

TecnoLógicas

Tecno Lógicas

ISSN: 0123-7799

tecnologicas@itm.edu.co

Instituto Tecnológico Metropolitano
Colombia

Muñoz-Bedoya, Luis A.; Mendoza, Luis E.; Velandia-Villamizar, Hernando J.
Segmentación de Imágenes de Resonancia Magnética IRM utilizando LS-SVM y Análisis
Multiresolución Wavelet
Tecno Lógicas, octubre, 2013, pp. 681-693
Instituto Tecnológico Metropolitano
Medellín, Colombia

Disponible en: <http://www.redalyc.org/articulo.oa?id=344234341052>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica
Red de Revistas Científicas de América Latina, el Caribe, España y Portugal
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto

Segmentación de Imágenes de Resonancia Magnética IRM utilizando LS-SVM y Análisis Multiresolución Wavelet

Segmentation of Magnetic Resonance Imaging MRI using LS-SVM and Wavelet Multiresolution Analysis

Luis A. Muñoz-Bedoya¹

Luis E. Mendoza²

Hernando J. Velandia-Villamizar³

-
- 1 Ing. Telecomunicaciones, DIEEST, Universidad de Pamplona, Pamplona-Colombia
luislamb99@unipamplona.edu.co
 - 2 Ing. Telecomunicaciones, DIEEST, Universidad de Pamplona, Pamplona-Colombia
luis.mendoza@unipamplona.edu.co
 - 3 Ing. Telecomunicaciones, DIEEST, Universidad de Pamplona, Pamplona-Colombia
hernando.velandia@unipamplona.edu.co

Resumen

Actualmente, las máquinas de soporte vectorial (SVM) se han convertido en una herramienta poderosa para resolver problemas de clasificación no lineal. Para la optimización de esta herramienta, se ha desarrollado una reformulación conocida como LS-SVM (máquina de soporte vectorial de mínimos cuadrados), la cual trabaja con un modelo de minimización basada en funciones y polinomios de Lagrange. Por lo tanto, este trabajo presenta un método para la segmentación de imágenes de resonancia magnética específicamente para estudiar la morfología de los pulmones y lograr la cuantificación de características relevantes en dichas imágenes usando SVM y LS-SVM. Adicionalmente a la técnica de clasificación, en este trabajo se usaron técnicas como: análisis Wavelet para eliminación de información no relevante (compresión), y algoritmos Splines, para interpolar la información encontrada y cuantificar las características, que se basaron en el reconocimiento de área, forma y estructuras anormales presentes en la zona pulmonar de dichas imágenes.

Palabras clave

Kernel; LS-SVM; optimización; segmentación; wavelet madre.

Abstract

Currently, support vector machines (SVM) have become a powerful tool to solve nonlinear classification problems. For the optimization of the tool, has developed a reformulation known as LS-SVM (Support Vector Machine least squares), which works with a model based on function minimization and Lagrange polynomials. Therefore, this paper presents a method for segmentation of magnetic resonance images specifically to study the morphology of the lungs and reach the quantification of relevant features in these images using SVM and LS-SVM. In addition to sorting technique in this work using techniques such as wavelet analysis to eliminate irrelevant information (compression) and Splines algorithms to interpolate the information found and quantify the characteristics, which in this work were based on the recognition area, shape and abnormal structures present in the lung of these images.

Keywords

Kernel; LS-SVM; optimization; segmentation; mother wavelet.

1. INTRODUCCIÓN

La adquisición de imágenes por resonancia magnética (IRM), es una técnica no invasiva que utiliza el fenómeno de la resonancia magnética para obtener información detallada sobre la estructura y composición del cuerpo (Gili & Capdevila 2006). La IRM, es utilizada en la actualidad, principalmente en medicina para observar alteraciones en los tejidos y detectar cáncer y otras patologías. La tarea de reconocimiento de patrones en imágenes, requiere de aprendizaje y de funciones apropiadas de clasificación, que asignen un determinado parámetro de entrada que por lo general es representado con un vector que contiene los atributos de cada una de las clases. Además de ello, se deben tener en cuenta otras características como lo son: el tiempo necesario de aprendizaje del algoritmo de clasificación y el número necesario de muestras para el aprendizaje. Todo esto es debido a la característica no estacionaria que poseen las imágenes de resonancia magnética.

