




UNIVERSIDAD
MODELO
INGENIERÍA

Attention U-Net con Monte Carlo Uncertainty-Aware Focal Loss para la Segmentación de Lesiones Cutáneas.

PROYECTOS VI _____
VI SEMESTRE, INGENIERÍA BIOMÉDICA

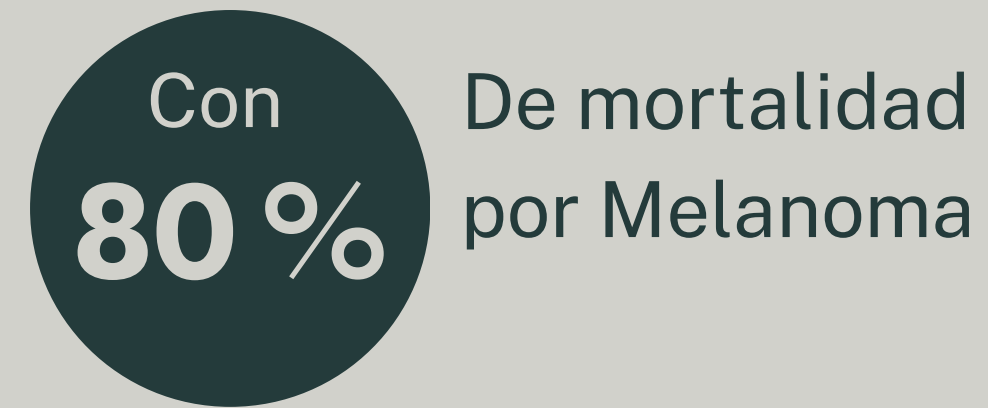
ALUMNAS: IVANNA FAISAL, DARA POOT, AURA GARRIDO



Cáncer de Piel

Tipo de tumor producido por el crecimiento anormal y descontrolado de las células de la piel. Clasificados ente Melanoma (más abrasivo) y No melanoma (más frecuente.)

En México el cáncer de piel ha tenido un incremento. Diagnosticado entre 11 mil y 16 mil nuevos casos **cada año** [1].




Se estima que las cifras del 2020 al rededor del mundo aumentarán un 50% para 2040 [2].



[1] Challenge validation. (s. f.). <https://www.gob.mx/imss/articulos/en-verano-reforzar-cuidados-para-reducir-riesgos-de-cancer-de-piel>.

[2] Arnold M, Singh D, Laversanne M, Vignat J, Vaccarella S, Meheus F, Cust AE, de Vries E, Whiteman DC, Bray F. Global Burden of Cutaneous Melanoma in 2020 and Projections to 2040. JAMA Dermatol. 2022 May 1;158(5):495-503. doi: 10.1001/jamadermatol.2022.0160. PMID: 35353115; PMCID: PMC8968696.

En el Diagnóstico



RETO VISUAL

La regla ABCD y dermatoscopías limitadas por la variabilidad subjetiva del especialista.

Un mal diagnóstico puede derivar al retraso de un tratamiento o a intervenciones innecesarias al paciente[3]

ACTUALIDAD

Existen métodos de Deep Learning para segmentación de piel, sin embargo, carecen de un enfoque que permita distinguir entre el objeto de interés y el fondo.

[3] Avci C, et. al. Diagnostic Performance of Dermoscopy for Distinguishing Early Melanomas and Intermediate Melanocytic Lesions From Low-Grade Dysplastic Nevi. J Cutan Med Surg. 2025 Sep-Oct;29(5):452-459. doi: 10.1177/12034754251325508. Epub 2025 Mar 12. PMID: 40072505; PMCID: PMC12432283.

