

Marca de agua robusta multibit basada en HMM

César Agustín García Vázquez

Instituto Nacional de Astrofísica, Óptica y Electrónica
Coordinación de Ciencias Computacionales
cesarnda@ccc.inaoep.mx

Resumen En este trabajo se presenta la aplicación de los modelos ocultos de Markov en la extracción de marcas de agua insertadas considerando el modelo WD-HMM. Se considera la sensibilidad al ruido del sistema visual humano para determinar cuánta alteración pueden tener ciertas regiones. La detección se realiza por máxima verosimilitud y se utiliza una versión extendida del algoritmo EM para inicializarlo. Se realizan pruebas con imágenes médicas para analizar la robustez de este método.

1 Introducción

Las marcas de agua en imágenes médicas han sido propuestas (Coatrieux et al., 2000; Puech and Rodrigues, 2004) para mejorar la seguridad, confidencialidad e integridad de datos médicos. Su importancia ha aumentado con el uso de sistemas de archivado y transmisión de imágenes (PACS¹) que almacenan digitalmente imágenes médicas, como tomografías, ecografías, mamografías, etc. (Dreyer et al., 2005). Usualmente estas imágenes son guardadas en un formato llamado DICOM (Digital Imaging and Communications in Medicine), el cual es un estándar para manejar, almacenar, imprimir y transmitir imágenes médicas (Pianikh, 2008).

En este trabajo se presenta un esquema de marca de agua robusta a ciertos ataques basado en el trabajo de Ni et al., 2005a, el cual se basa en el vector del modelo oculto de Markov en el dominio de la transformada Wavelet. Este modelo toma en cuenta tanto la correlación de energía a través de las escalas, así como las diferentes subbandas en la misma escala de la pirámide wavelet.

La organización del reporte es la siguiente, en la sección se presenta nociones básicas sobre la transformada wavelet y trabajos relacionados con su uso así como el de los modelos ocultos de Markov. En la sección 3 se presenta la metodología a seguir basándose en los trabajos comentados en la sección 2, así como los modelos a utilizar. La sección 4 presenta los experimentos y resultados obtenidos y en la sección 5 se comentan las conclusiones y trabajo futuro.

¹Picture Archiving and Communication System

2 Trabajo relacionado

2.1 Transformada Wavelet y HMM

La transformada wavelet discreta representa una imagen tanto espacio como en frecuencia, como se aprecia en la figura 1(a). Al aplicar la transformada wavelet con un nivel de descomposición se tiene 4 subbandas (LL, HL, LH y HH), de las cuales, HL, LH y HH representan los *bordes* de la imagen, y la subbanda LL, un submuestreo de la misma. Cabe mencionar, que aunque los resultados visuales den la idea de que la subbanda LL presenta la imagen escalada a la mitad en x y y , esto no es así, para un ejemplo más claro, se recomienda consultar Salomon, 2007 (pág 554).

