

# Pattern classification of brain tissues for navigation in telemedicine systems

Marco Javier Suarez Baron<sup>1</sup>, Carlos Andrés Cifuentes<sup>2</sup>, Luis Eduardo Rodriguez<sup>3</sup>, Juan Carlos Suarez Barón<sup>4</sup>

**Abstract**— This paper shows a multi-classification model of brain tissue in a simulation stage magnetic resonance imaging (MRI). Its purpose is to improve the quantification of brain pathologies and the planning of neurosurgeries. This paper shows the development and evaluation of the multi-class classification methods one-versus-one (1-v-1) and one-versus-all (1-v-r), based on support vector machines, selecting four classes of brain tissues in the sequences T1, T2, and DP (multispectral) MRI. The classified tissues were gray matter, white matter, cerebrospinal fluid (CSF) and a group of tissues called ‘the rest’, composed of bone, skin, muscle, fat, connective tissue and background. Finally, the performance of the classifier on different MRI slices was evaluated and showed an accuracy rate of 99.01 % using the one-versus-one model, and an average of 96.65% using the one-versus-all model”.

**Index Terms**— Magnetic Resonance Imaging (MRI), Support Vector Machines, Brain Tissue.

## I. INTRODUCCION

La clasificación de tejidos cerebrales es usada en investigaciones y estudios clínicos en el área de neurología para el seguimiento y cuantificación de patologías como: accidentes cerebrovasculares, edema cerebral, tumores, enfermedades degenerativas como Parkinson o Alzheimer (Ramani, Jensen, & Joseph A. Helpert, 2010); otra aplicación tiene lugar en el campo de la neurocirugía ya sea convencional o teleasistida por robots como: NeruoArm que es compatible que necesitan contar con la estructura detallada de la anatomía general del paciente, indicación de patologías claras, información geométrica para la planeación preoperatoria y la generación de modelos anatómicos virtuales para la navegación en sistemas de cirugía asistida por robots a distancia (telecirugía). El sistema de telecirugía fue avalado en Estados Unidos desde julio del 2000 por la *Food and Drug Administration* (FDA) (W.S. Melvin, 2012), técnicamente no

<sup>1</sup> Profesor Asociado, Escuela Colombiana de Carreras Industriales ECCI, Bogotá, Colombia, msuarezb@ecc.edu.co

<sup>2</sup> Investigador Asistente, Universidad Federal Espitu, Vitoria, Brasil, cacifuentes@gmail.com

<sup>3</sup> Profesor Titular, Escuela Colombiana de Ingeniería ECCI, Bogotá, Colombia, luis.rodriguez@escuelaing.edu.co

<sup>4</sup> Asistente de investigación, Escuela Colombiana de Carreras Industriales ECCI, Bogotá, Colombia, suarez.juan@ecc.edu.co

son robots cirujanos sino instrumentos telemanipulados por un cirujano; compuestos por brazos articulados controlados desde una consola que dispone de una cámara de alta definición en imágenes tridimensionales (S.L Lee, 2010).

El hospital universitario de Johns Hopkins, en Baltimore, ha desarrollado un sistema integrado para la planificación, navegación y asistencia de robots en cirugías de base del cráneo; en la planificación la zona de perforación se define mediante una tomografía preoperatoria, este procedimiento presenta una desviación en el corte planificado de 0.6 mm que es clínicamente inaceptable, por lo cual se requiere mayor precisión en el análisis digital de imágenes pre operatorias (Tian Xia, 2011).

