

Automatic Knee Cartilage Segmentation in Magnetic Resonance Images

Andrés D. Monsalvo¹ and Laura M. Vargas¹

¹Facultad de Ciencias Exactas Físicas y Naturales, Universidad Nacional de Córdoba, Argentina.

Abstract— Osteoarthritis is a degenerative disease of the articular cartilage. In the knee, it has a great impact in the patient's quality of life and is one of the main causes of total knee replacement. Advances in medical imaging techniques have led to the development of cartilage-morphology-based analysis techniques for the assessment of pathological or potentially pathological joints, but this requires precise image segmentation. The main objective of the present work is to design and implement the required algorithms for automatic segmentation of the articular cartilage in knee MRI's.

The proposed method is based on the application of multilayer Perceptron neural networks as voxel-wise classifiers, from a previously extracted feature set.

An image set consisting of 176 MRI scans was used. The images were obtained in a 3T machine with a DESS (Dual Echo Steady State) sequence. Anisotropic diffusion filtering was employed for noise reduction and a contrast enhancement *ad-hoc* transformation was developed. A set of 24 features were extracted related to voxel intensity, spatial location, and local geometry descriptors such as the Hessian matrix and the structure tensor.

A two-stage classification strategy was adopted using neural networks: first, cartilage vs background; and second, subdividing the cartilage between the femoral, tibial and patellar compartments. The final classification stage achieved Dice similarity coefficients (DSC) of $0,666\pm 0,042$, $0,674\pm 0,039$ y $0,550\pm 0,055$ for femoral, tibial, and patellar cartilage respectively.

Keywords— Articular cartilage, artificial neural networks, automatic image segmentation, knee osteoarthritis.

Resumen— La osteoartritis es una enfermedad degenerativa del cartílago articular asociada a dolor y pérdida de movilidad. Con los avances en imágenes médicas se han desarrollado herramientas de análisis basadas en la morfología del cartílago, pero esto requiere una segmentación precisa de las imágenes. Este trabajo tiene por objetivo el diseño e implementación de los algoritmos necesarios para la segmentación automática del cartílago articular de la rodilla en imágenes de resonancia magnética.

El método propuesto está basado en la aplicación de redes neuronales del tipo Perceptrón multicapa para realizar una clasificación voxel por voxel, a partir de un conjunto de características previamente extraídas.

Se trabajó sobre un set de 176 imágenes de resonancia magnética de rodilla obtenidas con un resonador de 3T mediante una secuencia DESS (Dual Echo Steady State). Las imágenes fueron preprocesadas mediante difusión anisotrópica para la reducción de ruido y una transformación de mejora de contraste diseñada *ad-hoc*. Se extrajeron 24 características relacionadas a intensidad, ubicación espacial y descriptores de la geometría local como la matriz Hessiana y el tensor de estructura.

Se adoptó una estrategia de clasificación en dos etapas usando redes neuronales: primero de cartílago vs. fondo y segundo un refinamiento subdividiendo el cartílago entre los compartimientos femoral, tibial y patelar. En la clasificación final de los voxeles se obtuvieron coeficientes de similitud de Dice de $0,666\pm 0,042$, $0,674\pm 0,039$ y $0,550\pm 0,055$ para el cartílago femoral, tibial y patelar respectivamente.

Palabras clave— Segmentación automática, cartílago articular, osteoartritis de rodilla, redes neuronales.

I. INTRODUCCIÓN

Los continuos avances en las tecnologías de adquisición de imágenes médicas permiten visualizar cada vez una mayor cantidad de estructuras y con creciente resolución. Esto resulta fundamental para el diagnóstico temprano y seguimiento de diversas patologías, como también la selección de los tratamientos más adecuados.

Si bien la valoración de un profesional entrenado es siempre determinante, resulta cada vez más importante contar con herramientas de análisis objetivo de las imágenes para facilitar la cooperación entre los profesionales de la salud, focalizar el trabajo en las actividades de mayor impacto positivo en paciente, extraer información y obtener

conclusiones sobre el tratamiento de un gran número de pacientes.

La segmentación automática permite obtener formas de visualización de las imágenes que complementan a las tradicionales y realizar mediciones cuantitativas que agregan valor a los estudios realizados a los pacientes.

En el campo de las imágenes médicas, y en particular en lo que respecta a los tejidos blandos, son numerosos los desafíos que se presentan en la tarea de segmentación, entre los que se destacan la variabilidad de la morfología de los objetos a segmentar, tanto por las diferencias anatómicas interpersonales como por las patologías que puedan presentarse; la baja relación señal-ruido de las imágenes en comparación con otras aplicaciones; y la frecuente ausencia de límites claros en los objetos a segmentar debido a

transiciones graduales de los tejidos, en relación a la resolución espacial disponible.