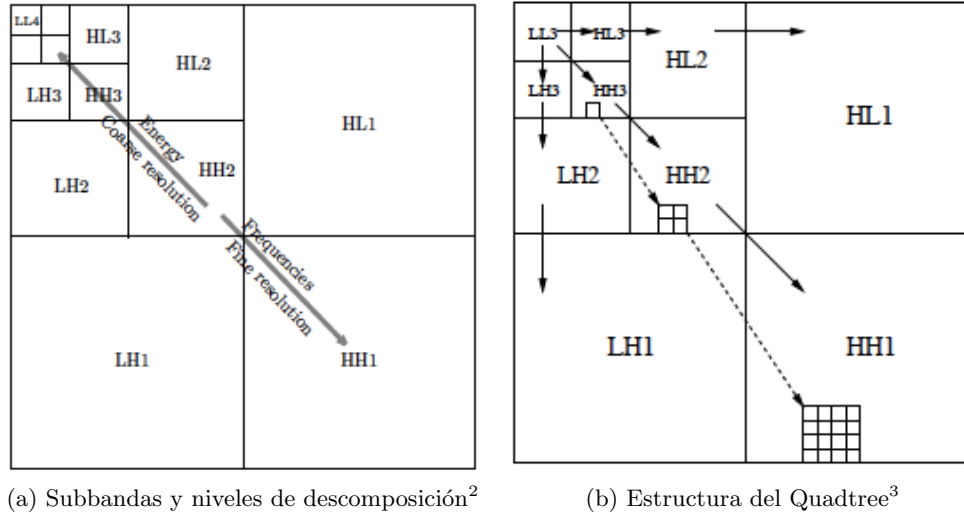


Fig. 1: Subbandas y niveles en la descomposición wavelet

De la figura 1(b), se puede apreciar la estructura quad-tree del subárbol de los coeficientes wavelet en cada subbanda $B = LH, HL, HH$. Dada la estructura quad-tree mostrada en la figura 1(b), y conjunto de coeficientes wavelet en la escala j , \mathbf{w} de una imagen de $N \times N$, $w_{j,i,k}^B$ quiere decir el (i, k) -ésimo coeficiente en la j -ésima escala de la subbanda B , $i, k = 0, \dots, N_j - 1$ y $N_j = N/2^j$. El padre de $w_{j,i,k}^B$ es $w_{j+1, \lfloor k/2 \rfloor, \lfloor i/2 \rfloor}$.

La función de densidad de probabilidad (pdf), de los coeficientes wavelet w ,

²Imagen tomada de Salomon, 2007 (pág. 614)

³Imagen tomada de Fan and Xia, 2000

puede ser descrita por una densidad no gaussiana centrada en $w = 0$. Se ha demostrado que los modelos de mezcla gaussiana pueden aproximar muy bien esta densidad no gaussiana. Por esta razón, cada coeficiente wavelet w es asociado con un conjunto de estados discretos ocultos, $S = 0, 1, \dots, M - 1$, que tienen funciones de masa de probabilidad $p_s(m)$. Así, se puede parametrizar el modelo de mezcla gaussiana por $\pi = \{p_s(m), \mu_m, \delta_m^2 | m = 0, 1, \dots, M - 1\}$, y la función general de densidad de probabilidad de w está determinada por

$$f_W(w) = \sum_{m=0}^{M-1} p_s(m) f_{W|S}(w|S = m) \quad (1)$$

2.2 HMT

Uno de los trabajos más importantes, para este trabajo, es el publicado por Crouse, Nowak, and Baraniuk, 1998, en el cual presentan un modelo para representar dependencias entre los coeficientes wavelet de una señal. Este modelo estadístico es llamado modelo *Hidden Markov Tree*. Este modelo caracteriza la función de masa de probabilidad conjunta de los coeficientes wavelet, como se muestra en la figura 2. Para este trabajo, se considera que la variable de estado cuenta con dos estados.




Fig. 2: Modelo en 2D del HMT

A cada coeficiente wavelet (nodos en negro en la figura 2) se le asigna una variable de estado (nodos en blanco), que puede tomar el valor **Alta** o **Baja** (**Grande** o **Pequeña**) dependiendo de la información que proporcione con respecto a la señal original. Existen coeficientes que al no proporcionar mucha información sobre la imagen, pueden ser alterados de tal forma que no se perciba una alteración visual. Esta característica es aprovechada por métodos de compresión (Lewis and Knowles, 1992) como el JPEG2000.

El esquema de marca de agua propuesto, es similar al metodo presentado por Lin et al., 2009, en el cual, ciertos coeficientes wavelet son alterados al agregar un valor que depende no solo de la marca de agua, si no también, de qué tanto ruido se puede agregar a ese coeficiente tomando en cuenta ciertos umbrales y el hecho de que sistema visual humano no es sensible a ciertos cambios.

Actualmente, aun se sigue trabajando con marcas de agua utilizando modelos ocultos de Markov. El trabajo video Elbasi, 2010, utiliza el HMM para determinar el grupo de imágenes a las cuales se les va a insertar la marca de agua.

Cabe remarcar, que actualmente aun no existe un modelo para insertar marcas de agua en imágenes médicas.

3 Metodología y desarrollo

3.1 Modelo WD-HMM

El modelo HMT es un modelo de mezcla gaussiana multidimensional que aplica dependencias Markovianas entre lo estados oculatos de dos escalas vecinas parametrizadas por

- $p_{S_j}(m)$: la función de masa de probabilidad del nodo raíz S_j .
- $\epsilon_{j,j+1}^{m,n} = p_{S_j|S_{j+1}}(S_{j,i,k} = m|S_{j+1,[k/2],[i/2]} = n)$: la probabilidad de transición que está representada por una matriz como la mostrada en (2), donde $p_i^{m' \rightarrow m}$ representa la probabilidad de que un nodo hijo esté en estado m dado que su nodo padre se encuentra en estado m' .
- $u_{j,j}$ y $\gamma_{j,m}^2$: los parámetros del modelo de mezcla gaussian.