Antecedentes

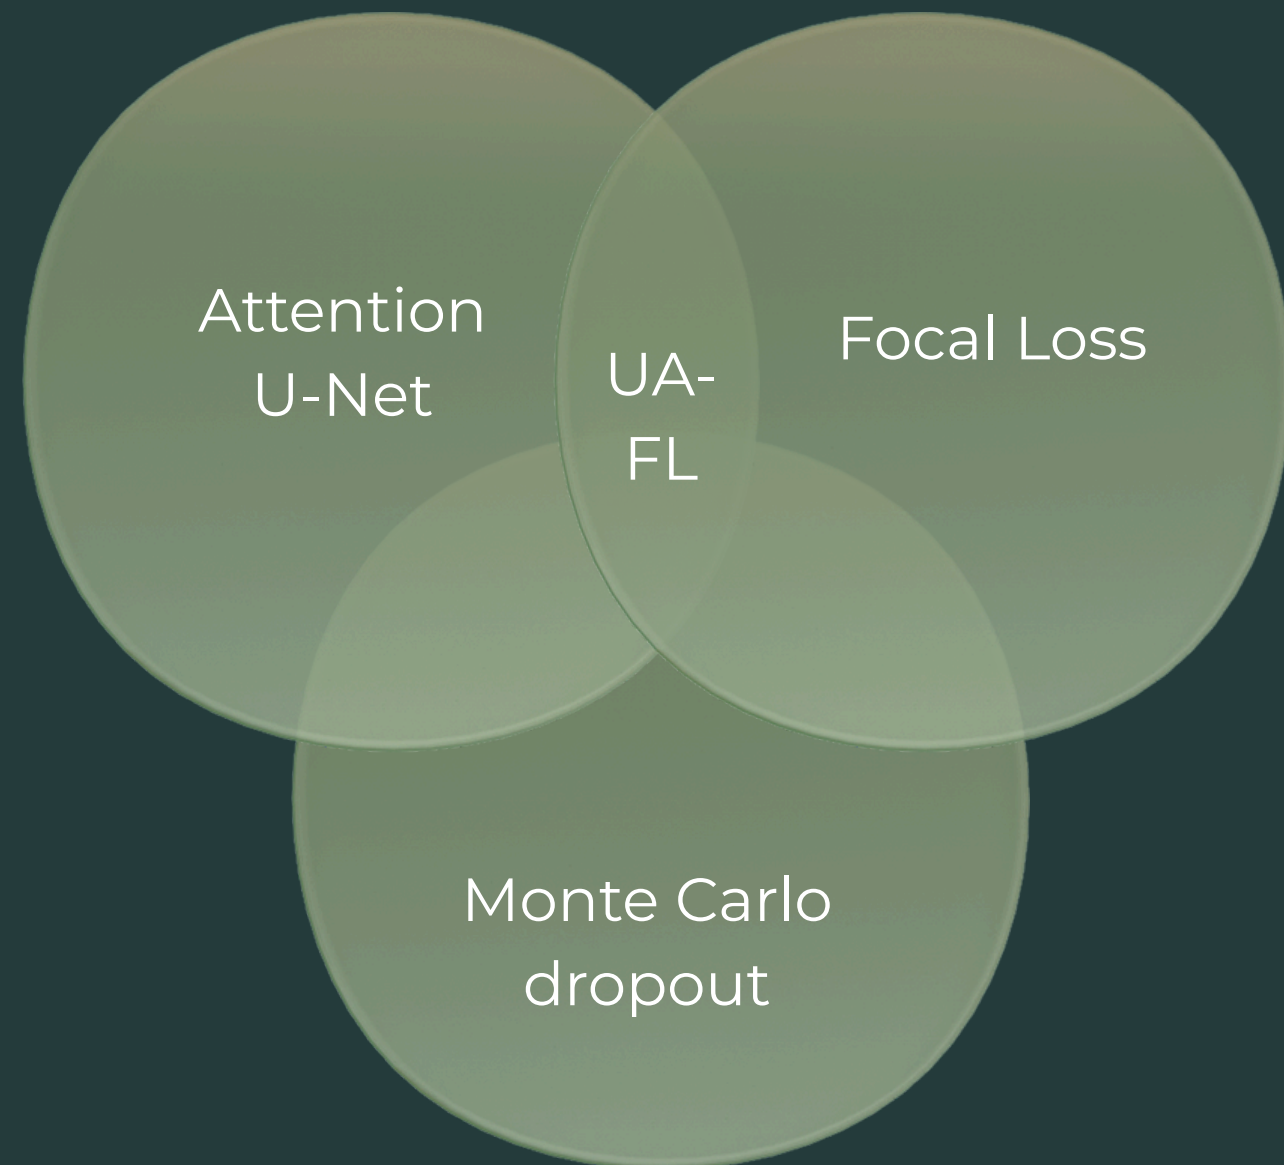
Autor (año)	Arquitectura	Contribución	Dataset	Limitación
Abraham & Khan (2018)	Attention U-Net mejorada con pirámide de imágenes de entrada y supervisión profunda (deep supervision).	Introduce la función de pérdida Focal Tversky Loss (FTL) para mejorar el equilibrio entre precisión y sensibilidad en la segmentación de lesiones pequeñas y desbalanceadas.	BUS 2017 (ultrasonido de mama) e ISIC 2018 (lesiones de piel).	Observan una sobresupresión de la función de pérdida FTL cuando el modelo está cerca de la convergencia y la precisión es alta.

