas sobre muestras de la imagen original y el tipo algoritmo de reconstrucción utilizado. El estudio comparativo se realiza en términos del tiempo de ejecución de los métodos y el SSIM (structural similarity index metric).

Palabras claves: Procesamiento de Imágenes, Sensado Compresivo, Fusión de Imágenes.

1. INTRODUCTION

El teorema de Shannon y Nyquist nos enseña que la tasa de muestreo necesaria para la reconstrucción exacta de una señal, debe ser superior al doble de su ancho de banda. En muchas aplicaciones de imágenes digitales y video-cámaras, la tasa de Nyquist es tan alta que el número de muestras resultantes causa que la compresión de estas señales sea una necesidad previa al almacenamiento o transmisión; y en otras aplicaciones, tener una alta tasa de muestreo resulta ser muy costosa. Alrededor del año 2006, emergió una teoría alternativa a este teorema propuesta por David L. Donoho y Emmanuel J. Candès, llamada "Sensado Compresivo" (Candes et al,2006, Donoho, 2006) . El principio del Sensado Compresivo (SC) propone que una señal o una imagen puede ser

reconstruida por un número de medidas/muestras mucho menor de lo que señala el teorema de Shannon y Nyquist. Nosotros basamos nuestro estudio en el procesamiento digital de imágenes, específicamente en técnicas para la fusión de imágenes de utilizando SC. Fusión de imágenes es un proceso que combina información de múltiples imágenes en una imagen fusionada que provee mejor capacidad de interpretación. La imagen fusionada resulta ser mucho más útil para consecuentes aplicaciones de procesamiento de imágenes. Hoy en día muchos algoritmos de fusión han sido propuestos (Krishnamoorthy, K P Soman, 2010). Un trabajo reciente (Luo et al., 2009) demuestra la posibilidad de fusionar imágenes con una cantidad menor de muestras de las imágenes originales, si ellas son adquiridas utilizando el principio de SC. Una ventaja clave de este enfoque es que las muestras necesarias para el procesamiento pueden ser recolectadas sin asumir información previa de la imagen que se está observando. Además, SC requiere menos espacio de almacenamiento, a pesar del mayor costo en proceso computacional. Por lo tanto, esta técnica de SC ha sido muy atractiva para aplicaciones de imágenes.

El objetivo de este trabajo es el estudio del rendimiento de este algoritmo en función de parámetros tales como el tamaño de los bloques de medición, la relación de medidas sobre muestras de la imagen original y el tipo algoritmo de reconstrucción utilizado. El estudio comparativo se realiza en términos del tiempo de ejecución de los métodos y el SSIM (structural similarity index metric).

A continuación, presentamos una breve reseña de la teoría, conceptos y términos mencionados y utilizados para el desarrollo de los algoritmos de procesamiento. En la sección 2 presentamos aspectos teóricos de SC. En la sección 3 presentamos el método de fusión de imágenes propuesto por (Luo et al, 2009). En la sección 4 se presenta el estudio del rendimiento del algoritmo de fusión considerando diferentes tamaños de bloques, tasas de porcentaje de muestras de las imágenes originales antes de ser fusionadas por el algoritmo y los métodos de reconstrucción.

2. SENSADO COMPRESIVO

Si consideramos una señal desconocida $x \in R^N$, la cual es k -esparsa en cierta base Ψ como por ejemplo wavelets, la señal x puede ser entonces representada como la descomposición de la base:

$$x = \Psi\theta \quad (1)$$

donde θ representa un vector de los coeficientes de transformación con solo un número k de componentes que no son cero. Esto significa que la imagen es esparsa en este dominio o base seleccionado.

Una señal puede ser reconstruida por medio de un número pequeño de muestras si es esparsa en alguna base Ψ . Sin embargo, existe la precondición de que las mediciones sean obtenidas a través de una matriz de medición Φ incoherente con la base esparsa Ψ . Solamente si $\Phi\Psi$ cumple con la propiedad isométrica restrictiva (PIR). El vector de medición $y \in R^m$ ($k < m \ll n$) es obtenido por el siguiente sistema lineal:

$$y = \Phi x = \Phi\Psi\theta \quad (2)$$

donde Φ es una matriz de medición $m \times n$. A diferencia del muestreo tradicional, las mediciones contienen suficiente información para reconstruir la señal. Bajo una base esparsa fija Ψ , utilizamos la matriz de medición llamada "scrambled block hadamard ensemble" (SBHE), o matriz Hadamard, ya que es una matriz que permite cumplir con esta condición.