En las últimas décadas, se han desarrollado una gran cantidad de técnicas para segmentación y reconocimiento de áreas en imágenes basadas en algoritmos genéticos, modelos dinámicos, redes neuronales, máquinas de soporte vectorial (SVM), entre otros (Hsu, C. W., Chang, C. C., & Lin, C. J. 2003). De acuerdo con lo anterior, una de las técnicas que da mejores resultados y que me puede mejorar la precisión en la clasificación corresponde a la SVM, la cual está basada en problemas de minimización con aprendizaje estadístico.

La máquina de soporte vectorial es una técnica de clasificación prometedora. Fue propuesta por Vapnik (Cortes & Vapnik, 1995). Esta técnica es capaz de separar clases mediante un hiperplano de clasificación óptimo; si en su espacio original no se cumple esta condición, se utilizan funciones Kernel, las cuales buscan un hiperplano óptimo en dimensiones mucho mayores. En este trabajo, se introduce una variación a la SVM, descrita por una versión de mínimos cuadrados (LS-SVM). Allí, la clasificación se interpreta como un problema de regresión con valores de clasificación entre 1 y -1 (Suykens, 2002).

Un aspecto relevante en la utilización de SVM, es la extracción de características para la realización de entrenamiento de la má-

quina. Dicha selección de características, ha llegado a ser el enfoque de muchas investigaciones en diferentes áreas de aplicación. Una vez ha sido seleccionada la información relevante y realizado un tratamiento apropiado para la extracción de características, puede mejorar la eficiencia y desempeño en la clasificación. (Lui & Motoda 1998) indican que el efecto de selección de características mejora el rendimiento (velocidad de aprendizaje, exactitud de predicción, o reglas de simplicidad) mediante visualización del modelo de selección de los datos, eliminación de ruido y reducción de dimensionalidad. Y es en esta última característica, donde el Análisis Wavelet se convierte en una herramienta potencial, a la hora de optimizar la segmentación de imágenes, ya que a partir de ella se puede obtener una disminución significativa en el tiempo de aprendizaje del algoritmo de clasificación mediante SVM, así como un mejoramiento en la precisión de la clasificación. El Análisis Wavelet provee un método para la compresión de un esquema de umbralización, disminuyendo la cantidad de información en la imagen, a través de la anulación de los valores de los coeficientes wavelet anterior a la reconstrucción.

1.1 LS-SVM

Las máquinas de soporte vectorial (SVM), han demostrado ser muy eficaces en muchos problemas de clasificación. Para una clasificación de clases binarias, la SVM construye el hiperplano de separación óptima entre ambas clases con el margen máximo. La formulación de mínimos cuadrados (LS-SVM), recientemente propuesta (J Vandevale, 2004) solo implica las restricciones de igualdad. Por tanto el hiperplano óptimo se puede obtener mediante la solución de ecuaciones lineales (del orden del número de ejemplos de entrenamiento). Asumiendo que tiene:

$$(x_i, y_i)_{i=1}^N \quad (1)$$

Donde, N contiene el número de muestras de la señal original, el conjunto (x_i, y_i) representa $x_i \in R^n$, $y_i \in \{-1, +1\}$ y el objetivo es estimación de una función f o el hiperplano de clasificación. Básicamente,

camente, se define un espacio de N-dimensiones con una función de activación:

$$\varphi = [\varphi_1, \varphi_2, \dots, \varphi_N]^2 \quad (2)$$

El modelo LS-SVM se puede expresar de la siguiente forma:

$$\hat{f}(x) = w^T * \varphi(x) + b \quad (3)$$

Aquí, w es el ancho del vector y b es la variable de desplazamiento. Entonces, el problema de optimización es el siguiente:

$$\min J(w, e) = \frac{\mu}{2} w^T * w + \frac{\gamma}{2} \sum_{i=1}^N \epsilon_i^2 \quad (4)$$

Así que,

$$\begin{aligned} y(i) &= w^T \varphi^T(x) \varphi(x_i, y_i) + b + \epsilon(i) \\ i &= 1, \dots, N \end{aligned} \quad (5)$$

Donde la variable de holgura esta denotada por (i) . Además (μ, γ) son los hiperparametros que controla la compensación entre la suavidad de la función y la exactitud de la forma. Este problema de optimización conduce la siguiente solución:

$$\hat{f}(x) = \sum_{i=1}^N \alpha_i K(x, x_i) = \varphi^T(x) \varphi(x_i) \quad (6)$$

De manera que α_i son los coeficientes y el valor de $K(x, x_i) = \varphi^T(x) \varphi(x_i)$ es el kernel.