A NOVEL FOCAL TVERSKY LOSS FUNCTION WITH IMPROVED ATTENTION U-NET FOR LESION SEGMENTATION

Nabila Abraham, Naimul Mefraz Khan

Ryerson University
Department of Electrical and Computer Engineering
350 Victoria Street, Toronto, ON

Attention U-Net con Monte Carlos Uncertainty Aware- Focal Loss



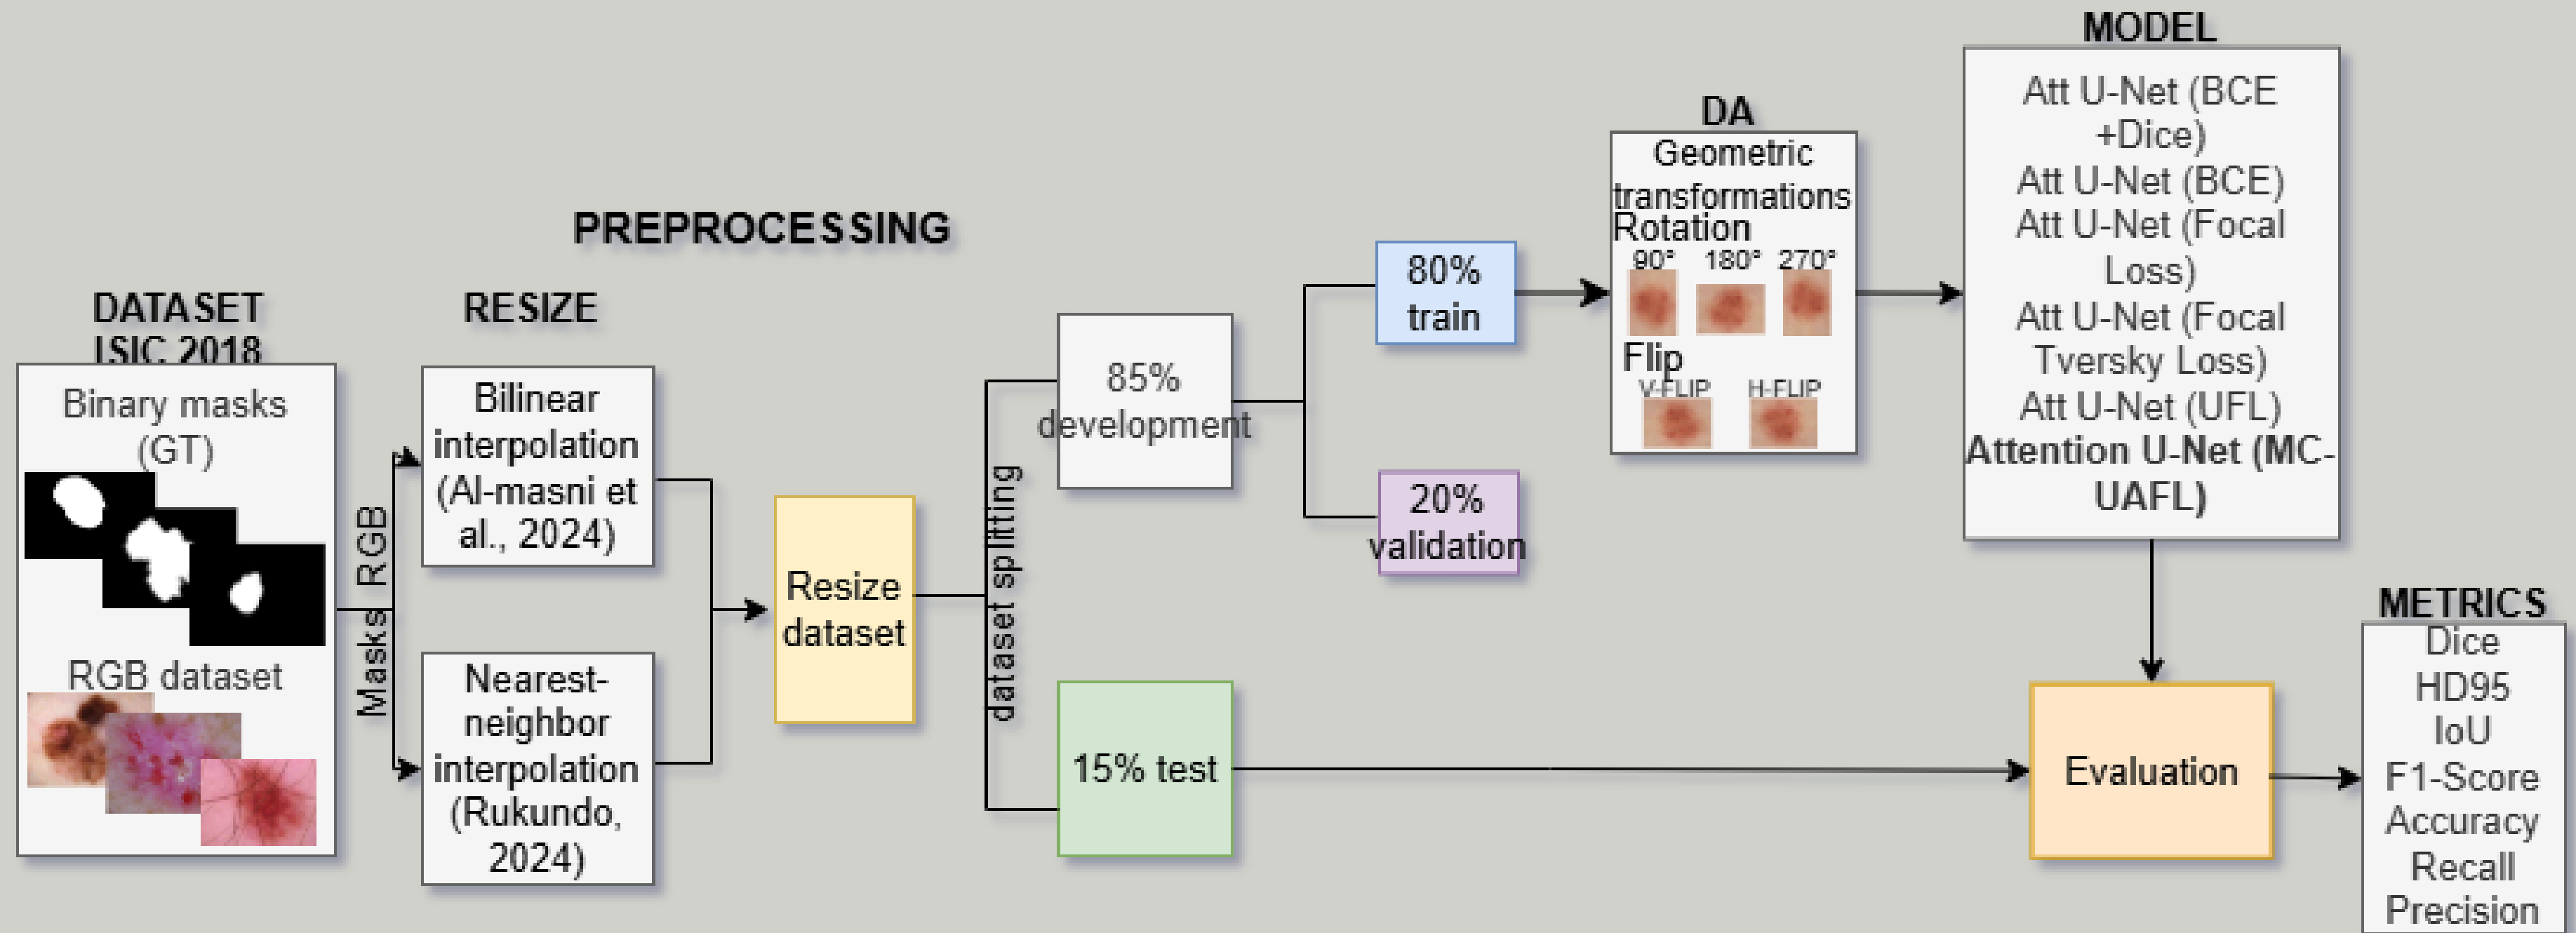
Objetivo General

Implementar un modelo de segmentación basado en la arquitectura Attention U-Net, integrando una función de pérdida de tipo Uncertainty-Aware Focal Loss, para optimizar la delimitación precisa de lesiones en imágenes dermatoscópicas de cáncer de piel, reduciendo el error en áreas de alta ambigüedad visual.