En el presente trabajo se aborda la temática de la segmentación automática de imágenes médicas aplicada al cartílago de la rodilla. La segmentación se basa en la extracción de características relacionadas a la intensidad, geometría local y ubicación espacial de los vóxeles, que alimentan a un clasificador de dos etapas conformado por redes neuronales del tipo Perceptrón multicapa.

A. La Osteoartritis

Si bien existen diversas patologías que afectan la correcta función del cartílago articular de la rodilla, es la osteoartritis la que más ha impulsado la investigación en este campo debido a su elevada prevalencia, la que llega aproximadamente a un 10% para personas mayores a 60 años a nivel mundial [1].

La osteoartritis (OA), comúnmente llamada artrosis en la práctica clínica, es una condición crónica caracterizada por el desgaste del cartílago articular. Formalmente, puede definirse como un grupo heterogéneo de condiciones que conducen a síntomas y signos articulares que están asociados a defectos de integridad del cartílago y hueso subyacente [2]; compromete cualquiera de los tejidos articulares, el cartílago se degenera y demuestra lesiones de fibrilación, con fisuras y ulceraciones que van determinando la pérdida total del espesor de la superficie articular [3].

La OA es una patología de etiología multifactorial, cuyo desarrollo está determinado por la relación de factores sistémicos y locales. Entre las diversas causas se puede mencionar alteraciones genéticas, como mutaciones en genes relacionados al metabolismo del colágeno; aumento en la carga biomecánica de la articulación, ya sea por sobrepeso, mala alineación del miembro inferior o traumatismos [4].

B. Imágenes médicas en OA

Si bien en los últimos años la resonancia magnética ha cobrado una elevada relevancia en la visualización de estructuras blandas, el "gold standard" para el diagnóstico y seguimiento de la OA está basado en radiografías, mediante la escala del Kellgren-Lawrence (KL) [1].

La escala KL constituye el primer método sistematizado de valoración semicuantitativa de la OA [5] y se basa en la evaluación del espacio articular, presencia de osteofitos y deformación de la anatomía normal de los extremos óseos.

Si bien este método es un estándar mundial, la medición del espacio articular para la valoración de la osteoartritis de rodilla mediante imágenes radiográficas es un tema controversial. Varias publicaciones discuten que esto se debe más a una cuestión de madurez tecnológica que a una bondad del indicador en sí mismo [6, 7]. El principal argumento es que estas técnicas se desarrollaron cuando la radiografía era el único método difundido de imagenología en rodilla, siendo la resonancia magnética y la tomografía computada técnicas de evolución mucho más reciente.

Debido a las limitaciones descriptas de la radiografía como método para el diagnóstico y seguimiento de la OA, se han desarrollado métodos semicuantitativos basados en resonancia magnética. Los más difundidos son WORMS (acrónimo de *Whole Organ MR Scoring*) [8], BLOKS (acrónimo de *Boston-Leeds Osteoarthritis Knee Scoring*) [9], y KOSS (acrónimo de *Knee Osteoarthritis Scoring System*) [10].

Estos métodos han demostrado ser útiles en aplicaciones clínicas, pero el tiempo insumido en su ejecución, que varía

entre 80 y 120 minutos aproximadamente, limita su campo de aplicación [11]. Por este motivo, se han propuesto varias técnicas basadas en mediciones cuantitativas del cartílago articular a partir de imágenes de resonancia magnética segmentadas [12, 13].

C. Trabajos relacionados

La segmentación de cartílago articular es una temática muy activa en el campo de investigación sobre procesamiento de imágenes médicas y son numerosas las distintas estrategias utilizadas para abordar el problema.

TABLA I
SÍNTESIS DE TRABAJOS RELACIONADOS.