$$A_i = \begin{bmatrix} p_i^{S \rightarrow S} & p_i^{S \rightarrow L} \\ p_i^{L \rightarrow S} & p_i^{L \rightarrow L} \end{bmatrix} \quad (2)$$

Se tiene que $p_i^{S \rightarrow L} = 1 - p_i^{S \rightarrow S}$ y $p_i^{L \rightarrow S} = 1 - p_i^{L \rightarrow L}$. Los parámetros $p_i^{S \rightarrow S}$ y $p_i^{L \rightarrow L}$ son las probabilidades de persistencia y los parámetros $p_i^{L \rightarrow S}$ y $p_i^{S \rightarrow L}$ las *nuevas* probabilidades, porque dan las probabilidades de que los valores de estado cambiarán de una escala a la siguiente. El tener valores grandes y pequeños de coeficientes wavelet propagándose por el quad-tree, requiere más persistencia, esto es, $p_i^{S \rightarrow S} > p_i^{S \rightarrow L}$ y $p_i^{L \rightarrow L} > p_i^{L \rightarrow S}$.

En general, estos parámetros pueden ser diferentes para cada coeficiente wavelet, haciendo que el modelo sea muy complicado. Para reducir la complejidad, se asume que cada parámetro es el mismo en cada escala de la transformada wavelet (Romberg, Baraniuk, and Choi, 2001)

Para construir el modelo, se va realizar la transformada Wavelet hasta cuatro niveles, en el cuarto nivel, de las subbandas LH, HL y HH se toma el pixel

ubicado en la misma posición en cada subbanda. De ahí, se toman los cuatro hijos de cada nodo ubicados en el tercer nivel, como se aprecia en la figura 3. Así, estos coeficientes son almacenados en un vector WD-HMM.




Fig. 3: Formación del árbol

En Ni et al., 2005a se seleccionan los píxeles por medio de una llave secreta o siguiente algún patrón en específico. En este caso, se tomará el primer píxel y luego se sigue continuamente.

3.2 Sistema visual humano

Yang et al., 1997 construyeron un modelo matemático para umbrales de detección de ruido de la DWT. Lewis and Knowles, 1992 presentaron umbrales obtenidos empíricamente, considerando la textura, iluminación y frecuencia del valor del píxel, así como de sus vecinos en las otras subbandas. De esta forma formularon un umbral, presentado en la ecuación (3) que recibe como parámetros la escala (j), la orientación (o) y la ubicación del píxel.

$$a(j, o, x, y) = \text{frecuencia} \times \text{iluminacion} \times \text{textura}^{0.034} \quad (3)$$

de donde

$$\text{frecuencia}(j, o) = \begin{cases} \sqrt{2} & \text{si } o = HH \\ 1 & \text{si } o = \text{otro} \end{cases} \times \begin{cases} 1.00 & \text{si } j = 1 \\ 0.32 & \text{si } j = 2 \\ 0.16 & \text{si } j = 3 \\ 0.10 & \text{si } j = 4 \end{cases} \quad (4)$$

$$\text{iluminacion}(j, x, y) = 3 + \frac{1}{3} \sum_{u=0}^1 \sum_{v=0}^1 I^{4,HH}(u + 1 + \frac{x}{2^{4-j}}, v + 1 + \frac{y}{2^{4-j}}) \quad (5)$$

$$\begin{aligned} \text{textura}(j, x, y) = & \sum_{k=1}^{4-s} 16^{-k} \sum_o^{HH,HL,LH} \sum_{u=0}^1 \sum_{v=0}^1 (I^{k+j,o}(u + \frac{x}{2^k}, v + \frac{y}{2^k}))^2 + \\ & 16^{4-j} \text{var} \left(I^{4,LL} \left(\{1, 2\} + \frac{x}{2^{4-j}}, \{1, 2\} + \frac{y}{2^{4-j}} \right) \right) \end{aligned} \quad (6)$$

A este umbral, se le llama máscara de peso o umbral de ruido.