En Southwestern Medical Center de la Universidad de Texas, la radiación quirúrgica de tumores cerebrales asistida por robots demanda de precisión geométrica en la planeación, para minimizar el riesgo de toxicidad en tejidos sanos, esto puede lograrse a partir de la clasificación automática de tejidos cerebrales con altas tasas de acierto (C.A. Giller, 2012), El Instituto Nacional de Neurociencias de Singapur plantea en la fase de planeación, el uso del procesamiento digital de imágenes para establecer la precisión en el posicionamiento y la trayectoria de la intervención tele asistida (Chan, y otros, 2009) (Chauhan, Tan, Seet, & Ng, 2010 ). Actualmente las pruebas de estos sistemas se han realizado con cadáveres o con perros buscando exactitud en la planificación quirúrgica (Tian Xia, 2009) (Chan, y otros, 2009) (Chauhan, Tan, Seet, & Ng, 2010 ); y es precisamente donde la clasificación automática de tejidos cerebrales puede brindar herramientas para obtener precisión en el corte, proteger y prevenir el daño del sistema neurovascular, y mejorar todos aquellos aspectos que permitan el avance científico de las intervenciones quirúrgicas en mención. Comúnmente en el análisis y procesamiento digital de imágenes médicas se encuentran técnicas de clasificación de tejidos cerebrales como *K-means* (Yong Fan, 2007)], *Fuzzy C-means* (FCM) (Bazin & Dzung L. Pham, 2007), *K-Nearest Neighbor* (KNN) (Petronella Anbeek, Bochove, Osch, & Grond, 2005), *Markov Random Fields* (MRF), *Partial Volume Estimation* (PVE) (Jahyun J. Koo, 2007), estas son solo algunas técnicas de clasificación, el desarrollo de estos trabajos generalmente se realiza sobre una sola secuencia de IRM iniciando con la extracción de la corteza craneal para eliminar su interferencia en la clasificación (Yong Fan, 2007) (Petronella Anbeek, Bochove, Osch, & Grond, 2005), la clasificación de los tejidos cerebrales en IRM se origina a partir de: a) diferentes intensidades de la imagen, b) modelamiento espacial, y/o c) estimaciones volumétricas; estos clasificadores presentan un costoso entrenamiento y manejan múltiples mínimos locales

(Alba Castro, 2009). Una de las técnicas más usadas es máquinas de soporte vectorial (SVM, por sus siglas en inglés), basada en la teoría del aprendizaje estadístico (Cortes & Vapnik, 1995) [9], en sus inicios esta técnica fue desarrollada para problemas binarios y posteriormente fue extendida a problemas multi-clase (Hsu & Lin) (Smola, 2009).

Las SVM permiten conseguir una solución óptima a un problema de clasificación con un tamaño pequeño de muestras, del cual se obtendrá una solución global no sólo para superar el problema de múltiples mínimos locales, sino también por transformar el problema a un espacio de características de alta dimensión y hacer una discriminación no lineal en el espacio original. Este método de clasificación ha presentado un mejor desempeño comparado con otros métodos clásicos del mismo orden (Guo, Liu, Wu, Yan, & Shen, 2007).

En la clasificación con SVM se asume un conjunto de etiquetas de entrenamiento  $(x_i, y_i)$ ,  $i = 1, \dots, l$  donde  $x_i \in \mathbb{R}^N$  y  $y_i \in \{-1, 1\}$ , que puede ser separado por un hiperplano  $h(x) = (w \cdot x) + b = 0$ . Para el caso lineal, se construye un hiperplano que separe las dos clases, de tal forma que el margen ( $\gamma$ ) será la máxima distancia entre el hiperplano óptimo y el patrón de entrenamiento más cercano (vectores de soporte), este problema puede ser descrito como (Eq. 1):

$$\begin{cases} \min_{w, b} \frac{1}{2} \|w\|^2 \\ s. a. \sum_i y_i ((w \cdot x_i) + b) \geq 1 \end{cases} \quad (1)$$

En el caso no lineal se introduce el espacio de entrada en otro de mayor dimensión, a fin de obtener un nuevo mapeo de los datos y poder usar un clasificador lineal. En términos matemáticos se introducen en la ecuación 1 variables *non-negative*  $\xi_i \geq 0$  y  $\gamma_i$  y un parámetro Coste (C), esto se expresa como (Eq.2):

$$\begin{cases} \min_{w, b, \xi_i} \frac{1}{2} \|w\|^2 + C \sum_i \xi_i \\ s. a. \sum_i y_i ((w \cdot x_i) + b) \geq 1 - \xi_i \\ \xi_i \geq 0 \forall_i \end{cases} \quad (2)$$

