

Análisis de texturas homogéneas para la estimación volumétrica de la materia cerebral por tomografía computarizada

Analysis of Homogeneous Textures for the Volumetric Estimation of Brain Matter by Computed Tomography

Adrian Alberto Mesa Pujals ^{(1) *}	0000-0003-0643-5315
Katherine Susana Hernández Cortés ⁽²⁾	0000-0001-9293-9450
Arquímedes Montoya Pedrón ⁽³⁾	0000-0001-9415-4585
Solangel Bolaños Vaillant ⁽⁴⁾	0000-0002-4585-6507
Eloy Daniel Álvarez Guerra ⁽¹⁾	0000-0002-0120-588X

⁽¹⁾ Centro de Biofísica Médica. Universidad de Oriente. Santiago de Cuba.

⁽²⁾ Universidad de Ciencias Médicas de Santiago de Cuba. Cuba.

⁽³⁾ Hospital General Docente Dr. Juan Bruno Zayas Alfonso. Santiago de Cuba. Cuba

⁽⁴⁾ Hospital Saturnino Lora Torres. Santiago de Cuba. Cuba

* Autor para la correspondencia: adrian.mesa@uo.edu.cu

RESUMEN

Las aplicaciones de análisis de texturas y su extracción de características son consideradas tendencias de investigación en las neurociencias. La textura como método de análisis de imágenes ha mostrado resultados prometedores en la detección de lesiones visibles y no visibles, y en estudios de tomografía computarizada (TC) son escasos. La presente investigación tiene como objetivo determinar la aplicabilidad del procesamiento automático de índices de texturas homogéneas en la estimación volumétrica de la sustancia gris cerebral en imágenes de TC craneal. Para ello se utilizaron imágenes artificiales con regiones predefinidas y la selección de imágenes de TC en los pacientes con indicaciones previas de TC de cráneo. Dos pasos fundamentales son conducidos para la implementación de este enfoque. Como resultado se obtuvo un método automático de reconocimiento de patrones sin ventanas por medio de la extracción de características de textura homogéneas a través de la matriz de co-ocurrencia.

Palabras clave: análisis de textura; extracción de características; tomografía computarizada; materia cerebral.



ABSTRACT

Texture analysis applications and their extraction of features are considered research trends in neuroscience. Texture as a method of image analysis has shown promising results in the detection of visible and non-visible lesions, and in computed tomography (CT) studies they are scarce. The present research aims to determine the applicability of the automatic processing of homogeneous texture indices in the volumetric estimation of brain gray matter in cranial CT images. For this, artificial images with predefined regions and the selection of CT images were used in patients with previous indications for CT of the skull. Two fundamental steps are taken for the implementation of this approach. As a result, an automatic windowless pattern recognition method was obtained by means of the extraction of homogeneous texture characteristics through the co-occurrence matrix.

Keywords: texture analysis; feature extraction; computed tomography; brain matter.

Recibido: 28/10/2021

Aprobado: 23/04/2022

Introducción

La tecnología de imágenes médicas ha experimentado un cambio dramático en las últimas tres décadas. Con el advenimiento de las computadoras modernas, nuevas modalidades de imágenes tomográficas como la tomografía computarizada (TC), la resonancia magnética nuclear (RMN) y la tomografía por emisión de positrones (TEP), que ofrecen imágenes transversales que muestran diferentes órganos libres de superposiciones con una precisión sin precedentes. Incluso se puede registrar la estructura tridimensional (3D) de los órganos si se toma una secuencia de secciones transversales paralelas.⁽¹⁾

En los últimos años, debido a la necesidad de realizar un diagnóstico precoz, el esfuerzo se ha centrado en el desarrollo de métodos de segmentación para imágenes TC que permitan la identificación de características informativas de un conjunto masivo de características originales en etapas pre clínicas, antes que el daño cerebral irreversible se produzca.^(1, 2)

El procesamiento digital de imágenes se ha consolidado dentro de la radiología clínica como un amplio campo de investigación en el análisis cualitativo y cuantitativo de neuroimágenes y sus aplicaciones son muy variadas. Con estos métodos los radiólogos disponen de una exhaustiva vista de las imágenes desde el nivel macroscópico hasta el microscópico.^(3,4)