Ya que $m < n$ la recuperación de la señal x a partir de y es imposible de resolver directamente por medio de la transformada inversa a partir de la Eq. (2), se requiere el uso de algoritmos de recuperación no lineales que han sido desarrollados para estos problemas. Para una recuperación práctica, varios algoritmos rápidos han sido propuestos. En este trabajo utilizamos dos algoritmos que se desempeñan bien en una amplia gama de aplicaciones, y es significativamente rápido. Estos son el l_1 -ls (Kim et al., 2007) y el Gradient Projection for Sparse Reconstruction (GPRS) (Figueiredo et al., 2007).

3. MÉTODO DE FUSIÓN DE IMAGENES POR BLOQUE USANDO SENSADO COMPRESIVO

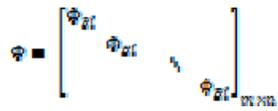
3.1 MUESTREO

Consideren una imagen de tamaño $I_f \times I_c$ con $N = I_f \times I_c$ pixeles y supongamos que deseamos tomar n mediciones SC. En SC por bloques la imagen se divide en bloques de tamaño $B \times B$ después a cada bloque se le aplica el mismo operador.

Llámesse este operador Φ_{Bi} , este operador es del tamaño $n \times B^2$ y llámese \mathbf{x}_i al bloque de la imagen después de haber sido vectorizado y donde el correspondiente vector de SC y es:

$$\mathbf{y}_i = \Phi_{Bi} \mathbf{x}_i \quad (3)$$

Para nuestro caso Φ_{Bi} es un bloque generado a partir de una matriz de Hadamard a la cual se le permutan las filas aleatoriamente y se seleccionan las filas a utilizar. La ventaja de utilizar SC por bloques es que se ahorra memoria debido a que solo hay que guardar un bloque en vez de Φ .



$$\quad (4)$$

Esta técnica también presenta unos retos como el obtener el de establecer el tamaño ideal de bloque a muestrear, este es un tema algo extenso que se aborda en (Gan et al., 2008).

3.2 FUSIÓN DE IMÁGENES

Al utilizar la técnica de SC se obtiene la imagen en una base distinta a la imagen en el espacio. A diferencia de los métodos tradicionales de fusión basadas en máximos (por ejemplo, realizados en la base de wavelets) la amplitud de las mediciones no es una medida de la importancia de las mismas. En el trabajo de (Luo et al., 2009) se propone fusionar los componentes como una combinación lineal ponderada en función de la aleatoriedad de los bloques de medición. Esto puede expresarse de la siguiente manera:

$$\mathbf{y}_b = w_1 \mathbf{y}_1 + w_2 \mathbf{y}_2 \quad (5)$$

En donde \mathbf{y}_b es el bloque resultante de los dos bloques \mathbf{y}_1 y \mathbf{y}_2 ponderados por w_1 y w_2 .

Esta propuesta se basa en el hecho de que las mediciones de SC son aleatorias ya que estas son obtenidas mediante proyecciones aleatorias. Por ello se proponen ponderaciones basadas en la cantidad de información usando métricas de entropía, las cuales están bien establecidas en la teoría de la información. Las métricas de entropía más utilizadas incluyen la entropía simple, la entropía conjunta, y la información mutua. Estas pueden expresarse como sigue:

$$H(\zeta) = - \sum_{\zeta} P(\zeta) \log P(\zeta) \quad (6)$$

$$H(\zeta_1, \zeta_2) = - \sum_{\zeta_1} \sum_{\zeta_2} P(\zeta_1, \zeta_2) \log P(\zeta_1, \zeta_2) \quad (7)$$

$$I(\zeta_1, \zeta_2) = - \sum_{\zeta_1} \sum_{\zeta_2} P(\zeta_1, \zeta_2) \log \frac{P(\zeta_1, \zeta_2)}{P(\zeta_1)P(\zeta_2)} \quad (8)$$