Los clasificadores SVM multi-clase son la combinación de varios clasificadores binarios, aunque existen muchas formas de combinar estos clasificadores, en este trabajo sólo se utiliza los métodos 1-v-1 y 1-v-r, en el primer método se construyen  $(k*(k-1)/2)$  clasificadores binarios donde k es el número de clases, luego se usa una estrategia de votación para cada clasificador binario, y se toma la clase con mayor número de votos (Hsu & Lin) (Smola, 2009). Para el método 1-v-r se construyen k modelos binarios, asignando etiquetas positivas a las muestras de la clase i-ésima y etiquetas negativas a las clases restantes, donde cada función clasificadora parcial  $f_i$  enfrenta los vectores de la clase  $\theta_i$  contra el resto de clases  $(k-1)$ .

El método desarrollado se fundamenta en las SVM y utiliza las técnicas multiclase 1-v-1 y 1-v-r, se presenta un modelo para la clasificación de cuatro clases de tejidos cerebrales a

partir de las diferentes intensidades de las IRM: materia gris (MG), materia blanca (MB), líquido cefalorraquídeo (LCR) y un conjunto denominado "resto" conformado por: fondo de la imagen, musculo, piel, grasa, conectivo y hueso. La clasificación de tejidos cerebrales de IRM se realiza en las tres secuencias: T1 (tiempo de relajación longitudinal), T2 (tiempo de relajación transversal), DP (densidad protónica), y no se realiza la extracción de la corteza craneal sobre estas imágenes. Esta publicación presenta un estudio de imágenes de Resonancia Magnética, basado en el clasificador SVM; la primera explica el clasificador, el método a utilizar, en esta sección también introducimos características de las imágenes y la base de datos para evaluar el clasificador escogido y diseñado. En la segunda sección se presentan los resultados de los métodos 1-v-1 y 1-v-r. En la siguiente sección se analizan y discuten los resultados obtenidos, donde se establecen las contribuciones, limitaciones, y por último los lineamientos futuros de esta investigación.

## II. MATERIALES Y MÉTODOS

Para este proyecto todos los algoritmos se programaron en *Matlab*®, que se complementaron con la librería *LIBSVM* para las SVM (Chih-Jen, Chih-Chung, & Lin, 2009); la base de datos de IRM se tomó del simulador *BRAINWEB* del laboratorio BIC (Brain Imagin Center- Montreal Neurology Institute-McGill, 2006). En esta base de datos del cerebro se pueden fijar tres secuencias distintas (T1, T2, DP), 5 espesores de corte, 6 niveles de ruido y 3 niveles de falta de homogeneidad, también se pueden solicitar simulaciones personalizadas con parámetros distintos y descargar los datos del modelo anatómico cerebral. En el sitio *BRAINWEB* se pueden visualizar en escala de grises o *hot metal* los diferentes cortes de las imágenes de RM o descargarlas en el formato MNC (.mnc), el cual es un formato volumétrico, dispuesto de la siguiente manera 181, 217, 181, en los planos X, Y, Z, (axial, coronal, sagital). El presente trabajo se desarrolló en tres etapas así: Selección de datos de entrenamiento, Diseño del clasificador y Evaluación.

### A. Selección de datos de entrenamiento

Para los datos de entrenamiento de las SVMs se tomó el modelo anatómico de *BRAINWEB*, el cual es un modelo difuso basado en Fuzzy C-Means con correcciones manuales realizadas por expertos y está representado por datos volumétricos que definen la distribución espacial de los diferentes tejidos como: MG, MB, LCR, grasa, músculo, piel, hueso, vasos sanguíneos, tejido conectivo, dura madre, médula ósea y fondo de la imagen, donde la intensidad del voxel es proporcional a la fracción de tejido dentro del voxel. La imagen base de este modelo es T1 con TE/TR/FA = 18mS/10mS/30deg y resolución espacial = 1mm, en condiciones ideales (0% ruido y =% falta de homogeneidad). Para tener datos de T2 y DP se solicitaron simulaciones personalizadas con estas mismas especificaciones.