Dentro del procesamiento de imágenes una característica importante es la textura. Esta es una propiedad innata de todas las superficies, por ese motivo cuando se desea detectar la presencia de un objeto éste puede identificarse por sus características de textura, que puede ser evaluada como fina, suave, gruesa o tosca según corresponda. Básicamente, la textura es otra característica que puede ayudar a segmentar las imágenes en regiones de interés y clasificar esas regiones.^(5,6)

El análisis de texturas es una metodología emergente con aplicaciones en una amplia variedad de tópicos radiológicos. Permite la detección matemática de cambios en las señales que no son visibles entre los píxeles de la imagen, proporcionando así un método cuantitativo y reproducible para extraer características de la imagen.⁽⁶⁾

Este hecho, unido al avance de los sistemas de cómputo ha influido en que la tomografía computarizada (TC) se haya convertido en la pieza central de las imágenes craneales. En la mayoría de los países, el número de escáneres de TC supera en gran medida al de las máquinas de RMN y la TC puede ser preferible sobre la RMN en entornos de radiología de emergencia debido a su amplia disponibilidad, facilidad de acceso y excelente resolución de detalles óseos. Es valiosa en pacientes que no pueden someterse a RMN debido a dispositivos biomédicos implantados o material extraño ferro magnético.^(1,2)

La textura nos da información sobre la disposición espacial de los colores o intensidades en una imagen. Se puede obtener una mejor precisión en la clasificación en numerosos trabajos de reconocimiento de texturas debido a que sus sistemas combinan diferentes descriptores múltiples para extraer las características.⁽⁵⁾

La mayoría de los trabajos reportados en el análisis de texturas caen en la categoría de los métodos de reconocimiento de patrones. La responsabilidad para que un método de reconocimiento de patrones sea exitoso recae en un efectivo método de extracción de características. Las intensidades basadas en rasgos estadísticos han sido ampliamente usadas. Pero debido a la complejidad de la patología en el cerebro humano y la alta calidad requerida para el diagnóstico clínico, resulta que este método por sí solo no alcanza resultados aceptables. La matriz de co-ocurrencia y las wavelets basadas en rasgos de texturas son a menudo usados y alcanzan resultados prometedores.^(5,6)

El problema en la mayoría de estos trabajos es que carecen de efectividad en las estrategias de selección de características. Las características de texturas son generalmente en grandes dimensiones, pero no todas las dimensiones proveen información útil para la segmentación.⁽⁷⁻⁹⁾

En el marco de este trabajo se entrega un análisis de textura bajo la categoría de reconocimiento de patrones, esto se debe principalmente a la capacidad que tiene de



segmentar patrones de homogeneidad de una imagen de forma suficientemente apropiada como para discriminar a que clase pertenece. Así, una imagen que tiene varios patrones de intensidades diferentes (visibles o no visibles) puede mediante un análisis de textura ser particionada en regiones.

Se asume que la información de los patrones de intensidad en una imagen CT de cabeza está contenida en la relación y la disponibilidad espacial de los tonos de grises entre ellos. Esas relaciones están especificadas en la matriz de co-ocurrencia espacial (o de niveles de grises) que son computarizadas en una dirección específica entre los píxeles vecinos dentro de una ventana móvil dentro de la imagen.^(10,11)

Muchas de estas variantes se han estudiado como métodos morfométricos en el procesamiento de imágenes médicas para estudiar los cambios volumétricos en el curso del envejecimiento normal y patológico^(1, 12,13). Este hecho cobra mayor relevancia en nuestro país si se tiene en cuenta que el 20.8% de la población cubana sobrepasa los 60 años; además de presentarse en las enfermedades neurodegenerativas muy frecuentes en la población envejecida.⁽¹⁴⁾

Sin embargo, los estudios aún no son concluyentes pues los resultados dependen en gran medida de las características étnicas de la población objeto de estudio y de los métodos morfométricos utilizados^(1,13). En nuestro medio, aunque la TC a 5 mm se utiliza ampliamente en el entorno clínico, no se dispone de métodos interactivos y automáticos de segmentación para estimar el volumen de la materia cerebral a partir de imágenes de TC craneal.