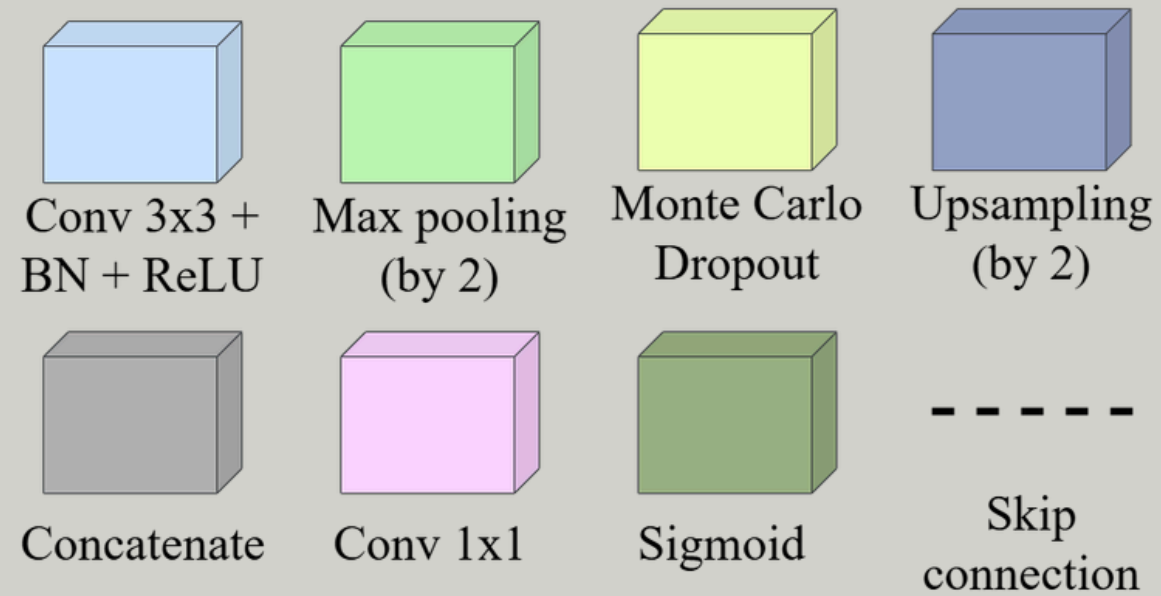