Trabajo	Método	Sens. %	Esp. %	DSC
Folkesson <i>et al.</i> [14]	Clasificadores binarios	84.17	99.89	0.811
Folkesson <i>et al.</i> [15]	Clasificadores binarios, crecimiento de regiones a partir de semillas aleatorias	80.3 (F) 86.8 (T) 83.9 (G)	99.91 (F) 99.96 (T) 99.87 (G)	0.77 (F) 0.81 (T) 0.80 (G)
Shan <i>et al.</i> [16]	"Multi-atlas", SVM, clasificador multiclase.	ND	ND	0.76 (F) 0.84 (T)
Dodin <i>et al.</i> [17]	Análisis de textura. Transformación normal a la superficie ósea, clasificador Bayesiano.	ND	ND	0.85 (F) 0.84 (T) 0.84 (G)
Prasoon <i>et al.</i> [18]	Clasificación en dos etapas. kNN, SPM	80.82	98.07	0.8115
Marstal <i>et al.</i> [19]	Similitud de "parches". kNN	83.1 (F) 85.3 (T)	99.9 (F) 99.9 (T)	0.78 (F) 0.80 (T)
Yin <i>et al.</i> [20]	Corte de grafos. AdaBoost, bosques aleatorios.	ND	ND	0.84 (F) 0.80 (T) 0.80 (P)
Folkesson <i>et al.</i> [14]	Segmentación manual para la evaluación de repetitividad intra-segmentador	NA	NA	0.85
Xia <i>et al.</i> [21]	Segmentación manual para la evaluación de repetitividad intra- e inter-segmentador	NA	NA	0.82 (inter) 0.86 y 0.88 (intra)

Sens. = sensibilidad, Esp. = especificidad, DSC = coeficiente de similitud de Dice, F = cartílago femoral, T = cartílago tibial, P = cartílago patelar, G = cartílago global (total de la articulación), ND = no declarado, NA = no aplica.

En la Tabla I se presenta una síntesis de las publicaciones destacadas en este campo, junto con los indicadores de desempeño reportados en cada una. En esta tabla, se presenta también los resultados obtenidos por Folkesson *et al.* [14] y Xia *et al.* [21] para la medición del coeficiente de similitud

de Dice (DSC) entre dos segmentaciones realizadas por un experto en distintas sesiones (intra-segmentador) y por dos expertos (inter-segmentador). Estos resultados sirven como referencia para valorar el desempeño de los algoritmos de segmentación automática. Cabe aclarar que el estudio de Xia *et al.* se trata de segmentación de cartílago articular en cadera, pero la similitud entre las aplicaciones justifica su representatividad.

II. MATERIALES Y MÉTODOS

Para el presente trabajo se utilizan imágenes provistas por la *Osteoarthritis Initiative* (<http://www.oai.ucsf.edu>), un proyecto promovido por el gobierno de Estados Unidos a través del *National Institutes of Health*, que involucra a 4796 varones y mujeres con OA o riesgo incrementado de adquirir la patología. Los individuos ingresaron al programa entre febrero de 2004 y mayo de 2006, con edades entre 45 y 79 años [22].

El set de imágenes de resonancia magnética consiste en una muestra de 88 rodillas que recibieron una adquisición de línea de base y una de seguimiento al cabo de un año. Las imágenes de RM fueron adquiridas en un resonador de 3T con una secuencia DESS (*Dual Echo Steady State*). Se trata de volúmenes de 160 imágenes en cortes sagitales, con una resolución de 0.36458333 mm/píxel y 0.7 mm de espesor de corte, lo que implica un FOV (Field Of View) de 112 mm x 140 mm x 140 mm. Las imágenes son proporcionadas en formato DICOM, con una profundidad de bits de 12.

Las imágenes son acompañadas por los contornos de los compartimientos correspondientes al cartílago femoral, tibial y patelar, como también los meniscos. Estos contornos fueron generados mediante segmentación manual realizada por personal entrenado de la compañía iMorphics. El método utilizado es descrito en [23] y [24].

En un análisis preliminar, se compararon los volúmenes de cartílago en el estudio de línea de base y seguimiento, calculados a partir de la segmentación proporcionada con las imágenes. En la Fig. 1 se presenta el resultado de este análisis. Puede observarse la presencia de algunos valores notablemente elevados en magnitud (marcados en círculos punteados). Al revisar estas imágenes se constató la ausencia de uno o más contornos correspondientes a la segmentación manual. Por este motivo, estas rodillas fueron descartadas para el resto del trabajo.

Los estudios correspondientes a las 83 rodillas disponibles (tras la desestimación de las imágenes mencionadas en el párrafo anterior) fueron divididas aleatoriamente en tres grupos:

- 60% (50 rodillas) son usadas para el diseño inicial y entrenamiento de los clasificadores; es decir que todos los patrones presentados a los clasificadores para su aprendizaje provendrán de este grupo.
- 25% (21 rodillas) se reservan para la validación y ajuste de los algoritmos. Los patrones obtenidos de este grupo no son presentados a los clasificadores para su aprendizaje, pero sí para evaluar su desempeño y capacidad de generalización, esto resulta de suma importancia para prevenir el sobre-entrenamiento [25].
- 15% (12 rodillas) para la verificación de los algoritmos. Estas imágenes sólo son usadas para la valoración final de los algoritmos; es decir que no son presentadas a los clasificadores durante el entrenamiento y su uso se restringe a la evaluación final del desempeño del sistema.