Debido a lo anteriormente expuesto, el objetivo general de esta investigación es evaluar, a través de un procesamiento automático, índices de texturas homogéneas que permiten segmentar patrones de intensidad visibles y no visibles en la imagen para su aplicabilidad en la estimación volumétrica de la sustancia gris cerebral en imágenes de TC craneal.

Método

Se desarrolló un estudio retrospectivo, transversal, descriptivo y observacional en el servicio de Imagenología del Hospital Saturnino Lora de Santiago de Cuba entre julio y diciembre del 2020. Se utilizaron imágenes de TC, previo consentimiento informado, del total de los pacientes cuyos resultados fueron negativos o se informaron con el diagnóstico de atrofia cerebral, de ambos sexos y con edades comprendidas entre 35-74 años de edad. La cifra ascendió a 33 individuos. Se seleccionó este rango de edades por considerarse que alrededor de los 40 años comienza la etapa de



neurodegeneración.^(1,4) Se excluyeron del estudio los pacientes con el diagnóstico de enfermedades neurológicas y psiquiátricas, antecedentes de traumatismos craneoencefálicos, factores de riesgo que tengan efecto conocido en la estructura cerebral en el curso de enfermedades degenerativas como la ataxia espino cerebelosa, trastornos neurocognitivos de tipo familiar, trastornos esquizofrénicos y embarazo.

Con los datos obtenidos se procedió a realizar el análisis estadístico mediante el sistema SPSS (Statistical Package for the Social Sciences) versión 10.6 para Windows XP.

Se preservó el cumplimiento ético de las investigaciones biomédicas promulgados en la declaración de Helsinki y el informe de Belmont.

El escáner TC utilizado en este estudio fue el SIEMENS, mono corte. Los factores de exposición seleccionados para la tomografía computarizada fueron 80-120 kvp y 250-450 más, y el índice de ruido fue de 3. Todas las tomografías computarizadas se realizaron en modo axial con algoritmo interactivo de reconstrucción.

El paciente fue colocado en la mesa PET / CT y la cabeza fue centralizada y soportada para mantener una posición correcta y para evitar desenfoque de la imagen. Se tomó una imagen de exploración lateral para confirmar posicionamiento del paciente. Se dibujó una línea orbito-meatal y una línea en un ángulo de 15 - 20 grados y 1 cm por encima, representando la sección tomográfica más baja, que pasó a través de la base de cráneo.

El tiempo total de la TC fue de 50-60 segundos. Cada paciente tiene entre 18 a 22 cortes con un grosor de 5 mm en este estudio. Se utilizaron imágenes patrones artificiales de 512 x 512 píxeles como referencia en la obtención de patrones de intensidad. Los resultados obtenidos serán mostrados a través de imágenes segmentadas, donde cada clase representa una textura con alto índice de homogeneidad.

El tamaño de la matriz de cada segmento es de 512 x 512 píxeles y el tamaño de píxel es de 0,426 mm con un nivel de gris de 16 bits. Todo el procesamiento y la medición de imágenes axiales de TC se realizaron en la estación de trabajo, por los integrantes del equipo de investigación. Las imágenes fueron evaluadas por un especialista de segundo grado en Imagenología.

Para evaluar la aplicabilidad de los patrones de intensidad en la volumetría cerebral, se implementa un método de segmentación interactiva con tres fases que son: pre-procesamiento, extracción de características y selección de texturas.

La primera fase tiene como objetivo reducir el nivel de ruido de la imagen de entrada. La etapa inicial es la conversión a un nivel de escala de grises. En el segundo paso, se



elimina la existencia de ruido en la imagen mediante una eficiente técnica de filtrado de difusión anisotrópica.

La segunda fase es la de extracción de características, donde se realiza la detección automática de patrones de intensidades, auxiliándose del índice de homogeneidad de las combinaciones en los puntos de intensidad (píxeles) obtenidas por la Matriz de Co-ocurrencia de Nivel de Gris (GLCM por sus siglas en inglés). No se hace necesario el uso de la configuración de ventanas del enfoque clásico del GLCM, toda la información de variabilidad se obtiene de la imagen completa.

