

SISTEMA DE CLASIFICACIÓN DE PATOLOGÍAS RENALES EN TC MEDIANTE MACHINE LEARNING



UNIVERSIDAD
MODELO

Ian Herrera Vázquez
Ingeniería Biomédica 8° Semestre

1 INTRODUCCIÓN

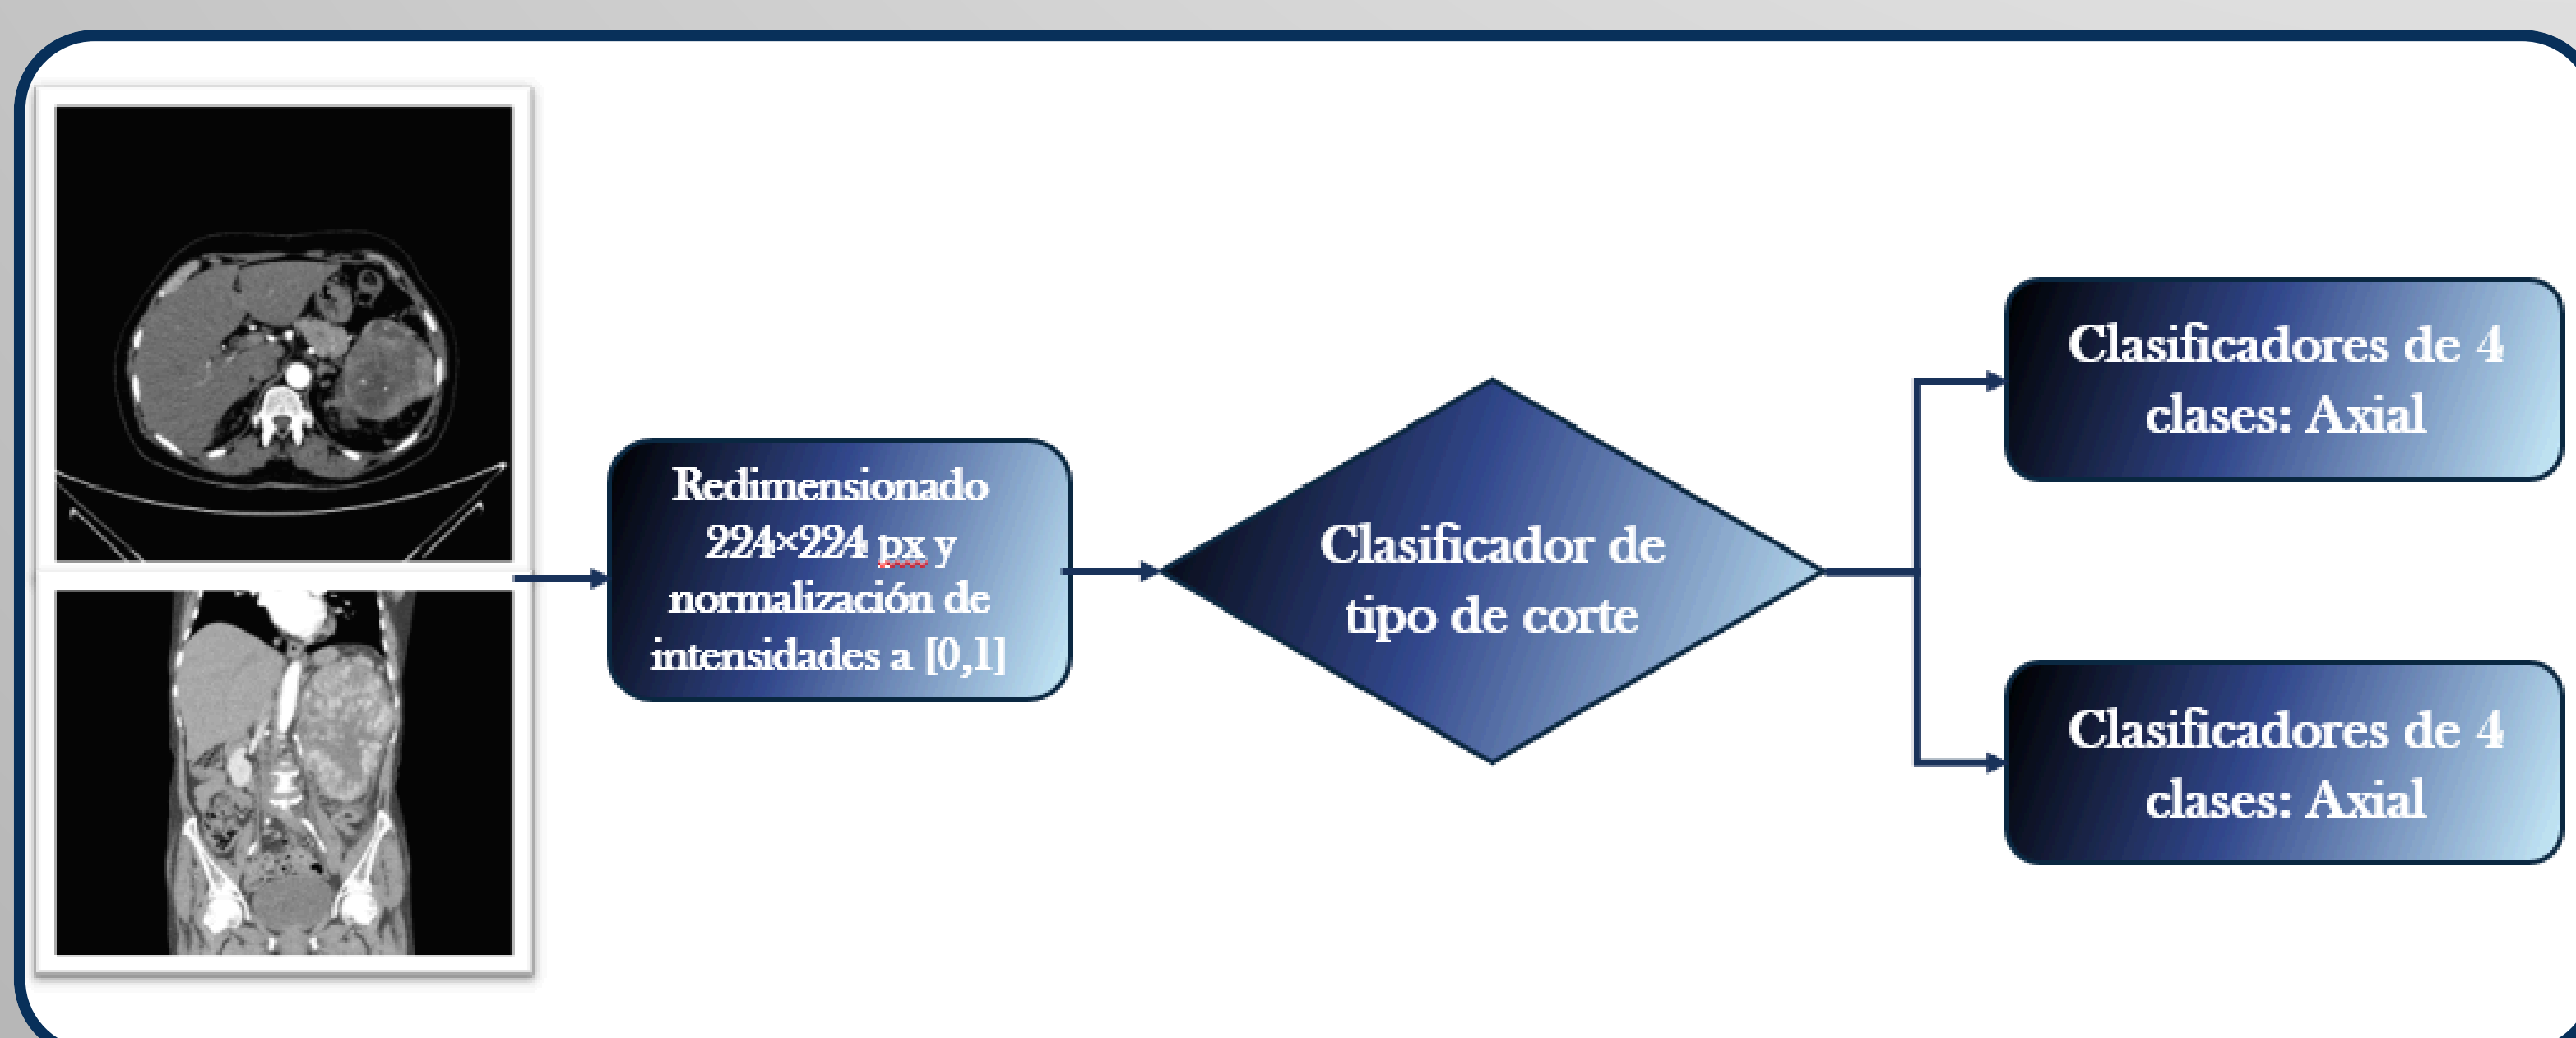
La radiología enfrenta una sobrecarga laboral relevante. El IMSS atiende +78mil estudios radiológicos diarios con 7 mil radiólogos, mientras que globalmente los estudios de TC crecieron más del 500% entre 2006 y 2020.