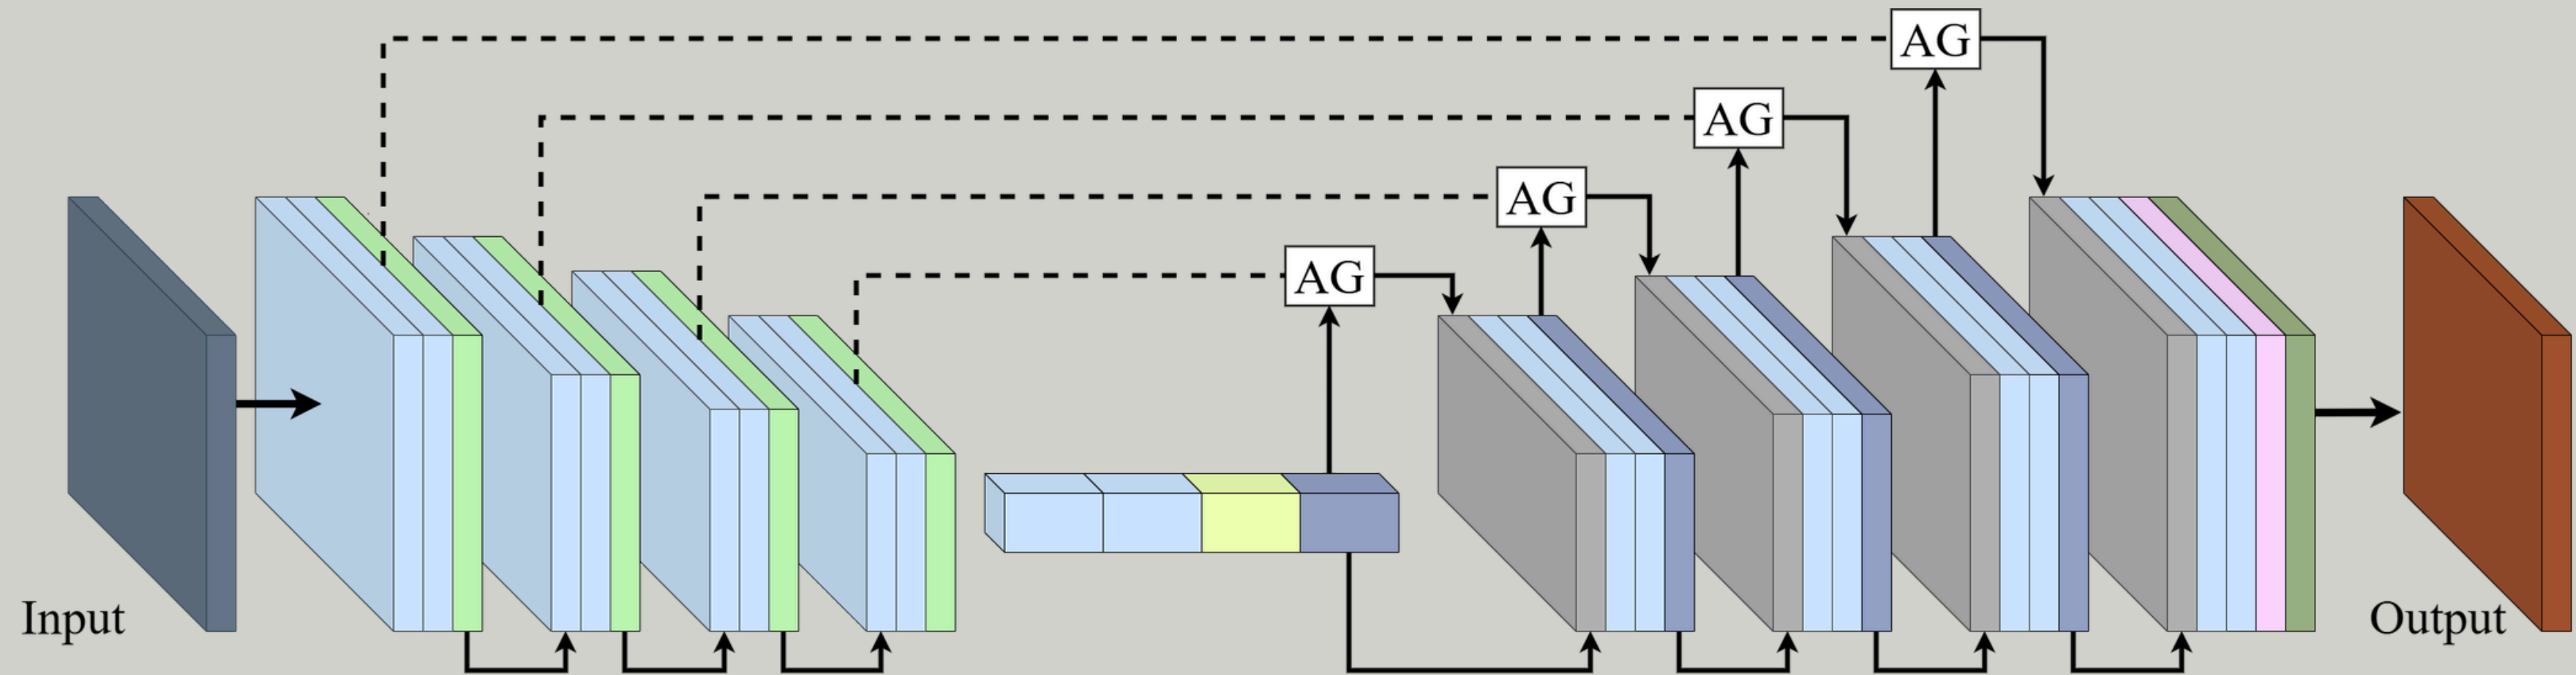
Objetivos Específicos