1.2 Transformada Wavelet

La transformada Wavelet (TW) es una herramienta matemática que permite el estudio de series temporales no estacionarias gracias a su análisis multi-resolución que proporciona simultáneamente información temporal y espectral de las mismas.

El análisis de imágenes mediante Transformada Wavelet descompone la imagen en versiones trasladadas (en tiempo) y escaladas de la Wavelet original, la que es más conocida como Wavelet Madre, de las cuales las más utilizadas para procesamiento digital de señales, se encuentran la Wavelet Haar, Daubechies, Mexican Hat, Symmlet, Coiflet entre otras (Mallat, 1999). Entonces, dada una función $s(t)$, la transformada Wavelet $W_\psi s(a, b)$ esta descrita como:

$$W_\psi s(a, b) = \int_{-\infty}^{\infty} s(t) \Psi_{a,b}(t) dt \quad (7)$$

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \left(\frac{t-b}{a} \right) \quad (8)$$

Donde (8) describe la Wavelet Madre utilizada. (D'Atellis & Fernandez 1992), siendo a y b los parámetros de escala y translación y $s(t)$ se define como la señal original. La aplicación principal en la cual se ha utilizado el Análisis Wavelet corresponde a la compresión de imágenes, donde apoyado del teorema de disminución de muestras (downsampling), reduce la tasa de muestreo en la imagen, generando así una disminución notable de resolución. La codificación wavelet se basa en la idea de que los coeficientes obtenidos mediante la TW, que representan los pixeles de una imagen pueden codificarse en forma más eficiente que los pixeles originales (Celeste 2005). Si la wavelet se utilizada como base, se puede concentrar la mayoría de la información visualmente importante en unos pocos coeficientes. Los coeficientes restantes pueden umbralizarse y tomar un valor de cero, con una pequeña distorsión de la imagen. Este análisis consiste en descomponer una imagen en una serie de aproximaciones y detalles organizados jerárquicamente en niveles.

2. METODOLOGÍA

A continuación se va a mostrar la metodología utilizada en este trabajo.

2.1 Selección y Adecuación de Características

Se utilizaron 26 IRM que poseen una dimensión de $[m,n]$, donde $m=n=512$, de las cuales 20 de ellas se usaron para el entrenamiento de la herramienta de clasificación y las 6 restantes se usaron para la validación del algoritmo diseñado. Las imágenes procesadas fueron obtenidas en el Grupo de Ingeniería Biomédica de la Universidad de los Andes GIBULA, Mérida Venezuela. Para mejorar el tiempo de ejecución del algoritmo de clasificación, se recurrió al Análisis Wavelet enfocado a la extracción de la data de entrenamiento para la SVM, específicamente en lo que se refiere a la eliminación de ruido y compresión de las imágenes tratadas. Esto con el propósito de realizar una disminución significativa en el tiempo de aprendizaje y clasificación de la SVM, y de esta misma forma un mejoramiento en la precisión de la clasificación.

Para que el resultado del proceso de compresión sea satisfactorio deben tenerse en cuenta dos aspectos muy importantes: la función wavelet a utilizar, el nivel de descomposición.

Función wavelet: La familia de wavelets elegida afecta tanto al diseño como a la performance del sistema de compresión, y depende de la imagen a analizar. Las funciones más utilizadas son Daubechies y Biortogonales, debido a su número de momentos nulos y al suavizado de la reconstrucción.

Nivel de descomposición: El número de operaciones de filtrado depende del nivel de descomposición, por este motivo debe tenerse cuidado en la determinación de este parámetro. Por otro lado, la elección de un nivel demasiado alto puede llevar a inconvenientes en la reconstrucción debido a la cuantización en los detalles. Los parámetros que presentaron mejores resultados se dieron utilizando la Familia wavelet db5, con 3 niveles de descomposición, siendo estos comparados con la wavelet madre bior2.4 con 2 y 3 niveles de descomposición.

2.2 Selección de Funciones Kernel

Aunque el enfoque de la LS-SVM con una función Kernel es usada para clasificación (Cortes & Vapnik, 1995), este rendimiento debe ser mejorado especialmente en data compleja donde se re-

quiere ajustar el máximo margen del hiperplano óptimo de clasificación. Esto es particularmente importante cuando se desarrollan aplicaciones en las cuales se debe obtener un alto nivel de precisión como lo es el diagnóstico médico.