Fig. 1: Diferencias en volumen de cartílago: seguimiento – línea de base.

A. Preprocesamiento

Para la reducción de ruido, se utilizó una implementación en Matlab [26] del algoritmo de difusión anisotrópica propuesto por Perona y Malik [27]. Este método permite disminuir la intensidad del ruido similarmente a la difusión gaussiana, con la diferencia que la intensidad del efecto de “suavizado” está influenciada por el gradiente de la imagen, lo que permite preservar la nitidez en zonas de alto contraste, como son los contornos de distintos elementos.

El filtro fue aplicado en dos iteraciones, con un parámetro Δt de 3/44 (recomendado en [26] por los desarrolladores del algoritmo) y un parámetro K de 0,1. La conducción es calculada según (1), lo que corresponde a la opción descrita en la publicación original de Perona y Malik que prioriza bordes de alto contraste sobre bordes de bajo contraste.

$$c(x, y, z, t) = \exp\left(\left(-\frac{\|\nabla I\|}{K}\right)^2\right) \quad (1)$$

Para la mejora del contraste se diseñó una transformación *ad-hoc* basada en el método propuesto en [28], con la diferencia principal que, en vez de adoptarse una transformación por tramos lineales entre los puntos de control calculados, se ajustó un spline cúbico, como se ilustra en la Fig. 2.

De acuerdo con la metodología adoptada, se seleccionaron como puntos de control las posiciones de los valles y picos del histograma de niveles de gris. Estos valores se corresponden con las abscisas de los puntos de control de la transformación, es decir los niveles de gris de la imagen de entrada.

Los valores de las ordenadas de los puntos de control de la transformación, es decir los niveles de gris de la imagen de salida, son calculados mediante (2); donde $P(l)$ es la frecuencia de ocurrencia de la intensidad l , y x_k e y_k son la abscisa y ordenada del k -ésimo punto de control.

$$y_k = \sum_{l=0}^{x_k} P(l) \quad 512 \quad (2)$$

A partir de la curva generada, se construye una tabla de valores que permite aplicar la transformación a las imágenes mediante la función *intlut* [27].




Fig. 2: Transformación de mejora de contraste. En azul, la transformación y en línea punteada los tramos rectos definidos por los puntos de control (♦).

B. Extracción de características

Para el correcto desempeño del clasificador, es preciso contar con características que permitan diferenciar adecuadamente a las clases. En este trabajo se extrajeron un total de 24 características candidatas, que pueden agruparse en cuatro categorías, como se describe a continuación.

De este grupo de 24, se seleccionó un total de 14 características, que son presentadas en la Tabla 2. La selección fue realizada mediante la función *sequentialfs* [27], que iterativamente agrega o elimina características y entrena un clasificador hasta generar un set óptimo con las características de mayor poder predictivo. Debido al elevado costo computacional de entrenar redes neuronales, para esta instancia se adoptó un clasificador de k-vecinos cercanos, con $k=5$.

TABLA II
LISTADO DE CARACTERÍSTICAS

Característica
Coordenada x
Coordenada y
Coordenada z
Valor propio λ_1 de la Matriz Hessiana con $\sigma=2$
Valor propio λ_2 de la Matriz Hessiana con $\sigma=2$
Valor propio λ_1 de la Matriz Hessiana con $\sigma=3$
Valor propio λ_2 de la Matriz Hessiana con $\sigma=3$
Valor propio λ_1 de la Matriz Hessiana con $\sigma=4$
Valor propio λ_2 de la Matriz Hessiana con $\sigma=4$
Intensidad con $\sigma=0$
Intensidad con $\sigma=1$
Intensidad con $\sigma=2$
Valor propio λ_1 del Tensor de Estructura con $\sigma=2$
Valor propio λ_2 del Tensor de Estructura con $\sigma=2$

1) Coordenadas espaciales

La posición de un vóxel en el sistema de coordenadas de la imagen está directamente relacionada con la probabilidad de una clasificación positiva, ya que todos los estudios están centrados en la articulación de la rodilla. En [14] se reporta un alto valor predictivo para estas características.

Las coordenadas son incorporadas al vector de características como tres valores: las coordenadas x y z de cada vóxel.