Gracias al factor de peso $(1 + (i - j)^2) - 1$ donde i y j describen los valores de intensidad del conjunto, el índice de homogeneidad obtiene pequeñas contribuciones de combinaciones no homogéneas observadas en los puntos de intensidad entre sí. El resultado es un valor del índice de homogeneidad bajo para regiones no homogéneas y un valor relativamente más alto para regiones homogéneas.

Finalmente, se segmenta la región de interés combinando información de índice de homogeneidad entre patrones con el enfoque de crecimiento de regiones en la fase de selección de características. Después de determinar los grupos o clústeres, se definen posiciones con semillas para la selección de regiones con características homogéneas. Las semillas seleccionadas marcan con su posición los patrones de intensidades que tienen que ser segmentados.

La manera de determinar un criterio cuantitativo de la segmentación efectuada se realizó a través del cálculo del coeficiente Dice, determinado por la ecuación:

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|}$$

El coeficiente Dice mide el grado de similitud entre los conjuntos, sea cual sea el tipo de elementos. Es un valor normalizado que alcanza valores cercanos a uno cuando la coincidencia es grande y cercana a cero cuando la coincidencia entre la región segmentada y la real es poca. En esta investigación se realizó una validación parcial de la segmentación, obteniéndose como coeficiente Dice 0.96.

Resultados y Discusión

En el análisis de imágenes TC de cráneo a menudo se involucran un gran número de características o rasgos, de las cuales no todas son esenciales ya que muchas son redundantes o irrelevantes. La selección de atributos o selección de características busca resolver el problema de la dimensionalidad de la información, eligiendo solo un



pequeño subconjunto de características informativas del conjunto original masivo de características.^(5,6,10) La construcción de características (o extracción de características), que también puede reducir la dimensionalidad, está estrechamente relacionada con la selección de características. La principal diferencia es que la selección de características elige un subconjunto de características originales, mientras que la construcción de características crea características novedosas a partir de las características originales.^(10,11)

Se presenta un enfoque para reconocer patrones de intensidades en un conjunto de datos de una imagen para una segmentación interactiva.

Para la evaluación mostramos los resultados de la extracción automática de rasgos homogéneos en imágenes artificiales (Fig. 1), y la selección de patrones de intensidades mediante un enfoque de crecimiento de regiones en imágenes TC de cráneo (Fig. 2).

La figura 1 (a y c) es una representación de imágenes artificiales, creadas con alto índice de homogeneidad entre clases.

Los colores en las imágenes (b y d) representan las clases de los patrones segmentados. Los valores numéricos en (b y d) representan el valor del índice de homogeneidad de cada clase.

La figura 1 (b y d) muestra los resultados satisfactorios en la segmentación de patrones de intensidades propuestos en las imágenes artificiales al coincidir con la cantidad de clases referenciadas. Se espera obtener señales de emisión con alto valor de homogeneidad entre sus píxeles adyacentes sin caer en sobre-segmentación.



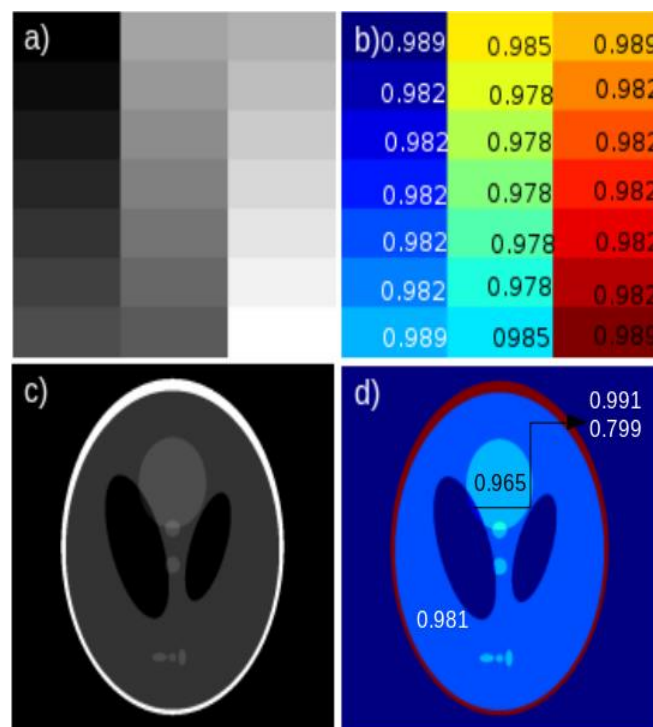


Fig.1- Segmentación de patrones de intensidades en imágenes originales y artificiales. (Elaborado por los autores).