De acuerdo a esto se debe escoger de manera precisa la función Kernel a utilizar al momento de la clasificación. Las más utilizadas para clasificación en LS-SVM son Polinomial, Función de Base Radial (RBF), Combinada. En este trabajo se utilizó la RBF gracias a que me genera una respuesta finita localizada sobre el eje real x . La Función RBF esta descrita por:

$$k_G = k(x_i, x') = \exp \left(-\frac{1}{\gamma} \|x_i - x'\|^2 \right) \quad (9)$$

De donde $k(x_i, x')$ es el Kernel continuo simétrico que se define en el intervalo cerrado $a \leq x_i \leq b$ asimismo para x', γ determinará el área de influencia que el vector tiene sobre el espacio de datos.

2.3 Afinación de Hiperparámetros

La selección de los Hiperparámetros óptimos en las máquinas de soporte vectorial es un paso importante en el diseño de la LS-SVM. En este caso dicha selección se realizó mediante una estimación y minimización del error generalizado dando como resultado $\gamma = 2.8$ y $\sigma^2 = 1$.

2.4 Simulación y Validación de LS-SVM

Para la realización de este procedimiento se deben tener una serie de pasos que se describen a continuación:

Paso1: Seleccionamos las imágenes que utilizaremos para entrenamiento y clasificación, y las ubicamos en directorios diferentes.

Paso2: Comprimimos las imágenes mediante análisis Wavelet generando así nuevas imágenes con dimensiones de $[m \times n]$ con $m=n=128$.

Paso3: En cada una de las imágenes comprimidas y que pertenecen al tipo entrenamiento, debemos escoger las zonas que

visualmente hacen parte del contorno y las que no. En el trabajo se escogieron 10 zonas de contorno (contornos) y 35 fuera de contorno (fondos). Cada zona contiene una matriz de $[m,n]$ con $m=n=13$.

Paso4: Se vectorizan las matrices de las zonas obtenidas para cada imagen, generando un vector fila. Luego de ello todos estos vectores se concatenan en una matriz la cual va a ser mi data de entrenamiento $X(i,j)$, donde i lo da el tamaño de la máscara y j almacena el número de fondos + número de contornos seleccionados. Para nuestro caso $i=900, j=81$.

Paso5: Se crea un vector de etiquetas Y , el cual debe tener el mismo tamaño que el número de filas de la matriz de entrenamiento $i=900$, y debe ser un vector columna, en cada posición de este vector se debe almacenar el valor de 1 o -1, que va en relación con la información de la matriz en la misma posición de fila. Si la matriz en la posición $X(i,:)$ almacena información de una zona de contorno, el valor del $y(i)=1$, de lo contrario $y(i)=-1$.

Paso6: Ahora procedemos a entrenar la LS-SVM con la información generada. Allí se debe incluir los Hiperparametros óptimos, el tipo de Función Kernel a utilizar, la data de entrenamiento, el vector de etiquetas y los valores de gamma, sigma cuadrado. De este entrenamiento se generan 2 parámetros $[\alpha, \beta]$.

Paso7: Estos parámetros $[\alpha, \beta]$ son los que se utilizan a la hora de clasificación. Para ello cargamos una imagen seleccionada en el grupo de clasificación, y ejecutamos la simulación de la LS-SVM. Dicha simulación me genera una variable Y_{test} , el cual toma valores de 1 o -1. En caso de que el valor de Y_{test} sea de 1, guardamos el valor de la fila y la columna en una matriz bidimensional.

Paso8: Sobre la imagen utilizada en la simulación, plotamos los puntos almacenados en la matriz y los cuales se graficaran sobre la imagen y en el contorno a reconocer.

Paso9: Realizamos una interpolación entre los puntos graficados obteniendo como resultado el contorno de la zona que en un principio hace parte del contorno.

Debe especificarse el nombre de la institución a la cual está afiliado el autor y la dirección de correo electrónico. En el caso de autores afiliados a universidades, el nombre de la unidad académica.

mica, escuela o departamento debe ir seguido del nombre de la universidad. En el caso de autores afiliados a empresas, debe darse primero el nombre del departamento, división o sección, seguido del nombre de la empresa. Las afiliaciones se listan precedidas por el número que fue insertado como superíndice al final del apellido de cada autor.