Tomando las imágenes de referencia (T1, T2 y DP) y sus respectivos tejidos del modelo anatómico, a partir de esto, se compara pixel a pixel, los tejidos con las imágenes de referencia, a fin de determinar las intensidades de cada tejido en las diferentes secuencias. Finalmente se obtienen

intensidades para los cortes 40, 90,120, con el fin de tener un número de muestras pequeño reduciendo el costo computacional.

Para el entrenamiento del clasificador se tomaron 4500 muestras aleatorias de los tejidos previamente adquiridos MG, MB, LCR, y 900 muestras aleatorias de cada tejido para conformar la clase Resto (hueso, piel y músculo, fondo de la imagen, conectivo y grasa). De esta manera se reduce el tiempo y el costo computacional al momento de utilizar el clasificador. La Fig. 1. es la representación en el espacio de los datos de entrenamiento.

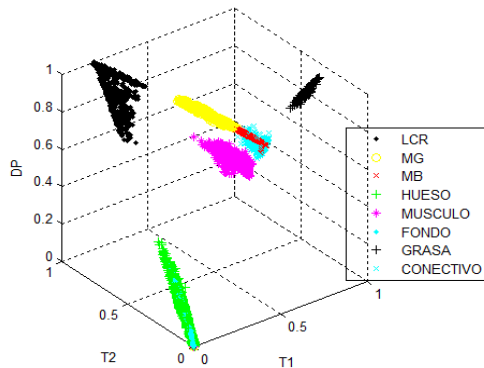


Fig. 1. Muestras de los datos de entrenamiento.

### B. Diseño del clasificador

En esta propuesta para la clasificación de los tejidos cerebrales se utilizan los métodos de clasificación SVM multi-clase 1-v-1 y 1-v-r, en el desarrollo se asignan etiquetas a las muestras de los datos previamente adquiridas para el entrenamiento de las SVM como se muestra en la tabla 1.

TABLA I. TETIQUETAS DE LOS DATOS DE ENTRENAMIENTO

Tejido	Clase	Etiqueta
MB	MB	1
MG	MG	2
LCR	LCR	3
Hueso	Resto	4
Piel y Músculo	Resto	4
Fondo de la imagen	Resto	4
Conectivo	Resto	4
Grasa	Resto	4

Los parámetros de  $C$  y  $\gamma$  se diseñan mediante una validación cruzada (VC) con el método de grilla de búsqueda (grid search), que crea una “red” de todas las posibles ubicaciones de los puntos de intersección de configuración, para encontrar los mejores parámetros, se tomaron los valores de  $C = 2^{-5}, 2^{-3}, \dots, 2^{15}$  y  $\gamma = 2^{-15}, 2^{-13}, \dots, 2^3$ , evaluando distintas funciones kernel: lineal, polinomial, Función Base Radial (RFB, por sus siglas en inglés) y sigmoidea, encontrando mejor desempeño con RFB. El método 1-v-1 se entrenó con los mejores resultados encontrados de la VC:  $C = 32768$ ,  $\gamma = 8$ , con un porcentaje de precisión en la clasificación de 98.8222%. En el método de clasificación 1-v-r se establecieron cuatro clasificadores binarios comparando un tejido con los otros restantes, la disposición de los 4 clasificadores se muestra en la tabla 2. A cada uno de estos

clasificadores se le aplicó la “grilla de búsqueda” de forma independiente, para hallar los parámetros óptimos de desempeño, los valores con mejor acierto de clasificación se presentan en la tabla 3. Finalmente se realizan las predicciones sobre las imágenes de prueba en ambos métodos.