Estas métricas tiene la siguiente relación siguiente:

$$I(x_1, x_2) = H(x_1) + H(x_2) - H(x_1, x_2) \quad (9)$$

En el trabajo (Luo et al, 2009) se proponen las siguientes ecuaciones para obtener las ponderaciones w_1 y w_2

$$w_1 = \frac{H(x_2)}{H(x_1, x_2)} - \frac{I(x_1, x_2)}{H(x_1)} + \frac{I(x_1, x_2)}{H(x_1, x_2)} \quad (10)$$

$$w_2 = \frac{H(x_1)}{H(x_1, x_2)} - \frac{I(x_1, x_2)}{H(x_2)} + \frac{I(x_1, x_2)}{H(x_1, x_2)} \quad (11)$$

El primer término en el lado derecho distribuye el peso de acuerdo a la proporción de su entropía sobre la entropía conjunta. No obstante, utilizando solamente este término se provocaría demasiado brillo en la imagen de la fusión recuperada. La razón es que el primer término incorpora el contenido comúnmente contenido en ambas imágenes de entrada. Nosotros corregimos esto substrayendo el segundo término, en el cual la información mutua refleja la información contenida en común. Por último, normalizamos los pesos por medio del escalar. De esta manera, la información complementaria puede ser retenida lo suficiente y la información redundante puede ser integrada efectivamente de las imágenes de entrada.

3.3 PROCEDIMIENTO

En este trabajo recobramos la imagen a partir de los coeficientes fusionados seleccionando utilizar el algoritmo l1_ls (Kim et al., 2007) y el Gradient Projection for Sparse Reconstruction (GPRS) (Figueiredo et al., 2007). El procedimiento que utilizamos está descrito a continuación.

Algoritmo 1. Fusión de imágenes en sensado compresivo.

1. Convertir las imágenes a fusionar a la base deseada (-en nuestro caso wavelet)
 2. Construir la matriz de medición Φ_{Bi} con SBHE
 3. Particionar las imágenes de entrada en bloques.
 4. obtener los vectores de SC y_1 y y_2 .
 5. Calcular w_1 y w_2
 6. Fusionar las mediciones de los dos bloques.
 7. Reconstruir la imagen bloque a bloque utilizando el algoritmo l1_ls o GPRS.
 8. Ordenar los bloques recuperados para después Recobrar la imagen fusionada por medio de la transformada inversa de la base seleccionada Ψ .
-

4. RESULTADOS Y PERSPECTIVAS

Para nuestra investigación decidimos utilizar las imágenes de los relojes muy comúnmente utilizadas en el estudio de fusión de imágenes; en donde un reloj se encuentra enfocado mientras que el otro no y viceversa.

Para comparar las imágenes desde un punto más objetivo decidimos utilizar el método de SSIM (structural similarity index metric) el cual compara dos imágenes y retorna un indicador en que tan parecidas son. En el trabajo (Krishnamoorthy and K P Soman, 2010) se presentan otros métodos además de este. Se utilizó SSIM por su simplicidad de implementación. El patrón que utilizaremos como fusión ideal es la imagen fusionada con el algoritmo pero con un porcentaje de muestras del 100% Para lograr esto utilizamos el bloque Φ_{Bi} al cual se le

reordenan las filas para mantener sus propiedades aleatorias pero no se dejan de utilizar filas. De esta manera el indicador entregado por el SSIM indicara que tan buena es la reconstrucción a ciertos valores de compresión.

