

## PROGRAMA DE INCENTIVOS PARA LA FORMACIÓN DE DOCENTES-INVESTIGADORES

Nombre del programa de posgrado: Maestría en Ciencias de la Computación

Categorización PRONII: No categorizada

Nombre de la Institución: Facultad Politécnica - UNA

Vinculación a Proyectos I+D: Programa de Incentivos

Nombre de la beneficiaria: Claudia Patricia Lezcano Giardina

Centro de investigación: Facultad Politécnica - UNA

Publicaciones realizadas durante el programa: Presentación en modalidad póster del trabajo “Correlation between image quality measurement of different image enhancement algorithms and Cascade R-CNN detection results applied to teeth detection in panoramic X-Ray images” en el XL Congreso Nacional de Matemática Aplicada e Computacional - CNMAC 2021.

Presentación del artículo “Correlation Between Quality Evaluation Metrics and Teeth Detection Results in Panoramic X-rays using Deep Learning” 18<sup>th</sup> World Congress of Medical and Health Informatics – MedInfo 2021.

Título de tesis: Correlation between Image Quality Metrics of Different Image Enhancement Techniques Applied to Panoramic X-ray Images and the Teeth Detection Results of Deep Learning Architectures

### RESUMEN

Las imágenes de rayos X dentales complementan el examen clínico, ayudan en el proceso de diagnóstico y permiten a los profesionales planificar el tratamiento adecuado para los pacientes. Interpretar estas imágenes es una tarea ardua propensa a un diagnóstico erróneo por fatiga o falta de experiencia profesional. Por ello, se ha venido trabajando en el desarrollo de sistemas computacionales para el análisis de estas imágenes, con los enfoques de aprendizaje profundo centrados en la detección y segmentación automática de los dientes. Sin embargo, estas son tareas complejas, especialmente en imágenes panorámicas, que son uno de los exámenes más solicitados, ya que permiten la visualización del conjunto total de dientes. Además, los resultados de detección de sistemas automáticos están sujetos a altos estándares de exactitud para su uso clínico, alcanzar dichos estándares es un desafío inclusive para los métodos de detección de objetos de última generación. Dado que la implementación de técnicas de preprocesamiento ha demostrado ser un factor diferenciador entre algoritmos de aprendizaje profundo con la misma arquitectura, este trabajo consistió en utilizar diferentes Técnicas de Realce de Imagen (TRI) como preprocesamiento para determinar qué características de la imagen se correlacionan con mejoras en la detección de dientes en imágenes panorámicas realizadas por cinco arquitecturas de detección.

### OBJETIVOS

- Determinar la relación entre las características de imágenes panorámicas realizadas con diferentes TRI y el impacto en la detección de dientes de arquitecturas de aprendizaje profundo.

### APORTES DE LA INVESTIGACIÓN

- De acuerdo con la literatura revisada, ningún estudio ha analizado el efecto de varias TRI aplicadas como preprocesamiento en la detección de dientes en imágenes panorámicas ni encontrado la relación entre las características de las imágenes y los resultados en la detección de dientes de diferentes algoritmos de detección de aprendizaje profundo.
- La sensibilidad de los resultados de la detección hacia las TRI depende de la arquitectura.
- Algunas métricas de calidad de imagen muestran una relación más fuerte con una métrica de evaluación de detección.

### ACTIVIDADES REALIZADAS

Las imágenes utilizadas en los experimentos pertenecen a un conjunto de imágenes panorámicas públicamente disponible [1]. Del conjunto, 300 imágenes fueron seleccionadas, respetando la variabilidad de este, y recortadas para reducir el área de búsqueda de dientes. Seguidamente se prepararon las anotaciones, las cuales fueron corregidas y validadas por dos odontólogos expertos. A continuación, a las 300 imágenes se les aplicaron 10 TRI, las cuales consisten en 2 algoritmos de reducción de ruido, las operaciones morfológicas dilatación y erosión, 1 filtro de realce de bordes, y 5 técnicas de realce de contraste. Las imágenes originales y las realizadas fueron luego usadas para entrenar 11 modelos en 5 arquitecturas de detección de objetos. Las arquitecturas seleccionadas fueron Faster R-CNN [2], RetinaNet [3], Cascade R-CNN [4], FCOS [5] y YOLOv3 [5]. Los 11 modelos se refieren a 1 modelo entrenado con las imágenes originales, el modelo base, y 10 modelos entrenados con una TRI aplicada a las imágenes como preprocesamiento. El siguiente paso consistió en seleccionar los mejores pesos de cada arquitectura para realizar la inferencia en el conjunto de imágenes correspondiente al testeo. La detección realizada por los modelos fue evaluada al medir la Exactitud, Precisión y Sensibilidad, mientras que varias Métricas de Calidad de Imagen (MCI) fueron

consideradas para evaluar los cambios en las características del conjunto de testeo. Finalmente, se procedió a calcular la correlación entre los valores de las MCI y de las métricas de evaluación de detección. La figura 1 muestra un diagrama de los pasos seguidos para obtener los resultados del trabajo.