TABLA II. CLASIFICADORES BINARIOS DE 1-V-R

Modelo	Clase 1	Clase 2
1	MG	MB, LCR y Resto
2	MB	MG, LCR y Resto
3	LCR	MG, MB y Resto
4	Resto	MG, M. Blanca y LCR

TABLA III. TVC CLASIFICADORES BINARIOS

Modelo	$\Gamma$	$C$	% Clasificación
1	8	0.03125	99.5882
2	8	32	98.8111
3	8	0.0125	100
4	8	32768	98.3111

### C. Evaluación de los clasificadores

Para la evaluación de los métodos de clasificación multi-clase se introdujeron las IRM en las secuencias T1, T2 y DP. La prueba inicial se hizo con el corte axial 90, corte medio del entrenamiento, en el cual hay mayor presencia de MG y MB, para establecer su comportamiento en condiciones ideales. Posteriormente se realizaron pruebas en cortes axiales diferentes a los del entrenamiento, así: por contar con mayor presencia de hueso, músculo y piel se eligió el corte 30; debajo del corte 75 empieza el cerebelo, y en los cortes superiores se encuentra mayor presencia de LCR, en este caso se eligió el corte 105. Se evalúa la clasificación en los cortes anteriormente mencionados por medio de una Matriz de Confusión (MC), que establece los falsos positivos y los falsos negativos de una clasificación. En este análisis se evalúan las etiquetas de los datos de entrenamiento y las etiquetas de los datos predichos, los datos se representan en matrices de  $N \times N$  correspondientes a las clases de la clasificación estableciendo la tasa de acierto para cada tejido.

## III. RESULTADOS

Teniendo en cuenta que el clasificador ha sido entrenado con condiciones ideales, se realizan pruebas con bajos niveles de ruido y de falta de homogeneidad, que serían el equivalente a las mejores condiciones encontradas en la toma de imágenes reales. Las imágenes de prueba tienen los siguientes parámetros: espesor = 1mm, 1% de ruido y 20% de falta de homogeneidad. Se presenta la respuesta de los clasificadores en imágenes binarias y la evaluación cuantitativa mediante la MC. En la Fig. 2. se indican las IRM en diferentes secuencias que se ingresaron en el clasificador.




Fig. 2. Imágenes de entrada en secuencias T1, T2 y DP, en los cortes axiales 90, 30, 75 y 105

Las imágenes de la Fig. 3. corresponden a la respuesta del método 1-v-1, en la figura 4 se muestra el resultado de la clasificación realizada con el método 1-v-r. En estas imágenes binarias se muestra cada clase de tejido de manera independiente en los diferentes cortes de prueba.