2) Valores propios de la Matriz Hessiana

La Matriz Hessiana (H) cuantifica los cambios de intensidad de segundo orden, fuertemente vinculados a la curvatura local. Está definida para cada vóxel por

$$H(p) = \begin{bmatrix} \frac{\partial^2 I}{\partial x^2}(p) & \frac{\partial^2 I}{\partial x \partial y}(p) & \frac{\partial^2 I}{\partial x \partial z}(p) \\ \frac{\partial^2 I}{\partial y \partial x}(p) & \frac{\partial^2 I}{\partial y^2}(p) & \frac{\partial^2 I}{\partial y \partial z}(p) \\ \frac{\partial^2 I}{\partial z \partial x}(p) & \frac{\partial^2 I}{\partial z \partial y}(p) & \frac{\partial^2 I}{\partial z^2}(p) \end{bmatrix} \quad (3)$$

El método utilizado para la extracción de características a partir de esta matriz es el cómputo de los valores propios, similarmente a lo descrito en [29].

Los valores propios de la Matriz Hessiana son incorporados al vector de características ordenados de mayor a menor en valor absoluto, es decir $|\lambda_1| \geq |\lambda_2| \geq |\lambda_3|$.

Con el objetivo de detectar estructuras a distintas escalas, estas características son computadas previa aplicación de un filtro gaussiano con $\sigma=2, 3$ y 4 . La Fig. 3 muestra el resultado del cómputo de los valores propios de la Matriz Hessiana para las escalas mencionadas mapeando los valores de λ_1, λ_2 y λ_3 a los canales R, G y B de la imagen respectivamente.




Fig. 3. Valores propios de la Matriz Hessiana a distintas escalas. (a) $\sigma=2$. (b) $\sigma=3$. (c) $\sigma=4$.

El tensor de estructura (S) es una matriz relacionada al gradiente de una función cuyos valores están relacionados a la dirección y magnitud de la variación de la función. Esta matriz está definida para cada vóxel por:

$$S(p) = \begin{bmatrix} \left(\frac{\partial I}{\partial x}(p)\right)^2 & \frac{\partial I}{\partial y}(p) \frac{\partial I}{\partial x}(p) & \frac{\partial I}{\partial z}(p) \frac{\partial I}{\partial x}(p) \\ \frac{\partial I}{\partial x}(p) \frac{\partial I}{\partial y}(p) & \left(\frac{\partial I}{\partial y}(p)\right)^2 & \frac{\partial I}{\partial z}(p) \frac{\partial I}{\partial y}(p) \\ \frac{\partial I}{\partial x}(p) \frac{\partial I}{\partial z}(p) & \frac{\partial I}{\partial y}(p) \frac{\partial I}{\partial z}(p) & \left(\frac{\partial I}{\partial z}(p)\right)^2 \end{bmatrix} \quad (2)$$

Similarmente a lo descrito para la matriz Hessiana, el método utilizado para la extracción de características consiste en el cómputo de los valores propios de la matriz. En este caso, los valores propios son definidos positivos y también se los ordena de manera decreciente ($\lambda_1 \geq \lambda_2 \geq \lambda_3$).

Estas características también fueron computadas a distintas escalas mediante la aplicación de un filtro gaussiano con $\sigma=2, 3$ y 4 . La Fig. 4 ilustra el resultado del cómputo de los valores propios del tensor de estructura a distintas

escalas, realizando el mismo mapeo de valores propios en los canales R, G y B.




Fig. 4. Valores propios del Tensor de Estructura a distintas escalas. (a) $\sigma = 2$. (b) $\sigma = 3$. (c) $\sigma = 4$.

3) Intensidades

Una característica de gran relevancia para la detección de un determinado tejido en una imagen médica es el nivel de gris (intensidad) de dicho elemento.

Similarmente a los casos anteriores, la característica de intensidad es extraída a distintas escalas mediante la aplicación de un filtro gaussiano, con la diferencia que en este caso se adopta $\sigma=0$ (imagen original), 1 y 2.

C. Clasificación

Para la clasificación de los vóxeles se emplearon redes neuronales de tipo Perceptrón multicapa, siguiendo un esquema de clasificación en dos etapas, como se ilustra en la Fig. 5.

En primera instancia los vóxeles son clasificados en cartílago y fondo.

Con el objetivo de mejorar el desempeño del sistema, en particular de la especificidad, la segunda etapa de clasificación sigue una estructura jerárquica en la que los vóxeles inicialmente etiquetados como cartílago son reclasificados entre los compartimientos femoral, tibial y patelar, pudiendo ser también reclasificados como fondo.