3.3 Estrategia de mapeo óptimo

A diferencia de la estrategia de mapeo presentada en Ni et al., 2005a y luego utilizada en Ni et al., 2005b, en este trabajo se utiliza una estrategia de mapeo directa. La marca de agua es pasa de forma matricial a forma vectorial, al concatenar cada renglón. Así, en vez de tener una marca de agua en una matriz de 8×8 , se tiene un vector de 64 elementos. Los elementos 0, son considerados como -1 y los elementos 1 son consideramos como tal. Así, un vector de la forma $[1, 0, 1, 0]$ es mapeado como $[1, -1, 1, -1]$. Este mapeo se representa como $M \rightarrow d$. Para cada vector de 15 nodos, existen 2^{15} maneras de modificarlo.

3.4 Inserción de la marca de agua

Después de que se tiene el mapeo de la marca de agua M a d , se inserta d en la imagen por medio de la fórmula en (7).

$$X(t, i) = X(t, i) + d_i \cdot \beta \cdot a(t, i) \quad (7)$$

donde

- $X(t, i)$: es el i -ésimo nodo en el t -ésimo vector de árbol.
- $a(t, i)$: es su correspondiente umbral de ruido, del sistema visual humano.
- β : es el factor de ajuste global.
- d_i : es el i -ésimo elemento del mapeo de la marca de agua.

La detección de la marca de agua es formulada como el detector de maxima verosimilitud (8), lo que indica que el patrón de salida d_l para el detector basado en el vector HMM es aquel con el mayor valor de probabilidad logarítmica.

$$\ln \frac{f_x(T_z^t - a^t \cdot d_l | \theta)}{f_x(T_z^t - a^t \cdot d_m | \theta)} > 0, \quad \forall m \neq l \quad (8)$$


3.5 Inicialización del aprendizaje del modelo

El modelo es inicializado por medio de un algoritmo presentado por Fan and Xia, 2000, el cual consta de dos pasos que permite un cálculo más eficiente y exacto de los parámetros del model HMT. Se utiliza esta inicialización dado que ésta afecta la velocidad de convergencia y el resultado del entrenamiento de las iteraciones EM.

En el primer paso, se determinan estadísticas locales de los coeficientes wavelet en distintas escalas, dado que se asume que los coeficientes en la misma escala tienen la misma densidad. El segundo paso sirve para proveer las probabilidades de transición inicial $\epsilon_{j,j+1}^{m,n}$ entre dos escalas vecinas. Al terminar ambos pasos, se utiliza el algoritmo EM con este punto inicial θ^0 .

4 Experimentos y resultados

Como experimento se insertó la marca de agua en la figura 4(a), cuya representación en bits se presenta en la figura 4(b). La marca de agua consta de 64 bits, y como se realiza un mapeo directo, existe un vector que no sufre mas que 4 alteraciones. Por esta razón, la marca de agua es complementada, después de haber sido mapeada, con -1's, hasta llegar a un múltiplo de 15.



(a) Imagen de la marca de agua

(b) Representación en bits

Fig. 4: Marca de agua con su correspondiente representación en bits.

Para realizar los experimentos, se consideró la imagen de Lena de 512×512 en escala de grises (ver figura 5(a)) y la imagen modificada después de insertar la marca de agua se muestra en la figura 5(b).

Para determinar la degradación de la imagen modificada por la marca de agua con respecto a la original, se aplicó las métricas PSNR y MSE, obteniendo que $MSE = 0.0142$ y $PSNR = 66.6018$ db. Al aumentar la iluminación se pudo recuperar un 88 % de la marca de agua, ecualizar el histograma de la imagen, se recuperó 85% de la marca de agua y al realizar compresión se pudo recuperar un 80%.

(a) Imagen de Lena original, 512×512 

(b) Imagen de Lena modificada

Fig. 5: Imagen de Lena original y modificada

En la figura 6(a), se muestra una imagen médica de 256×256 utilizada con su correspondiente transformación wavelet de 4 niveles en la figura 6(b). La imagen utilizada pertenece al trabajo MRI Brain Segmentation de Robert Bemis⁴.


Como se puede apreciar en la figura 6(a), la imagen médica puede ser recortada por el extremo izquierdo, derecho o superior (*cropping*) y ser colocada en otro fondo negro y no se tendría ninguna alteración visible.

Esta imagen, obtuvo un $MSE = 0.0569$ y $PSNR = 60.5812$. Al aumentar la iluminación se pudo recuperar un 95 % de la marca de agua, ecualizar el histograma de la imagen, se recuperó 89% de la marca de agua y al realizar compresión se pudo recuperar un 87%.