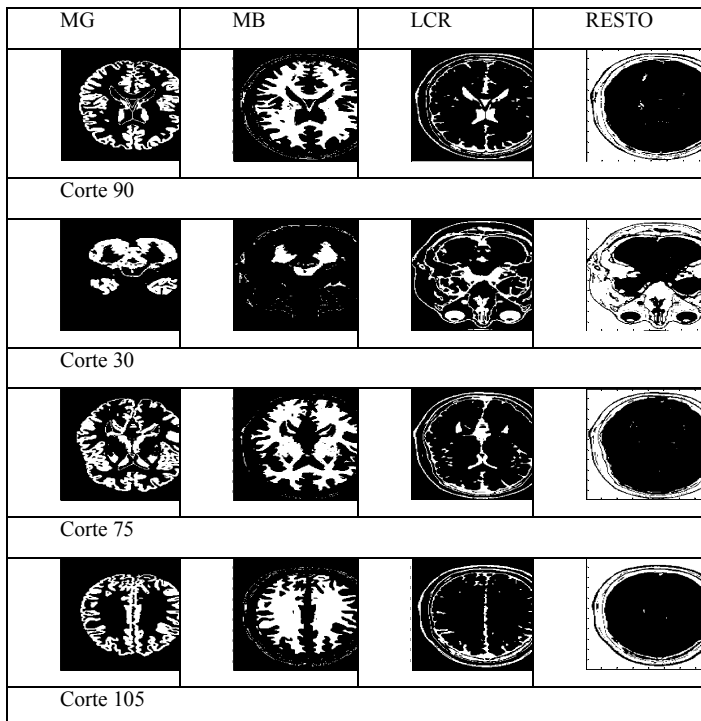


Fig. 3. Resultados de SVM multiclase 1-v-1 en los cortes 90, 30, 75 y 105




Fig. 4. Resultados de SVM multiclase 1-v-r en los cortes 90, 30, 75 y 105

La evaluación se realiza mediante MC en cada corte de prueba, los datos se representan en matrices de 4x4 correspondientes a las clases de la clasificación estableciendo la tasa de acierto para cada tejido, el promedio de las MC de los cortes de prueba se muestra en la tabla 4 para ambos clasificadores.

TABLA IV. MC DE LOS CLASIFICADORES

1-v-1				
	MG	MB	LCR	Resto
MG	0,999775	0,000225	0	0
MB	0,000075	0,996775	0	0,00315
LCR	0	0	1	0
Resto	0,0499	0,0388	0,1485	0,7628
1-v-r				
	MG	MB	LCR	Resto
MG	0,999025	0,000925	0,00005	0
MB	0,000075	0,9979	0	0,002025
LCR	0	0	1	0
Resto	0,077825	0,04225	0,146575	0,73335

El tiempo que tarda en hacer la predicción se calcula después del entrenamiento de cada modelo, el algoritmo se ejecuta en un procesador DualCore de 2.20 GHz, memoria RAM de 2 GB; el tiempo promedio para los cortes de prueba en segundos en el método 1-v-1 es de 6.9359, y en el clasificador 1-v-r son 27.1383 segundos.

#### IV. DISCUSIONES

La clasificación realizada de los tejidos cerebrales presenta altas tasas de acierto y tiempos de ejecución reducidos. Se resalta el resultado obtenido en la clase MG en todos los cortes con el método 1-v-1 el cual aparece totalmente independiente de los tejidos extra craneales, aun en el corte más bajo (30), donde también es clara esta independencia, a pesar de contar con mayor presencia de hueso y músculo, que dificulta la clasificación, mientras que en el método 1-v-r este tejido presenta adiciones de tejidos extra craneales.

En la clasificación de los tejidos MB y LCR en ambos clasificadores se observa un comportamiento parecido, sin embargo es clara la adición de los tejidos extra craneales debido a que las intensidades de estos son muy similares. En trabajos futuros deben tenerse en cuenta los tejidos intracraneales adyacentes al hueso (meninges y médula ósea) para mejorar el desempeño del clasificador.

El análisis cuantitativo de la clasificación realizado por medio de la MC confirma la precisión en la clasificación de los tejidos MG, MB y LCR de igual modo permite comprobar los errores en la detección de la clase resto en las otras clases de tejidos. En este análisis también se observa la superioridad del método 1-v-1 sobre el método 1-v-r en todas las clases de tejidos establecidas. El clasificador 1-v-r puede ser mejorado estableciendo un esquema de votación diferente.

La generación de un nuevo etiquetado a partir de un modelo difuso con correcciones manuales, da paso a la posibilidad de trabajar cualquier secuencia de IRM con altas tasas de acierto, si bien existen clasificadores con tasas de acierto más altas como el usado en la reconstrucción 3D con la técnica PVE implementado en una FPGA, sólo admite la secuencia T1 (Petronella Anbeek, Bochove, Osch, & Grond, 2005).