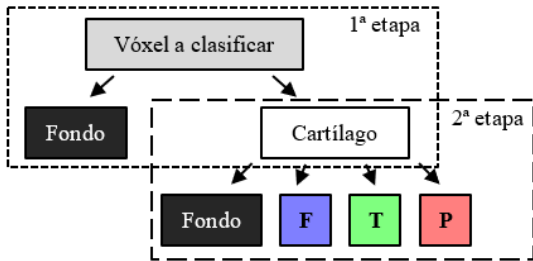


Fig. 5. Esquema de clasificación en dos etapas. F = cartílago femoral, T = cartílago tibial, P = cartílago patelar.

Esta clasificación en dos etapas resulta en un método similar al propuesto por Parsoon *et al.* [18] al mismo tiempo que representa un abordaje “focalizado a nivel de datos” al problema del desbalance entre clases como es descrito por Theodoridis y Koutroumbas [30]. A diferencia del abordaje “aleatorio a nivel de datos”, en este caso la mayoría de las instancias negativas se encuentran próximas o guardan alguna similitud con las instancias positivas.

La segunda instancia de clasificación consiste en tres redes neuronales, cada una entrenada para clasificar positivamente a uno de los compartimientos (femoral, tibial y patelar). Cada una de estas redes arroja como resultado un valor en el intervalo $[0, 1]$. La regla de decisión para el refinamiento es la siguiente:

- El vóxel i es clasificado como cartílago femoral si $O_i^f > O_i^t$ y $O_i^f > O_i^p$ y $O_i^f > 0.5$
- El vóxel i es clasificado como cartílago tibial si $O_i^t > O_i^f$ y $O_i^t > O_i^p$ y $O_i^t > 0.5$

- El vóxel i es clasificado como cartílago patelar si $O_i^p > O_i^f$ y $O_i^p > O_i^t$ y $O_i^p > 0.5$
- El vóxel i es clasificado como fondo en caso contrario; es decir si $O_i^f < 0.5$ y $O_i^t < 0.5$ y $O_i^p < 0.5$

Siendo O_i^c la salida de la red neuronal entrenada para clasificar el compartimiento “c” (f =femoral, t =tibial y p =patelar) ante la entrada del i -ésimo vóxel. Cabe aclarar que los únicos vóxeles que hacen de entrada para estas redes son los inicialmente clasificados como cartílago.

Las redes neuronales empleadas poseen 14 neuronas en la capa de entrada (una para cada característica), dos capas ocultas con 10 y 5 neuronas y una capa de salida de una neurona.

Esta estructura de dos capas ocultas fue la que presentó el mejor compromiso entre tasa de aciertos y costo computacional al ensayarse con otras redes de una y tres capas ocultas.

Los pesos sinápticos fueron inicializados en valores aleatorios en el intervalo $[-1, 1]$ y entrenados mediante el algoritmo de *scaled conjugate gradient backpropagation* [31].

III. RESULTADOS

En la Tabla III se presentan los resultados obtenidos para la clasificación de los vóxeles.

La Fig. 6 presenta el resultado de la clasificación coloreando los distintos compartimientos en imágenes representativas.

TABLA III
RESULTADOS DE LA CLASIFICACIÓN

Compartimiento	Sensibilidad	Especificidad	DSC
Femoral	95,37±2,14%	99,34±0,12%	0,666±0,042
Tibial	93,67±1,85%	99,81±0,09%	0,674±0,039
Patelar	94,05±1,97%	99,75±0,07%	0,550±0,055

Los resultados se presentan como media \pm desvío estándar obtenidos para el subset de verificación.




Fig. 6. Resultados de la segmentación automática en dos de las rodillas del set de imágenes.

IV. CONCLUSIONES

El método logrado obtuvo un buen desempeño en la segmentación del cartílago articular. Si bien los indicadores como el coeficiente de similitud de Dice (DCS) y la especificidad son inferiores a los reportados en trabajos previos, se considera que los resultados obtenidos presentan gran potencial de aplicación en la práctica clínica, probablemente no de manera completamente automática, pero sí como un paso previo que alivie considerablemente el tiempo que requeriría una segmentación manual por un usuario entrenado.

Cabe destacar que para el desarrollo de este trabajo se contó con un set de imágenes correspondientes a pacientes con osteoartritis, sin existir un grupo sano de control.