Mediante una identificación visual se puede observar como las clases en la imagen segmentada están bien preservadas por el método. Los valores numéricos en las imágenes 1b) y 1d) indican una estimación de la homogeneidad en el área de las clases. En la imagen 1d) la pequeña región que da origen a la flecha de indicación muestra que la poca disponibilidad espacial influye directamente con su valor de homogeneidad, lo que se traduce en una señal pobre y de poca cohesión. En muchas ocasiones este efecto coincide con que la señal está siendo opacada por otra, creando la idea de que componen entre sí o que es una señal de ruido.

Debido a que algunos patrones pueden componerse entre sí, surge la segmentación interactiva. En la evaluación de su aplicabilidad en imágenes TC en la volumetría cerebral, como aparece en la secuencia de cortes que muestra la Figura 2, se utilizó como conocimiento previo la información de homogeneidad entre patrones. Con estos datos se aplicó el enfoque de crecimiento de regiones en la selección de características asignando por demanda los grupos adyacentes más homogéneos a una semilla. En los resultados, los colores reflejan el número de patrones segmentados y el proceso de



crecimiento de regiones sobre ellas a través de los grupos de puntos de intensidades seleccionados.




Fig.1- Ejemplos de segmentación de materia cerebral usando información de homogeneidad. El color verde describe a los píxeles vecinos más homogéneos a los puntos de intensidad en color rojo y en su efecto la segmentación de la materia cerebral.

El hecho de que el método utilizado es sensible al ruido también es visualmente evidente en estos resultados por la distorsión entre las regiones. Sin embargo, la característica de las texturas en imágenes de cráneo TC, podría conducir a direcciones interesantes para futuras investigaciones.

El volumen de la materia cerebral es una medida importante para estudios cuantitativos de atrofia cerebral asociada con envejecimiento saludable y otras enfermedades neurodegenerativas. Específicamente, debido a que la tasa de atrofia cerebral en la salud difiere de la observada en muchas enfermedades del sistema nervioso central, la volumetría cerebral se puede usar junto con otras medidas anatómicas y funcionales para estimar el riesgo de mortalidad y otros parámetros que



son de gran interés para los médicos, científicos biomédicos, demógrafos y epidemiólogos. ^(1, 15,16)

La capacidad de segmentar los tejidos blandos del cerebro a partir de la TC depende en gran medida de la relación entre el contraste y el ruido de la imagen (CNR por sus siglas en inglés). En la TC, la propia CNR depende de la configuración del tubo, el método de reconstrucción iterativo, la dosis de radiación y otros factores; en dosis estándar, las radio densidades promedio de sustancia gris (SG) y sustancia blanca (SB) han sido reportadas como 38.7 ± 2.2 unidades Hounsfield (HU) y 31.8 ± 2.3 HU, respectivamente, lo que resulta en una atenuación promedio de rayos X de 5 HU. ^(17,18)

Al digitalizar una imagen, la probabilidad de introducción de ruido y el degrade de la imagen es muy alta, lo que provoca pérdida de calidad. Reducir el ruido presente en las imágenes conduce a la obtención de áreas más homogéneas que pueden ser delineadas con menor esfuerzo, eliminando información que no se considera relevante, aunque se puede comprometer la detección de pequeños elementos importantes. Por este motivo, antes de hacer cualquier análisis, es fundamental mejorar la calidad de las imágenes. No obstante, debe reiterarse que, cuando está disponible y es de suficiente calidad, la resonancia magnética es con mucho preferible a la tomografía computarizada para la segmentación de los tejidos blandos del cerebro. ⁽¹⁹⁾

Hay muy pocos estudios donde se apliquen métodos con los que nuestro enfoque puede compararse cuantitativamente. Deleo y co-autores ⁽²⁾ propusieron un método semiautomático. Se pidió a los usuarios que seleccionaran manualmente puntos representativos de líquido cefalorraquídeo (LCR), materia gris (GM) y materia blanca (WM) en la región superior al tercer ventrículo para evitar artefactos. Los umbrales se calcularon en base a la especificación manual de los CSF, GM y WM representativos. Sus inconvenientes incluyen: la especificación manual es tediosa y propensa a errores cuando no ha habido entrenamiento, y la información espacial no se explota para tratar tejidos que tienen una intensidad superpuesta.