Al analizar las tablas 1 y 2 se observa que el método de reconstrucción $l1_ls$ es mucho más lento que el GPRS, alrededor de 50 veces, por apreciación visual se observa que el GPRS agrega en múltiples casos más artefactos a la imagen que el $l1_ls$. Como casos marcados comparar la imagen de ambas tablas. El método de reconstrucción GPRS a pesar de ser bastante poderoso tiene la característica de ser menos consistente que el $l1_ls$ esto significa que al utilizarlo más de una vez para el mismo tamaño de bloque con el mismo número de muestras cambia drásticamente el resultado. En la figura b se corrió dos veces y el SSIM de la primera vez fue 0.0447 (bastante bajo) mientras que al correrlo una segunda vez se obtuvo 0.6949 que está mucho más acorde a lo obtenido por $l1_ls$. Este método de conversión de fusión de imágenes tiene la falencia de que no permite realizar una gran reducción en las muestras originales. Al utilizar menos del 85% de la imagen original ya se tienen muchos artefactos o pérdida casi total de la imagen resultante. También empíricamente encontramos que los bloques de 16 y 32 pixeles de ancho y largo son los que menos tiempo toman en ejecutarse y además son bastante buenos en la reconstrucción. Bloques de 8 también dan buenos resultados para el algoritmo $l1_ls$ pero aumentan drásticamente el tiempo de trabajo.

Como trabajos futuros sería interesante probar el algoritmo 1 con otros métodos de reconstrucción, además de probar otras implementaciones de muestreo por bloques. Gran parte de los artefactos encontrados en las reconstrucciones están asociados al muestreo en bloques.

Otros estudio interesante sería implementar el muestreo por bloques en otros dominios o técnicas de wavelets.

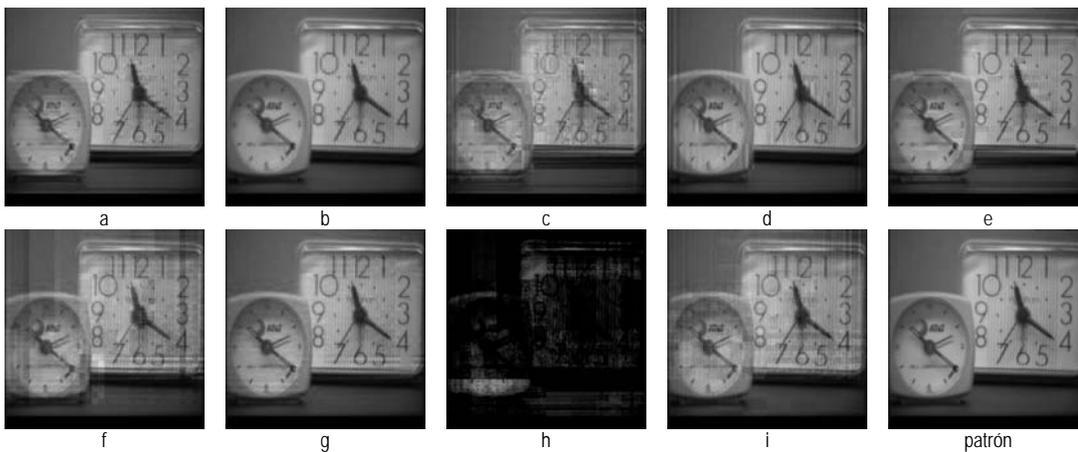


Figura 1. Resultados de la fusión por bloques con algoritmo de reconstrucción $l1_ls$.

Tabla. 1. Resultados de pruebas con el método de reconstrucción l1_1s, para diferentes tamaños de bloque de muestreo y % de muestras del bloque original utilizadas (Figura 1).

imagen	tamaño de bloque	% de muestras por bloque	tiempo de solución (s)	SSIM
a	8	84.38%	1763.47	0.5916
b	8	89.06%	1272.49	0.7952
c	16	80.08%	643.48	0.4089
d	16	89.84%	618.19	0.6002
e	16	94.92%	390.28	0.6219
f	32	80.08%	625.81	0.5070
g	32	89.94%	584.87	0.6544
h	64	79.98%	2555.71	0.0441
i	64	90.01%	2068.2	0.5417
patrón	32	100.00%	307.1	1.0000