REFERENCIAS

- [1] D. Symmons, C. Mathers y B. Pflieger, «Global burden of osteoarthritis in the year 2000,» *Geneva: World Health Organization*, 2003.
- [2] Sociedad Argentina de Reumatología, «Guías argentinas de práctica clínica para el diagnóstico y tratamiento de la osteoartritis,» *Rev argent reumatol*, n° 4, 2010.
- [3] R. Altman, E. Asch, D. Bloch, G. Bole, D. Borenstein, K. Brandt, W. Christy, T. D. Cooke, R. Greenwald y M. Hochberg, «Development of Criteria for Classification and Reporting of Osteoarthritis. Classification of Osteoarthritis of the Knee. Diagnostic and Therapeutic Criteria Committee of the American Rheumatism Association,» *Arthritis Rheum*, vol. 29, n° 8, pp. 1039-49, 1986.
- [4] B. Heidari, «Knee osteoarthritis prevalence, risk factors, pathogenesis and features: Part I,» *Caspian J Intern Med*, vol. 2, n° 2, p. 205-212, 2011.
- [5] J. H. Kellgren, J. Ball y J. M. Rutherford, Atlas of standard radiographs. The epidemiology of chronic rheumatism, O. B. S. Publications, Ed., 1963.
- [6] R. Patel, M. Eltgroth, R. B. Souza, C. A. Zhang, S. Majumdar, T. M. Linka y D. Motamedi, «Loaded versus unloaded magnetic resonance imaging (MRI) of the knee: Effect on meniscus extrusion in healthy volunteers and patients with osteoarthritis,» *Eur J Radiol Open*, vol. 3, pp. 100-107, 2006.
- [7] D. J. Hunter, Y. Q. Zhang, X. Tu, M. Lavalley, J. B. Niu, S. Amin, A. Guermazi, H. Genant, D. Gale y D. T. Felson, «Change in joint space width: hyaline articular cartilage loss or alteration in meniscus?,» *Arthritis Rheum*, vol. 54, n° 8, pp. 2488-2495, 2006.
- [8] C. G. Peterfy, A. Guermazi, S. Zaim, P. F. Tirman, Y. Miaux, D. White, M. Kothari, Y. Lu, K. Fye, S. Zhao y H. K. Genant, «Whole-Organ Magnetic Resonance Imaging Score (WORMS) of the knee in osteoarthritis,» *Osteoarthritis Cartilage*, vol. 12, n° 3, pp. 177-190, 2004.
- [9] D. J. Hunter, G. H. Lo, D. Gale, A. J. Grainger, A. Guermazi y P. G. Conaghan, «The reliability of a new scoring system for knee osteoarthritis MRI and the validity of bone marrow lesion assessment: BLOKS (Boston Leeds Osteoarthritis Knee Score),» *Ann Rheum Dis*, vol. 67, n° 2, pp. 206-211, 2008.
- [10] P. R. Kooma, R. Y. Ceulemans, H. M. Kroon, N. Riyazi, M. Kloppenburg, W. O. Carter, T. G. Woodworth y J. L. Bloem, «MRI assessment of knee osteoarthritis: Knee Osteoarthritis Scoring System (KOSS)—inter-observer and intra-observer reproducibility of a compartment-based scoring system,» *Skeletal Radiol*, vol. 34, n° 2, pp. 95-102, 2005.
- [11] J. A. Lynch, F. W. Roemer, M. C. Nevitt, D. T. Felson, J. Niu, C. B. Eaton y A. Guermazi, «Comparison of BLOKS and WORMS scoring systems part I. Cross sectional comparison of methods to assess cartilage morphology, meniscal damage and bone marrow lesions on knee MRI: data from the osteoarthritis initiative,» *Osteoarthritis Cartilage*, vol. 18, n° 11, pp. 1393-1401, 2010.
- [12] M. P. Hellio Le Graverand, R. J. Buck, B. T. Wyman, E. Vignon, S. A. Mazuca, K. D. Brandt, M. Piperno, H. C. Charles, M. Hudelmaier, D. J. Hunter, C. Jackson, V. B. Kraus, T. M. Link, S. Majumdar, P. .. Prasad, T. J. Schnitzer y A. Vaz, «Subregional femorotibial cartilage morphology in women – comparison between healthy controls and participants with different grades of radiographic knee osteoarthritis,» *Osteoarthritis Cartilage*, vol. 17, n° 9, pp. 1177-1185, 2009.
- [13] S. Reichenbach, M. Yang, F. Eckstein, J. Niu, D. J. Hunter, C. E. McLennan, A. Guermazi, F. Roemer, M. Hudelmaier, P. Aliabadi y D. T. Felson, «Does cartilage volume or thickness distinguish knees with and without mild radiographic osteoarthritis? The Framingham Study,» *Ann Rheum Dis*, vol. 69, n° 1, pp. 143-149, 2010.