Ruttimann y colegas propusieron utilizar criterios de varianza máxima entre clases para diferenciar los tejidos duros y blandos, y el LCR se segmentó utilizando una técnica de umbral local basada en el principio de máxima entropía. El procesamiento se limitó a cortes axiales seleccionados. ⁽¹⁸⁾

Soltanian-Zadeh y Windhampropusieron encontrar contornos cerebrales de forma semiautomática: especificar manualmente los umbrales en diferentes regiones para binarizar cortes de TC, usar el seguimiento de bordes para encontrar contornos, usar multi-resolución para resolver contornos rotos y especificar puntos de semilla para recoger el contorno deseado. ⁽²⁰⁾ La gran cantidad de intervención del usuario es su principal inconveniente. No obstante, los avances recientes en la tecnología de los



escáneres de TC y la mejora en la calidad de la imagen de TC sugieren que la capacidad de distinguir los tipos de tejidos blandos mediante TC es cada vez más factible.

Gupta y co-autores, por ejemplo, propusieron un método de segmentación heurística que aprovecha el umbral de intensidad para distinguir WM de GM y de CSF. ⁽²¹⁾ Sin embargo, la eficacia de este método solo se postuló sobre la base de regiones cerebrales fiduciales de alta confianza contorneadas manualmente y en ausencia de confirmación independiente por otras técnicas de imagen.

Por el contrario, Kemmling y co-autores introdujeron un atlas probabilístico basado en volúmenes de resonancia magnética previamente segmentados co-registrados con imágenes de TC para llevar a cabo la clasificación de tejido, ⁽²²⁾ pero ninguna validación cuantitativa de este enfoque fue implementado en su estudio.

Más recientemente, Manniesing y colaboradores propusieron un método para la segmentación basada en TC que requiere correcciones manuales utilizando software dedicado y que también se basa en el promedio de los volúmenes de TC adquiridos longitudinalmente del mismo sujeto después de la administración de un agente de contraste para mejorar la SNR. ⁽²³⁾ Se desconoce la precisión del enfoque de estos autores en el escenario en el que no se dispone de más de una tomografía computarizada. Además, el promedio de los volúmenes de TC adquiridos longitudinalmente puede producir resultados indeseables en los casos en los que la evolución de la patología entre puntos temporales modifica la forma y estructura del cerebro, por ejemplo, en un accidente cerebro vascular. Además, el método de Manniesing implica la segmentación de SG, SB y LCR de la TC con contraste.

Conclusiones

El procesamiento automático utilizado para la detección de patrones de intensidad o densidad demostró su aplicabilidad en la segmentación interactiva de la materia cerebral en imágenes CT de cabeza.

La fortaleza del método utilizado es la información de homogeneidad derivada del análisis de texturas y la precisión de segmentación de materia cerebral alcanzada por las entradas directas del usuario mediante un enfoque de crecimiento de regiones.

El método de segmentación descrito muestra buenos pronósticos para la segmentación automática y semi-automática en el campo de las neurociencias y en la práctica clínica habitual, pudiendo ser utilizado como una herramienta para predecir tempranamente los signos imagenológicos en las enfermedades neurodegenerativas y en el curso del envejecimiento.