Esto lleva a los especialistas a invertir tiempo en estudios sin hallazgos, incrementando la fatiga y el riesgo de error diagnóstico. Trabajos recientes demuestran que la IA para excluir estudios normales puede reducir el tiempo de lectura sin aumentar el error clínico, con sistemas logrando reducción potencial de 15% en la carga laboral.

Este trabajo propone un sistema de clasificación automática de cortes de TC renal como herramienta de apoyo al radiólogo.

2 METODOLOGÍA


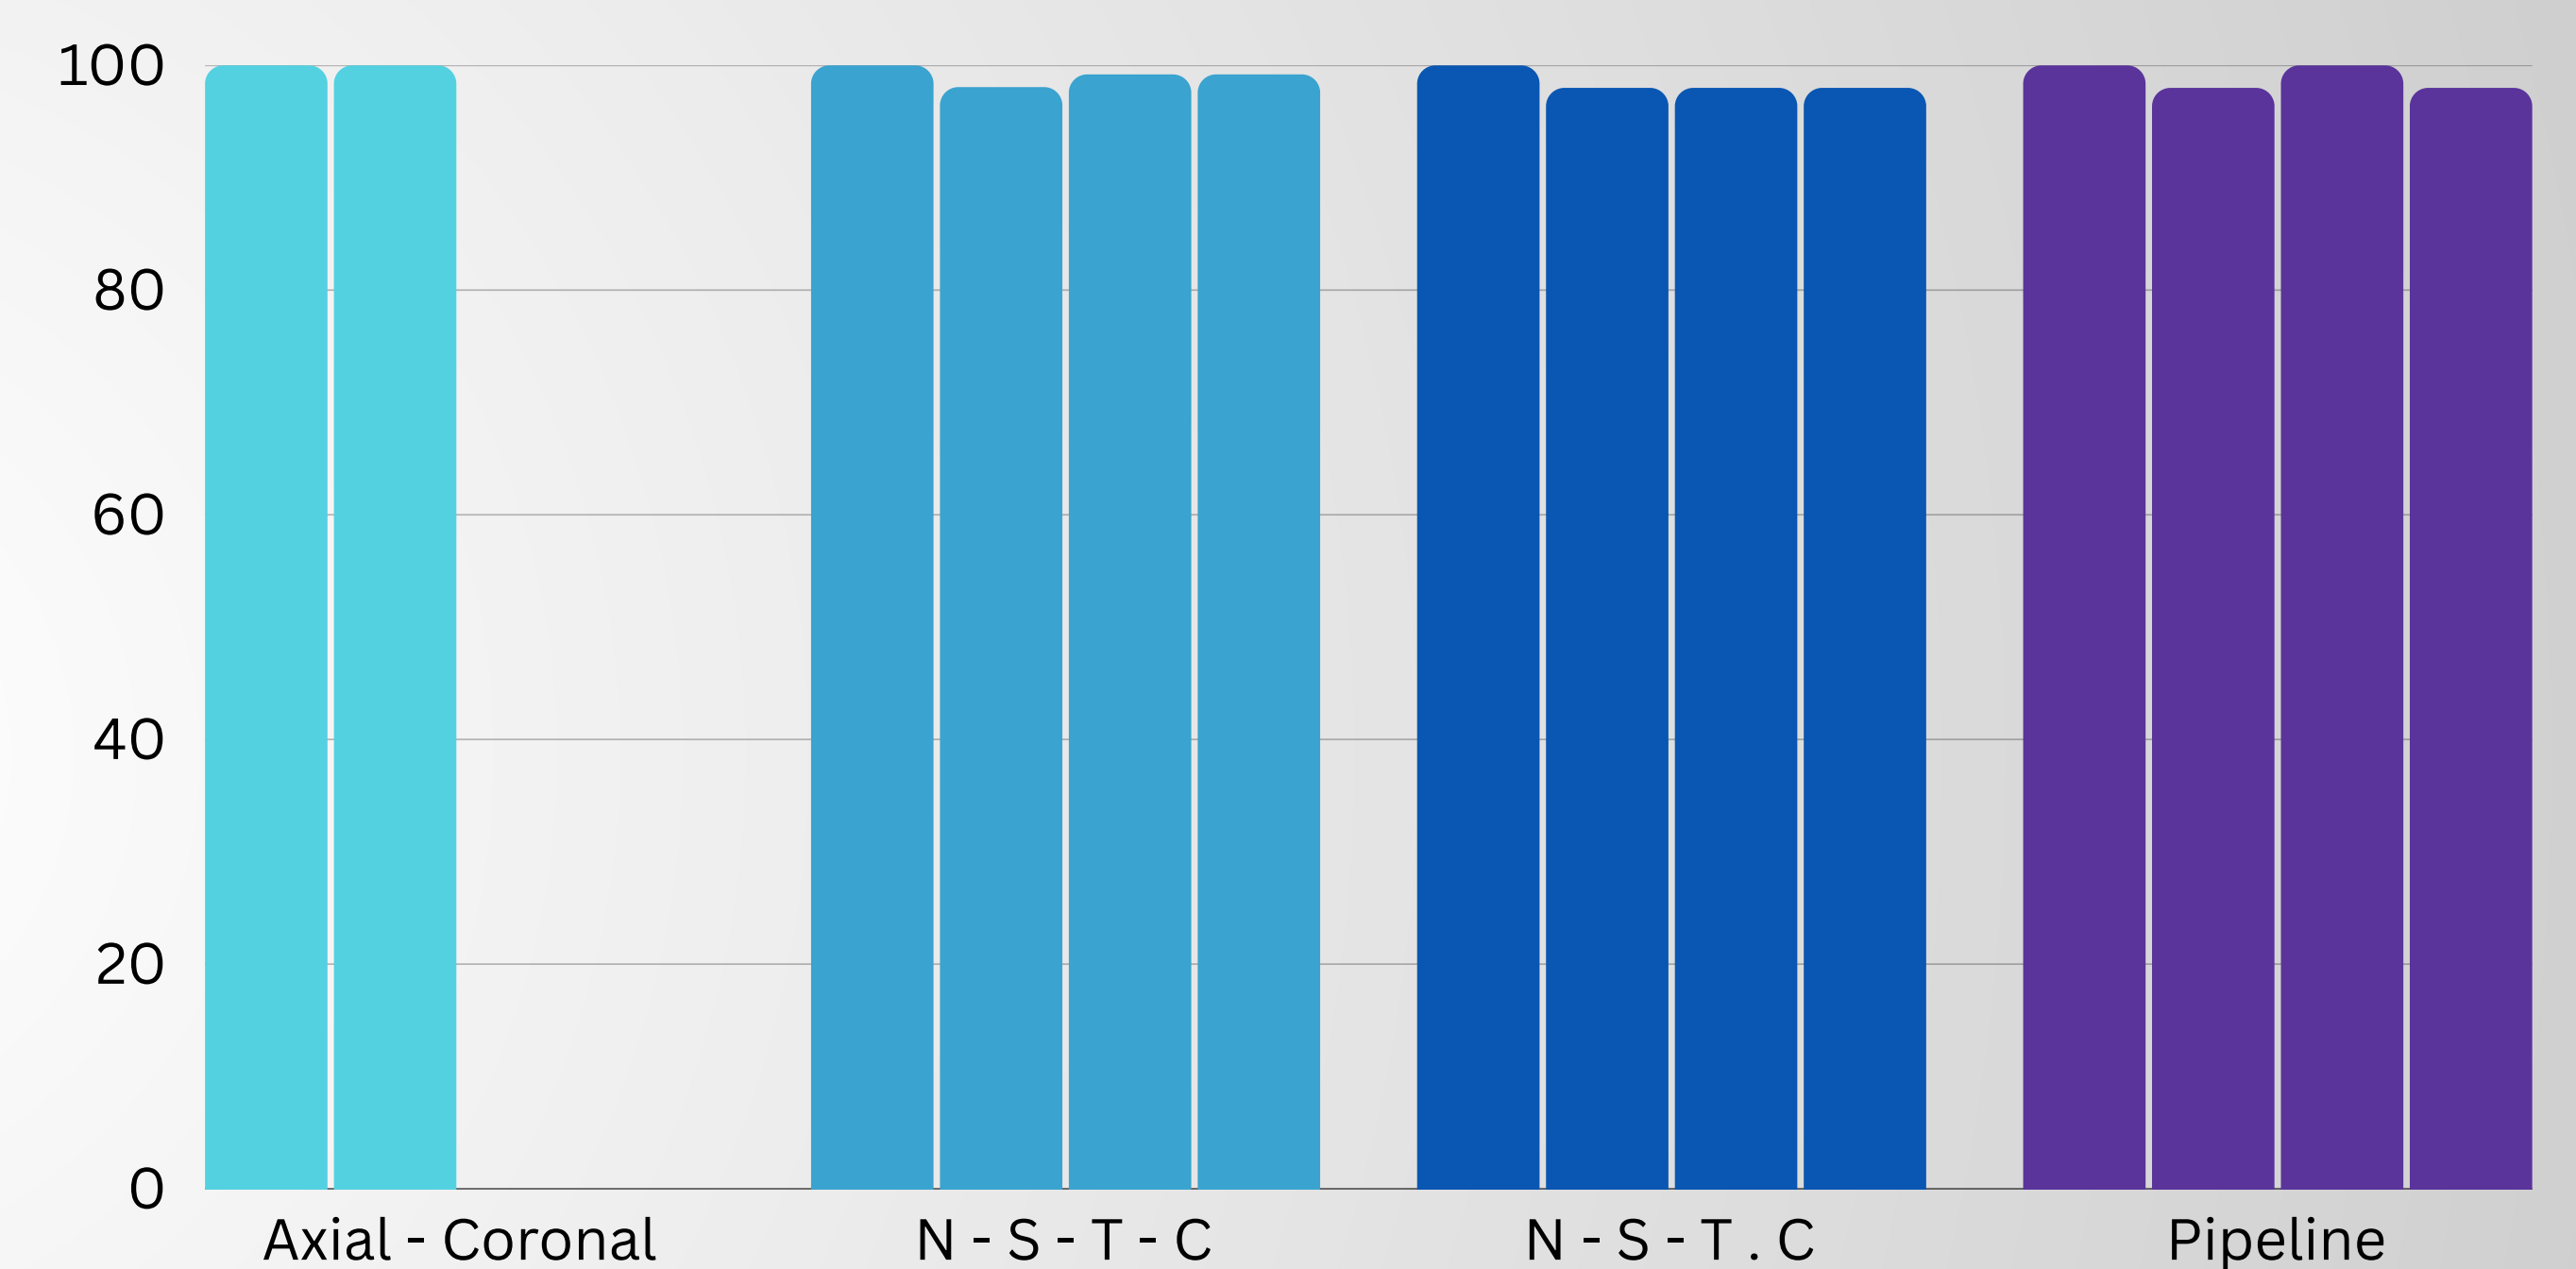
Se utilizó un dataset de 12,400 imágenes JPG de cortes 2D de TC abdominal (de Kaggle), dividido en 4 clases: Normal, Quiste, Piedra y Tumor. Se subdividió en 80% para entrenamiento, 10% para validación y 10% para pruebas. Se implementó un *pipeline* en tres etapas con tres modelos de MobileNetV2 con fine-tuning:



3 RESULTADOS

El clasificador de tipo de corte tuvo una precisión, sensibilidad y F1-score de 1 para ambas clases en el conjunto de prueba. El clasificador de cuatro clases y el flujo de trabajo completo tuvieron una precisión global de 99%.

Ninguna imagen Normal fue clasificada como patológica ni viceversa. Los únicos errores ocurrieron entre las clases Quiste y Piedra, que son categorías con cierta similitud morfológica.



4 CONCLUSIONES Y DISCUSIÓN

El sistema demostró viabilidad técnica para la clasificación automática de patologías renales en cortes de TC con recursos computacionales accesibles, resolviendo la heterogeneidad del dataset entre tipos de corte.

Una limitación importante es la posible sobreestimación del desempeño debido a la división por imagen y no por paciente. Se requiere validación externa con datos de múltiples centros y partición por paciente.

REFERENCIAS

- Schalekamp et al. (2024). Performance of AI to exclude normal chest radiographs to reduce radiologists' workload. *European Radiology*, 34(11), 7255-7263. <https://doi.org/10.1007/s00330-024-10794-5>
- Bennani et al. (2023). Using AI to improve radiologist performance in detection of abnormalities on chest radiographs. *Radiology*, 309(3), e230860. <https://doi.org/10.1148/radiol.230860>
- Bruls & Kwee (2020). Workload for radiologists during on-call hours: Dramatic increase in the past 15 years. *Insights into Imaging*, 11(1), 121. <https://doi.org/10.1186/s13244-020-00925-z>