- [14] J. Folkesson, O. F. Olsen, P. Pettersen, E. Dam y C. Christiansen, «Combining Binary Classifiers for Automatic Cartilage Segmentation in Knee MRI,» de *Computer Vision for Biomedical Image Applications*, Y. Liu, T. Jiang y C. Zhang, Edits., Springer-Verlag, 2005, pp. 230-239.
- [15] Y. Xia, S. S. Chandra, C. Engstrom, M. Strudwick, S. Crozier y J. Frupp, «Automatic hip cartilage segmentation from 3D MR images using arc-weighted graph searching,» *Phys. Med. Biol.*, vol. 59, pp. 7245-7266, 2014.
- [16] J. Folkesson, E. Dam, O. F. Olsen, P. Pettersen y C. Christiansen, «Segmenting articular cartilage automatically using a voxel classification approach,» *IEEE Trans Med Imaging*, vol. 26, n° 1, pp. 106-115, 2007.
- [17] L. Shan, C. Zach, C. Charles y M. Niethammer, «Automatic atlas-based three-label cartilage segmentation from MR knee images,» *Medical Image Analysis*, vol. 18, pp. 1233-1246, 2014.
- [18] P. Dodin, J.-P. Pelletier, J. Martel-Pelletier y F. Abram, «Automatic Human Knee Cartilage Segmentation Automatic Human Knee Cartilage Segmentation,» *IEEE Transactions on Biomedical Engineering*, vol. 57, n° 11, pp. 2699-2711, 2010.
- [19] A. Prason, C. Ige, M. Loog, F. Lauze, E. B. Dam y M. Nielsen, «Femoral Cartilage Segmentation in Knee MRI Scans Using Two Stage Voxel Classification,» de *35th Annual International Conference of the IEEE EMBS*, 2013.
- [20] K. Marstal, H. Gudbergesen, M. Boesen, O. Kubassova, R. Bouert y H. Bliddal, «Semi-automatic Segmentation of Knee Osteoarthritic Cartilage in Magnetic Resonance Images,» de *53rd International Symposium ELMAR*, 2011.
- [21] Y. Yin, X. Zhang, R. Williams, X. Wu, D. D. Anderson y M. Sonka, «LOGISMOS—Layered Optimal Graph Image Segmentation of Multiple Objects and Surfaces: Cartilage Segmentation in the Knee Joint,» *IEEE Transactions on Medical Imaging*, vol. 29, n° 12, pp. 2023-2037, 2010.
- [22] C. G. Peterfy, E. Schneider y M. Nevitt, «The osteoarthritis initiative: report on the design rationale for the magnetic resonance imaging protocol for the knee,» *Osteoarthritis Cartilage*, vol. 16, n° 2, pp. 1433-1441, 2008.
- [23] S. Balamoody, T. G. Williams, J. C. Waterton, M. Bowes, R. Hodgson, C. J. Taylor y C. E. Hutchinson, «Comparison of 3T MR scanners in regional cartilage-thickness analysis in osteoarthritis: a cross-sectional multicenter, multivendor study,» *Arthritis Res Ther*, vol. 12, n° 5, 2010.
- [24] T. G. Williams, A. P. Holmes, M. Bowes, G. Vincent, C. E. Hutchinson, J. C. Waterton, R. A. Maciewicz y C. J. Taylor, «Measurement and visualisation of focal cartilage thickness change by MRI in a study of knee osteoarthritis using a novel image analysis tool,» *Br J Radiol*, vol. 83, n° 995, pp. 940-948, 2010.
- [25] D. H. Alman y L. Ningfang, «Overtraining in Back-Propagation Neural Networks: A CRT Color Calibration Example,» *Color Research Application*, vol. 27, n° 2, pp. 122-125, 2002.
- [26] D. Lopes, 2007. [En línea]. Available: <https://www.mathworks.com/matlabcentral/fileexchange/14995-anisotropic-diffusion-perona-malik>.
- [27] The MathWorks, Neural Network Toolbox™ User's Guide, 2010.
- [28] C. M. Tsai y Z. M. Yeh, «Contrast enhancement by automatic and parameter-free piecewise linear transformation for color images,» *IEEE Transactions on Consumer Electronics*, vol. 54, n° 2, pp. 213-219, 2008.
- [29] A. F. Frangi, W. J. Niessen, K. L. Vincken y M. A. Viergever, «Multiscale vessel enhancement filtering,» de *Medical Image Computing and Computer-Assisted Intervention — MICCAI'98*, W. M. Wells, A. Colchester y S. Delp, Edits., Springer-Verlag Berlin Heidelberg, 1998, pp. 130-137.
- [30] S. Theodoridis y K. Koutroumbas, Pattern Recognition, 4ª ed., Academic Press, 2009.
- [31] M. F. Moller, «A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning,» *Neural Networks*, vol. 6, pp. 525-533, 1993.