Referencias

1. Hernández Cortés K, Mesa Pujals AA, García Gómez O, Montoya Pedrón A. Morfología del envejecimiento cerebral: La morfometría como herramienta para la cuantificación de los cambios degenerativos cerebrales. En *Morfovirtual 2020* [Internet]; 1-30 Noviembre de 2020; Cuba. Cuba: MINSAP; 2020 [citado 2021 Mar]. Disponible en: <https://www.google.com/search?q=Morfolog%C3%ADa+del+envejecimiento+cerebral%3A+La+morfometr%C3%ADa+como+herramienta+para+la+cuantificaci%C3%B3n+de+los+cambios+degenerativos+cerebrales.+&ie=utf-8&oe=utf-8&client=firefox-b-ab>
2. De Leo JM, Schwartz M, Creasey H, Cutler N, Rapoport SI. Computer assisted categorization of brain computerized tomography pixels into cerebrospinal fluid, white matter, and gray matter. *Computers and biomedical research* [Internet]. 1985 [cited 2021 Mar];18(1). Available from: <https://pubmed.ncbi.nlm.nih.gov/3838273/>
3. Zhao L, Matloff W, Ning K, Kim H, Dinov ID, Toga AW. Age-related differences in brain morphology and the modifiers in middle-aged and older adults. *Cerebral Cortex* [Internet]. 2019 [cited 2021 Mar];29(10):4169-93. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6931275/>
4. Fernández Viadero C, Verduga Vélez R, Crespo Santiago D. Deterioro Cognitivo Leve. Patrones de envejecimiento cerebral. *Rev Esp Geriatr Gerontol* [Internet]. 2017 [citado 13 Feb 2020];52(Supl 1):7-14. Disponible en: <https://www.elsevier.es/es-revista-revista-espanola-geriatria-gerontologia-124-pdf-S0211139X18300738>
5. Kassner A and Thornhill RE. Texture analysis: A review of neurologic MR imaging applications. *American Journal of Neuroradiology* [Internet]. 2010 [cited 2021 Feb 13];31:809–16. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7964174/>
6. Castellano G, Bonilha L, Li LM, Cendes F. Texture analysis of medical images. *Clin Radiol* [Internet]. 2004 [cited 2021 Feb 13];59:1061–9. Available from: <http://facweb.cdm.depaul.edu/research/vc/medix/2011/papers/reuweek5.pdf>
7. Kollem S, Reddy KR, Rao DS. A review of image denoising and segmentation methods based on medical images. *International Journal of Machine Learning and Computing* [Internet]. 2019 Jun [cited 2021 Mar];9(3):288-95. Available from: <http://www.ijmlc.org/vol9/800-L0252.pdf>
8. Sakib S, Siddique M, Bakr A. Unsupervised Segmentation Algorithms' Implementation in ITK for Tissue Classification via Human Head MRI Scans. *ArXiv e-Journal* [Internet]. 2019 [cited 2021 Mar]:[about 4 p.] Available from: <https://arxiv.org/ftp/arxiv/papers/1902/1902.11131.pdf>



9. Irimia A. Cross-Sectional Volumes and Trajectories of the Human Brain, Gray Matter, White Matter and Cerebrospinal Fluid in 9473 Typically Aging Adults. *Neuroinformatics* [Internet]. 2021 [cited 2021 Mar];19. Available from: <https://link.springer.com/article/10.1007/s12021-020-09480-w>
10. Alharan AF, FatlawiHK, Ali NS. A cluster-based feature selection method for image texture classification. *Indonesian Journal of Electrical Engineering and Computer Science* [Internet]. 2019 Jun [cited 2021 Mar];14(3):1433-42. Available from: <http://ijeecs.iaescore.com/index.php/IJE ECS/article/download/16643/12225>
11. Heurtier A. Texture feature extraction methods: A survey. *IEEE Access* [Internet]. 2019 [cited 2021 Mar];7:8975-9000. Available from: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8600329>
12. Sudheesh KV, Basavaraj L. Impact of Statistical Texture Feature Abstraction Based Classification Applied for Detection of Abnormalities in Brain CT Images. *International Journal of Pure and Applied Mathematics* [Internet]. 2018 [cited 2021 Mar];118(18):2645-54. Available from: <https://acadpubl.eu/jsi/2018-118-18/articles/18c/42.pdf>
13. Farokhian F, Yang CH, Beheshti I, Matsuda H, Wu S. Age-Related Gray and White Matter Changes in normal adult Brains. *Aging and Disease* [Internet]. 2017 Dec [cited 2019 Ene 10];8(6):899-909. Available from: <http://www.aginganddisease.org/EN/10.14336/AD.2017.0502>
14. Delgado Vergara T, Pereira Pérez J. Retos del derecho ante el envejecimiento poblacional en Cuba. *Anales de la Academia de Ciencias de Cuba* [Internet]. 2019 [citado 18 Feb 2021];9(3):182-4. Disponible en: <http://revistaccuba.sld.cu/index.php/revacc/article/view/695/713>
15. Hagenauer MH, Schulmann A, Li JZ, Vawter MP, Walsh DM, Thompson RC, et al. Inference of cell type content from human brain transcriptomic datasets illuminates the effects of age, manner of death, dissection, and psychiatric diagnosis. *PloS One* [Internet]. 2018 [cited 2021 Mar];13(7):[about 31 p.]. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6049916/>
16. Nissim NR, O'Shea AM, Bryant V, Porges EC, Cohen R, Woods AJ. Frontal structural neural correlates of working memory performance in older adults. *Front Aging Neurosci* [Internet]. 2017 [cited 2021 Mar];8:[about 9 p.]. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5210770/>
17. Haralick RM, Shapiro LG. Image segmentation techniques. *Computer vision, graphics, and image processing* [Internet]. 1985 [cited 2021 Mar];29(1):100-32. Available from: https://haralick.org/journals/image_segmentation.pdf
18. Ruttimann UE, Joyce EM, Rio DE, Eckardt MJ. Fully automated segmentation of cerebrospinal fluid in computed tomography. *Psychiatry Research: Neuroimaging* [Internet]. 1993 [cited 2021 Mar];50(2). Available from: <https://www.semanticscholar.org/paper/Fully-automated->