3. RESULTADOS

En la Fig. 1a, se muestra una de las imágenes originales la cual tiene una dimensión $[m,n]$, donde $m = n = 512$. En la Fig. 1b, se muestra el resultado de la compresión de la imagen original mediante la TW. Obsérvese como la imagen conserva las características de la imagen original quedando con un tamaño de $[m,n]$ donde $m=n=128$.




Fig. 1. a) Imagen Original, b) Imagen comprimida

El proceso de ajuste de hiperparámetros para el correcto reconocimiento del contorno se puede observar claramente en la Fig. 2. La clasificación observada en la Fig. 2a. tiene poca exactitud y suavidad a la hora de ubicar los puntos sobre el contorno. La correcta variación de los hiperparámetros me permite lograr una mejoría en la exactitud del hiperplano de clasificación, visualizado en la Fig. 2b. Finalmente, en la Fig. 2c. se observa cómo se han ajustado los hiperparámetros que han minimizado el error, consiguiendo así un equilibrio entre la exactitud y precisión del hiper-

plano óptimo de clasificación y permitiendo de esta forma lograr una ubicación exacta de los puntos sobre el contorno. Finalmente se realiza un spline sobre los puntos ubicados en la imagen, como se puede observar en la Fig. 3a.




Fig. 2. Evolución de la clasificación mediante ajuste de hiperparámetros




Fig. 3. a) Spline sobre imagen clasificada b) Spline mejorado sobre imagen clasificada

En la Fig. 3b se aplica un spline cubico sobre los puntos aumentando así la segmentación en la IRM. En la actualidad, nos encontramos trabajando en la afinación máxima de los hiperparámetros, para de esta forma obtener un porcentaje de exactitud mayor, ya que imágenes biológicas de este tipo lo requieren.

4. CONCLUSIONES

El análisis Wavelet permitió optimizar el tiempo de ejecución del algoritmo en aproximadamente un 500% ya que se pasó de un resultado de clasificación después de 56 horas a un resultado de clasificación en 50 minutos, esto debido a la reducción de costo computacional producto de la compresión de datos en la IRM. Inicialmente wavelet se utilizó para filtrar, siendo la compresión su mayor utilidad en el desarrollo de este trabajo.

Según los resultados obtenidos, se observa el buen desempeño que realiza la LS-SVM para segmentar de manera satisfactoria una región en la IRM, mostrando así la potencialidad de las LS-SVM a la hora de realizar clasificación en imágenes médicas. Los resultados de este trabajo son preliminares en su conjunto para la segmentación de este tipo de imágenes IRM. Además son prometedores y sugieren que este enfoque puede ser aplicado de una manera más amplia a la tarea de categorización de imágenes médicas. Sin embargo, es necesario llevar a cabo más experimentos con mayor número y variedad de imágenes de IRM. Igualmente, en trabajos futuros se planea validar la eficacia de esta técnica con otro tipo de algoritmos para segmentación de imágenes como lo son contornos activos.

5. REFERENCIAS

- Celeste Gómez Carolina (2005). Compresión de imágenes con pérdidas. Método de la Transformada Wavelet. Madrid.
- Cortes, C & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
- Clymer, J. R. (1992). "Discrete Event Fuzzy Airport Control". *IEEE Trans. On Systems, Man, and Cybernetics*, Vol. 22, No. 2.
- D'Atellis, E. Fernandez B. (1992) *Wavelet Theory and Harmonic Analysis in Applied Sciences*, Birkhauser, Boston.
- Gili. Planas. J., & Capdevila. Cirera. A. (1996). *Resonancia Magnética de Imágenes*. Barcelona: Centro de Diagnóstico Predalbes, 52-8.
- Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). A practical guide to support vector classification. Available at: <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide>.

- Liu, H., & Motoda, H. (1998). Feature selection of knowledge discovery and data mining. Norwell, MA: Kluwer Academic.
- Mallat. (1999). Wavelet bases. A wavelet tour of signal processing, pp. 220-320.
- Suykens, T. Van Gestel, J. De Brabanter, B. De Moor y J. Vandewalle (2002). Least SquaresSupport Vector Machines, World Scientific Publishing Co., Singapore.
- Vandewalla (2004). Benchmarking. Least squares support vector machine classifiers. Machine Learning, 54(1):5-32.