



1. DATOS BÁSICOS DEL TFG:

Título: Análisis fractal para describir patrones de mimetismo tisular en imagen histológica.

Descripción general (resumen y metodología):

El diagnóstico a partir de imágenes médicas se somete usualmente al sesgo de la subjetividad humana. Pequeños cambios en la textura o morfología celular pueden ser difíciles de cuantificar a simple vista, generando variabilidad en el pronóstico.

En este trabajo se propone la revisión bibliográfica de cómo los modelos analíticos cuantitativos pueden estandarizar el proceso, en concreto en muestras histológicas. Se propone hacer un recorrido de los algoritmos con uso de geometría fractal combinados con técnicas de Inteligencia Artificial (Machine Learning) para estudiar los diferentes patrones artificiales en los tejidos y mejorar la precisión del diagnóstico o de la clasificación.

La irregularidad de las estructuras biológicas hace que la geometría euclídea clásica resulte insuficiente para modelarlas. Los fractales permiten describir la complejidad topológica y la textura intrínseca de las estructuras biológicas, ya que modelan la "rugosidad" natural de las superficies (Chen et al., 1989). La dimensión fractal se utiliza como un potente extractor de características para discriminar entre tejidos normales y patológicos. Utilizando algoritmos matemáticos como el Box-Counting, es posible asignar un valor numérico exacto a la "rugosidad" de una muestra celular. La premisa matemática fundamental es que la alteración patológica del tejido modifica su firma fractal, permitiendo discriminar entre tejido sano y maligno de forma objetiva (evita errores comunes de herramientas al estudiar lesiones con bordes difusos o poco contraste). Además, el análisis fractal se usa para el realce y la detección de bordes, permitiendo resaltar los límites del tejido sin amplificar el ruido (Chen et al., 1989).

Usualmente, el desarrollo de sistemas de clasificación médica está limitado por la falta de bases de datos masivas. Por tanto, se utiliza el Transfer Learning para sobrepasar esta barrera (Mabrouk et al., 2022). Esta técnica aprovecha redes neuronales convolucionales preentrenadas, adaptando (CNNs) preentrenadas para que actúen como potentes "extractoras de características" visuales sobre las imágenes histológicas (Castro Escribano, 2024). La imagen histológica pasa a través de la red y se comprime en un vector numérico que condensa la información semántica. Posteriormente, podemos aplicar algoritmos ya implementados para clasificar el tejido histológico, predecir tumores o evaluar el grado de adaptación celular. Esta propuesta se basa en estudios recientes (como el de Molina-Molina et al., 2020) que demuestran el potencial de combinar el enfoque matemático y el computacional. Al extraer las firmas fractales de la imagen histológica y concatenarlas con las características abstractas extraídas por las redes neuronales, se obtiene un modelo de clasificación híbrido. Mientras el Transfer Learning detecta patrones estructurales globales, el análisis fractal cuantifica el "caos" microscópico. (Ribeiro et al., 2016).

Tipología: Estudio de casos, teóricos o prácticos, relacionados con la temática del Grado.

Objetivos planteados:

- 1) Describir el potencial del análisis y la dimensionalidad fractal en la imagen médica
- 2) Explorar algoritmos tipo box counting en R o Python para cuantificar patrones y discriminar imágenes histológicas.

Bibliografía básica:

Castro Escribano, J. (2024). Análisis de concordancia en decisión de imagen histológica [Trabajo de Fin de Grado]. Universidad de Granada, Departamento de Estadística e Investigación Operativa.
Chen, C.-C., DaPonte, J. S., & Fox, M. D. (1989). Fractal feature analysis and classification in medical imaging. *IEEE Transactions on Medical Imaging*, 8(2), 133–142.
Mabrouk, A., Dahou, A., Abd Elaziz, M., Díaz Redondo, R. P., & Kayed, M. (2022). Medical image classification using transfer learning and chaos game optimization on the internet of medical things. *Computational Intelligence and Neuroscience*, 2022, 9112634. <https://doi.org/10.1155/2022/9112634>

Molina-Molina,E.O.,Solorza-Calderón,S.,& Álvarez-Borrego,J.(2020). Classification of dermoscopy skin lesion color-images using fractal-deep learning features. Applied Sciences, 10(17), 5954.
Ribeiro, E., Uhl, A., Wimmer, G., & Häfner, M. (2016). Exploring deep learning and transfer learning for colonic polyp classification. Computational and Mathematical Methods in Medicine, 2016.

Recomendaciones y orientaciones para el estudiante:

Es aconsejable un manejo, al menos inicial, de Latex, R, Orange, Python y Matlab. Probar algunos ejemplos de los siguientes:

https://www.rdocumentation.org/packages/VoxR/versions/1.0.0/topics/box_counting

<https://sethna.lassp.cornell.edu/Plasticity/Tools/boxcounting.html>

https://www.researchgate.net/publication/339442578_Box-Counting_Method_in_Python_for_Fractal_Analysis_of_Biomedical_Images

<https://math.stackexchange.com/questions/2517426/box-counting-method-for-fractal-dimension>

Plazas: 1

2. DATOS DEL TUTOR/A:

Nombre y apellidos: JUAN MANUEL MELCHOR RODRÍGUEZ

Ámbito de conocimiento/Departamento: ESTADÍSTICA E INVESTIGACIÓN OPERATIVA

Correo electrónico: jmelchor@ugr.es

3. COTUTOR/A DE LA UGR (en su caso):

Nombre y apellidos:

Ámbito de conocimiento/Departamento:

Correo electrónico:

4. COTUTOR/A EXTERNO/A (en su caso):

Nombre y apellidos:

Correo electrónico:

Nombre de la empresa o institución:

Dirección postal:

Puesto del tutor en la empresa o institución:

Centro de convenio Externo:

5. DATOS DEL ESTUDIANTE:

Nombre y apellidos: Alba Gómez Román

Correo electrónico: agomrom@correo.ugr.es