[segmentationofcerebrospinalfluidRuttimannJoyce/e4dd84856d2f15220b8241d84a247d9999bf9438](https://doi.org/10.1038/s41598-017-00239-z)

19. Daudt RC, Le Saux B, Boulch A, Gousseau Y. Guided anisotropic diffusion and iterative learning for weakly supervised change detection. In 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW) [Internet]; 2019 June 16-17; Long Beach, CA, USA. 2020 Apr [cited 2021 Feb]. USA: IEEE. Available from: <https://ieeexplore.ieee.org/abstract/document/9025678>
20. Soltanian Zadeh H, Windham JP. A multiresolution approach for contour extraction from brain images. Medical Physics [Internet]. 1997 Dec [cited 2021 Mar];24(12). Available from: <https://aapm.onlinelibrary.wiley.com/doi/abs/10.1118/1.598099>
21. Gupta V, Ambrosius W, Qian G, Blazejewski A, Kazmierski R, Urbanik A, et al. Automatic segmentation of cerebrospinal fluid, white and gray matter in unenhanced computed tomography images. Acad Radio [Internet]. 2010 [cited 2021 Mar];17(11). Available from: <https://pubmed.ncbi.nlm.nih.gov/20634108/>
22. Kemmling A, Wersching H, Berger K, Knecht S, Groden C, Nölte I. Decomposing the hounsfield unit. Clin Neuroradiol [Internet]. 2012 [cited 2021 Mar];22(1). Available from: <https://pubmed.ncbi.nlm.nih.gov/22270832/>
23. Manniesing R, Oei MT, Oostveen LJ, Melendez J, Smit EJ, Platel B, et al. White matter and gray matter segmentation in 4D computed tomography. Scientific Reports [Internet]. 2017 [cited 2021 Mar];7(1):[about 11 p.]. Available from: <https://doi.org/10.1038/s41598-017-00239-z>

Conflicto de interés

Los autores declaran no tener conflicto de intereses.

Contribución de autoría

Ing. Adrián Alberto Mesa Pujals: dirigió el proyecto, proporciono documentación, realizó el análisis y discusión de los resultados, genero estadísticas y elaboró el informe final.

M.Sc. Katherine Susana Hernández Cortés, Dra. Solangel Bolaños Vaillant : aplicaron métodos científicos para la búsqueda y recolección de información, realizaron análisis y llegaron a conclusiones de importancia para la investigación.

Dr.C. Arquímedes Montoya Pedrón, Dr.C. Eloy Daniel Álvarez Guerra: aplicaron métodos científicos para la búsqueda y recolección de información, realizaron análisis, llegaron a conclusiones de importancia para la investigación y aprobaron el informe final.