5 Conclusiones y trabajo futuro

El uso de modelos de Markov permite tener un esquema de marca de agua robusto ante ciertos ataques, como el cambio de brillo, contraste y compresión. Dado que los nodos padres son seleccionados por medio de una llave, es posible que mucha información sobre la marca de agua sea insertada en regiones que puedan ser removidas sin alterar la región de interés. Tales ataques pueden ser de *cropping* o *segmentación*.

⁴<http://www.mathworks.com/matlabcentral/fileexchange/4879>



(a) Imagen I0000466_anon.dcm



(b) Transformada wavelet de 4 niveles

Fig. 6: Imagen con su correspondiente transformada wavelet

Se puede obtener un mayor porcentaje en la recuperación de la marca de agua, si se aplican códigos correctores de errores como códigos convolucionales. Como trabajo futuro se plantea comparar este método con el detector de correlación, así como el considerar insertar la marca de agua en ciertas regiones de la imagen médica, que de acuerdo al sistema visual humano, el alterarlas no afectaría un diagnóstico médico, pero que el removerla sí.

References

- Coatrieux, G et al. (2000). “Relevance of watermarking in medical images”. In: *in Workshop of the Int. Telemedical Information Soc., IEEE EMBS Int. Conf. Information Technology Applications in Biomedicine*, pp. 250–255.
- Crouse, M S, R D Nowak, and R G Baraniuk (1998). “Wavelet-Based Statistical Signal Processing Using Hidden Markov Models”. In: *IEEE Trans. Signal Processing* 46, pp. 886–902.
- Dreyer, Keith J. et al. (2005). *PACS: A Guide to the Digital Revolution*. USA: Springer-Verlag, p. 579. ISBN: 0-38726-010-2.
- Elbasi, Ersin (2010). “Robust multimedia watermarking: Hidden Markov Model approach for video sequences”. In: *Turk. J. Elec. Eng. and Comp. Sci.* 18.2, pp. 147–158. ISSN: 1300-0632.
- Fan, Guoliang and Xiang-Gen Xia (2000). “Wavelet-Based Statistical Image Processing Using Hidden Markov Models”. In: *34th Annual Conference on Information Sciences and Systems*. USA.

- Lewis, A. S. and G. Knowles (1992). “Image Compression using 2-D Wavelet Transform”. In: *IEEE Transactions on Image Processing*. Vol. 1. 2, pp. 244–250.
- Lin, Wei-Hung et al. (2009). “A blind watermarking method using maximum wavelet coefficient quantization”. In: *Expert Systems with Applications* 36.9, pp. 11509–11516. ISSN: 0957-4174. DOI: DOI:10.1016/j.eswa.2009.03.060.
- Ni, Jiangqun et al. (2005a). “A Robust Multi-bit Image Watermarking Algorithm based on HMM in Wavelet Domain”. In: *Int. Workshop on Digital Watermarking*. Ed. by Springer-Verlag. Lectures Notes in Computer Science 3710. Siena, Italy, pp. 110–123.
- Ni, Jiangqun et al. (2005b). “A RST-Invariant Robust DWT-HMM Watermarking Algorithm Incorporating Zernike Moments and Template”. In: *KES (1)*. Ed. by Rajiv Khosla, Robert J. Howlett, and Lakhmi C. Jain. Vol. 3681. Lecture Notes in Computer Science. Springer, pp. 1233–1239. ISBN: 3-540-28894-5.
- Pianykh, Oleg S. (2008). *Digital Imaging and Communications in Medicine (DICOM): A Practical Introduction and Survival Guide*. USA: Springer-Verlag, p. 384. ISBN: 3-54074-570-X.
- Puech, W. and J. M. Rodrigues (2004). “A new crypto-watermarking method for medical images safe transfer”. In: *12th European Signal Processing Conference*, pp. 1481–1484. ISBN: 3-200-00148-8.
- Romberg, Justin K., Richard G. Baraniuk, and Hyeokho Choi (2001). “Bayesian tree-structured image modeling using wavelet-domain hidden Markov models”. In: *IEEE Transactions on Image Processing*. Vol. 10. 7, pp. 1056–1068.
- Salomon, David (2007). *Data Compression: The Complete Reference*. With contributions by Giovanni Motta and David Bryant. USA: Springer-Verlag, pp. xxv + 1092. ISBN: 1-84628-602-6.
- Yang, Gloria Y. et al. (1997). “Visibility of Wavelet Quantization Noise”. In: *IEEE Transactions on Image Processing*. Vol. 6. 8, pp. 1164–1175.