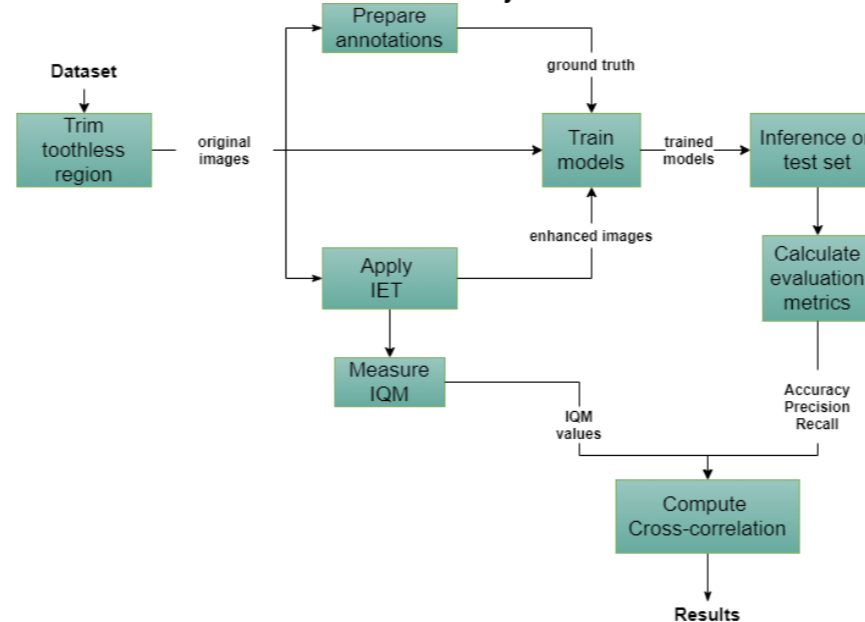


Figura 1. Diagrama de pasos seguidos.

### RESULTADOS OBTENIDOS

Los resultados de correlación entre las MCI y las métricas Exactitud, Precisión y Sensibilidad son mostrados a través de mapas de calor en la Figura 2. En los 5 mapas, correspondientes a cada arquitectura usada, vemos relaciones negativas comunes. Dichas relaciones nos indican que un excesivo cambio en el brillo medio y contraste global de las imágenes repercutirá negativamente en la Precisión alcanzada por un modelo, mientras que el incremento en el contraste local afecta a la Sensibilidad.

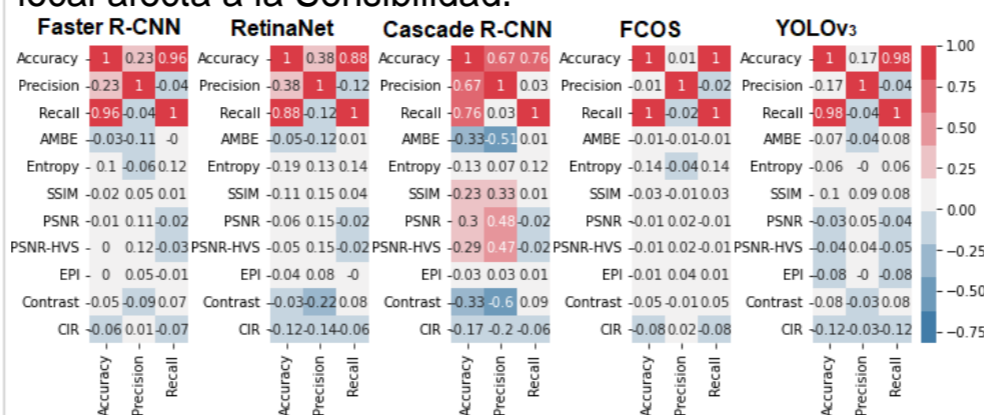


Figura 2. Mapas de calor de correlaciones.

En lo que respecta a las relaciones positivas, las más fuertes se presentan en el mapa de calor de Cascade R-CNN. Estas relaciones nos indican que realzar los detalles de las imágenes permitirá alcanzar mejores valores de Sensibilidad. Mientras que preservar el brillo medio y contraste de las imágenes, introduciendo el menor ruido posible, repercute positivamente en la Precisión.

### CONCLUSIÓN

La selección de una TRI a ser aplicada como preprocesamiento para mejorar resultados de detección obtenidos por una arquitectura de aprendizaje profundo debe realizarse tras pruebas pertinentes que determinen si efectivamente la TRI será capaz de obtener los resultados deseados. Las métricas de evaluación de detección se ven afectadas por cambios de diferentes características de las imágenes realizadas. Respecto a este punto, la Precisión se ve afectada negativamente por cambios importantes en el contraste global y brillo medio de las imágenes, mientras que la Sensibilidad por cambios en el contraste local de las mismas. Por su parte, la Precisión se ve afectada positivamente por una preservación de las características generales de las imágenes, y la Sensibilidad, por una mejora en los detalles de la imagen.

### VISIÓN Y PLANES FUTUROS

- Realizar los experimentos con un número mayor de imágenes panorámicas.
- Realizar los experimentos al resolver una tarea distinta como la segmentación.
- Determinar la correlación entre las características de imágenes realizadas y los parámetros de arquitecturas de aprendizaje profundo.

### REFERENCIAS

- [1] Silva, G., Oliveira, L., & Pithon, M. (2018). Automatic segmenting teeth in x-ray images: Trends, a novel data set, benchmarking and future perspectives. *Expert Systems with Applications*, 107, 15-31. <https://doi.org/10.1016/j.eswa.2018.04.001>
- [2] Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39. <https://doi.org/10.1109/TPAMI.2016.2577031>
- [3] Lin, T.-Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2018). Focal loss for dense object detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42, 318-327. <https://doi.org/10.1109/TPAMI.2018.2858826>
- [4] Tian, Z., Shen, C., Chen, H., & Tong, H. (2019). FCOS: Fully convolutional one-stage object detection, 9626(9635). <https://doi.org/10.1109/ICCV.2019.00972>
- [5] Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement.

“Este programa de posgrado fue cofinanciado por el Consejo Nacional de Ciencia y Tecnología - CONACYT con recursos del FEEI”