La reconstrucción 3D con ISSSVM (*Immune Sphere-Shaped SVM*) donde se evalúan 7 clases de tejidos (Smola, 1999), usan *Immune Algorithm* para encontrar los mejores parámetros de  $C$  y  $\gamma$ , en nuestro caso se usó la grilla de búsqueda que arroja mejores tasas de acierto que es verificable en los resultados de la evaluación mediante la MC para las mismas clases de tejidos, adicionalmente como ya se ha establecido con anterioridad en este trabajo se tiene la posibilidad clasificar tejidos cerebrales a partir de cualquiera de las tres secuencias de IRM.

#### V. LINEAMIENTOS FUTUROS

El grupo de trabajo plantea la utilización de los resultados obtenidos de las imágenes clasificadas en un estudio sobre imágenes reales, que luego será aplicado en la cuantificación

de patologías, planeación de neurocirugías, además de ser un apoyo en la investigación sobre la precisión en el posicionamiento y la trayectoria de la intervención de telecirugías a través de la generación de modelos 3D de estructuras anatómicas para la navegación virtual, para el estudio sobre imágenes reales se plantea la incorporación de una base de imágenes de pacientes de la Clínica Universitaria de la Sabana.

#### REFERENCIAS

- [1] R. Anita, J.Jens H and H. Joseph A. "Quantitative MR Imaging in Alzheimer Disease" 26, s.l. : Radiol, 2006, Vol. 241.
- [2] New Scientist Tech and Reuters. NewScientist. (2007, Abril) MRI-enabled brain surgery robot revealed. [Online]. <http://www.newscientist.com/article/dn11631-mri-enabled-brain-surgery-robot-revealed.html>.
- [3] DPA. World's first robot brain surgeon developed. smh. [Online] (2003, Enero). <http://www.smh.com.au/articles/2003/01/15/1042520673704.html>.
- [4] Yong Fan, Dinggang Shen Gur, R.C. Gur, R.E. Davatzikos, C. 1, COMPARE: Classification of Morphological Patterns Using Adaptive Regional Elements., Pennsylvania : IEEE, 2007, Vol. 26. 10.1109/TMI.2006.886812.
- [5] B. Pierre-Louis and y P. Dzung L. "Topology-Preserving Tissue Classification of Magnetic Resonance Brain Images". 4, s.l. : IEEE, 2007, Vol. 26. 10.1109/TMI.2007.893283.
- [6] A. Petronella, V. Koen L., Glenda S. van BochoveMatthias J.P. van Osch, and Jeroen van der Grond. Probabilistic segmentation of brain tissue in MR imaging. Netherlands: ScienDirect-Elsevier, 2005, Vol. 10.
- [7] K. Jahyun J., E. Alan C., G. Warren J. "3-D Brain MRI Tissue Classification on FPGA". 12, Montreal-Canada : IEEE, 2009, Vol. 18. 10.1109.
- [8] A. Jose Luis. "Decisión, estimación y clasificación SVM". Oro Verde : s.n., 2009.
- [9] C. Corina and V. Vladimir. SUPPORT-VECTOR NETWORKS. USA : AT&T Bell Labs, 1995. NJ 07733.
- [10] C-W. Hsu y C-J. Lin. A Comparison of methods for multi-class Support Vector Machines. Taiwan : Tapei. IEEE, 2002, Vol. 13. 10.1109/72
- [11] Smola, Schölkopf C. Burges A. Joachims, Making large-Scale SVM Learning Practical. Advances in Kernel Methods - Support Vector Learning. s.l. : MIT-Press, 1999.
- [12] Guo, Lei, y otros Research on the Segmentation of MRI Image Based on Multi-Classification Support Vector Machine.. Lyon, France : IEEE, 2007. 1-4244-0788-5.
- [13] Chih-Jen, Chang Chih-chung and Lin. LIBSVM -- A Library for Support Vector Machines. [Online] Enero 5, 2009. <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>.
- [14] Brain Imagin Center- Montreal Neurology Institute-McGill . BrainWeb: Simulated Brain Database. [Online] 12 de Junio de 2006. <http://mouldy.bic.mni.mcgill.ca/brainweb/>.