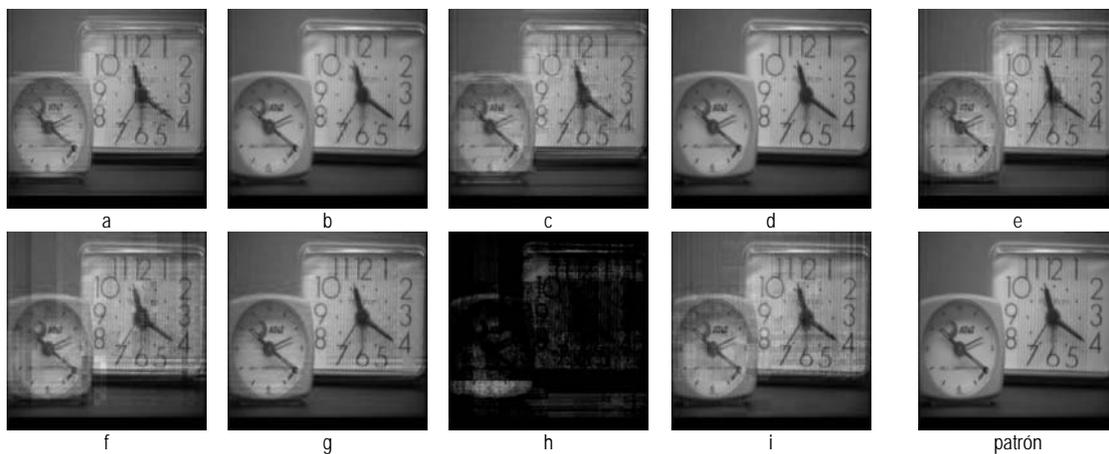


Figura 2. Resultados de la fusión por bloques con algoritmo de reconstrucción GPRS.

Tabla. 2. Resultado de pruebas utilizando el método de reconstrucción GPRS, para diferentes tamaños de bloque de muestreo y % de muestras del bloque original utilizadas (ver figura 2).

imagen	tamaño de bloque	% de muestras por bloque	tiempo de solución	SSIM
a	8	84.38%	36.94	0.4821
b*	8	89.06%	38.09	0.6949
c	16	80.08%	8.05	0.4822
d	16	89.84%	8.36	0.8088
e	16	94.92%	8.87	0.5983
f	32	80.08%	8.86	0.0527
g	32	89.94%	10.1	0.6042
h	64	79.98%	28.2	0.0441
i	64	90.01%	32.1	0.5561
patrón	32	100.00%		1

AGRADECIMIENTOS

Este trabajo fue parcialmente financiado por la Secretaría Nacional de Ciencia, Tecnología e Innovación (SENACYT) de Panamá a través del fondo del proyecto “Tecnología de video-procesamiento basada en fusión compresiva de la información”, código 4-ITE-006.

REFERENCIAS

E. Candés, J. Romberg, and T. Tao “Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information,” *IEEE Trans. Inform. Theory*, vol. 56, no.2 pp. 489-509, 2006.

D. L. Donoho, “Compressed sensing,” *IEEE Trans. Inform. Theory*, vol. 52, no.4, pp. 1289-1306, Apr. 2006.

M. A. T. Figueiredo, R. D. Nowak, S. J. Wright, “Gradient Projection for Sparse Reconstruction: Application to Compressed Sensing and Other Inverse Problems,” *IEEE Journal in Selective Topics in Image Processing*, vol. 1, Issue 4, pp.586-597, 2007

L. Gan, T.T.Do, T.D. Tran, “Fast compressive imaging using scrambled block hamard ensemble,” *www-dsp.rice.ed*, (preprint), 2008

Xiaoyan Luo, Jun Zhang, Jingyu Yang, Qionghai Dai “Image fusion in compressed sensing”, *Image Processing (ICIP), 2009 16th IEEE International Conference on*, vol., no., pp.2205,2208, 7-10 Nov. 2009

S.-J. Kim, K. Koh, M. Lustig, S. Boyd, and D. Gorinevsky, “A method for large-scale ℓ_1 -Regularized Least Squares” *IEEE Journal in Selective Topics in Signal Processing*, pp. 606–617, 2007

Shivsubramani Krishnamoorthy, K P Soman “Implementation and Comparative Study of Image Fusion Algorithms” *International Journal of Computer Applications (0975 – 8887) Volume 9– No.2, November 2010*

Authorization and Disclaimer

Cancun, Mexico

11th Latin American and Caribbean Conference for Engineering and Technology

August 14-16, 2013

Authors authorize LACCEI to publish the paper in the conference proceedings. Neither LACCEI nor the editors are responsible either for the content or for the implications of what is expressed in the paper.