- Preprocesar el dataset ISIC Challenge 2018 (compuesto por 2594 imágenes RGB con sus máscaras binarias), aplicando redimensionamiento e incremento de datos (Data Augmentation) mediante transformaciones geométricas espaciales para evitar el sobreajuste.
- Implementar una arquitectura Attention U-Net con una función de pérdida basada en incertidumbre y la pérdida focal para enfocar la red en bordes difíciles y penalizar dinámicamente las zonas ambiguas.
- Evaluar la superposición global y la precisión de los contornos del modelo utilizando las métricas Dice Similarity Coefficient (DSC) y Hausdorff Distance 95 (HD95), validando su efectividad mediante una comparación directa de rendimiento contra una U-Net estándar, un Vision Transformer (ViT) y una Attention U-Net estándar y Attention U-Net con distintas funciones de pérdida.

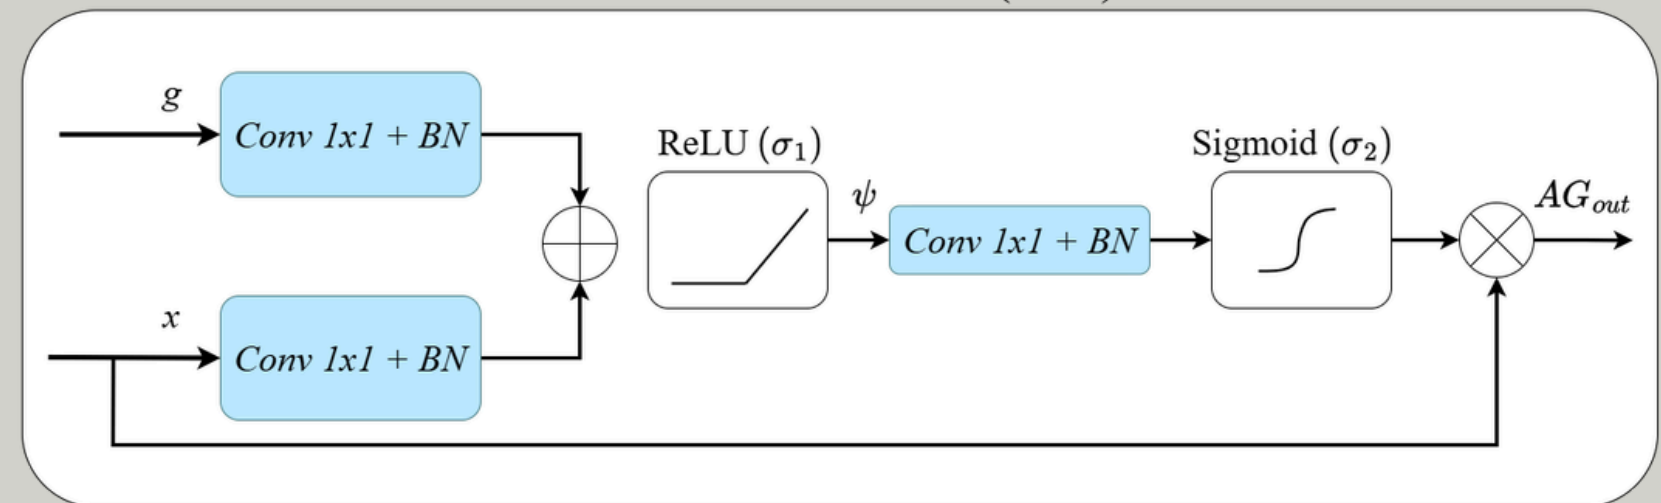
Metodología




Metodología



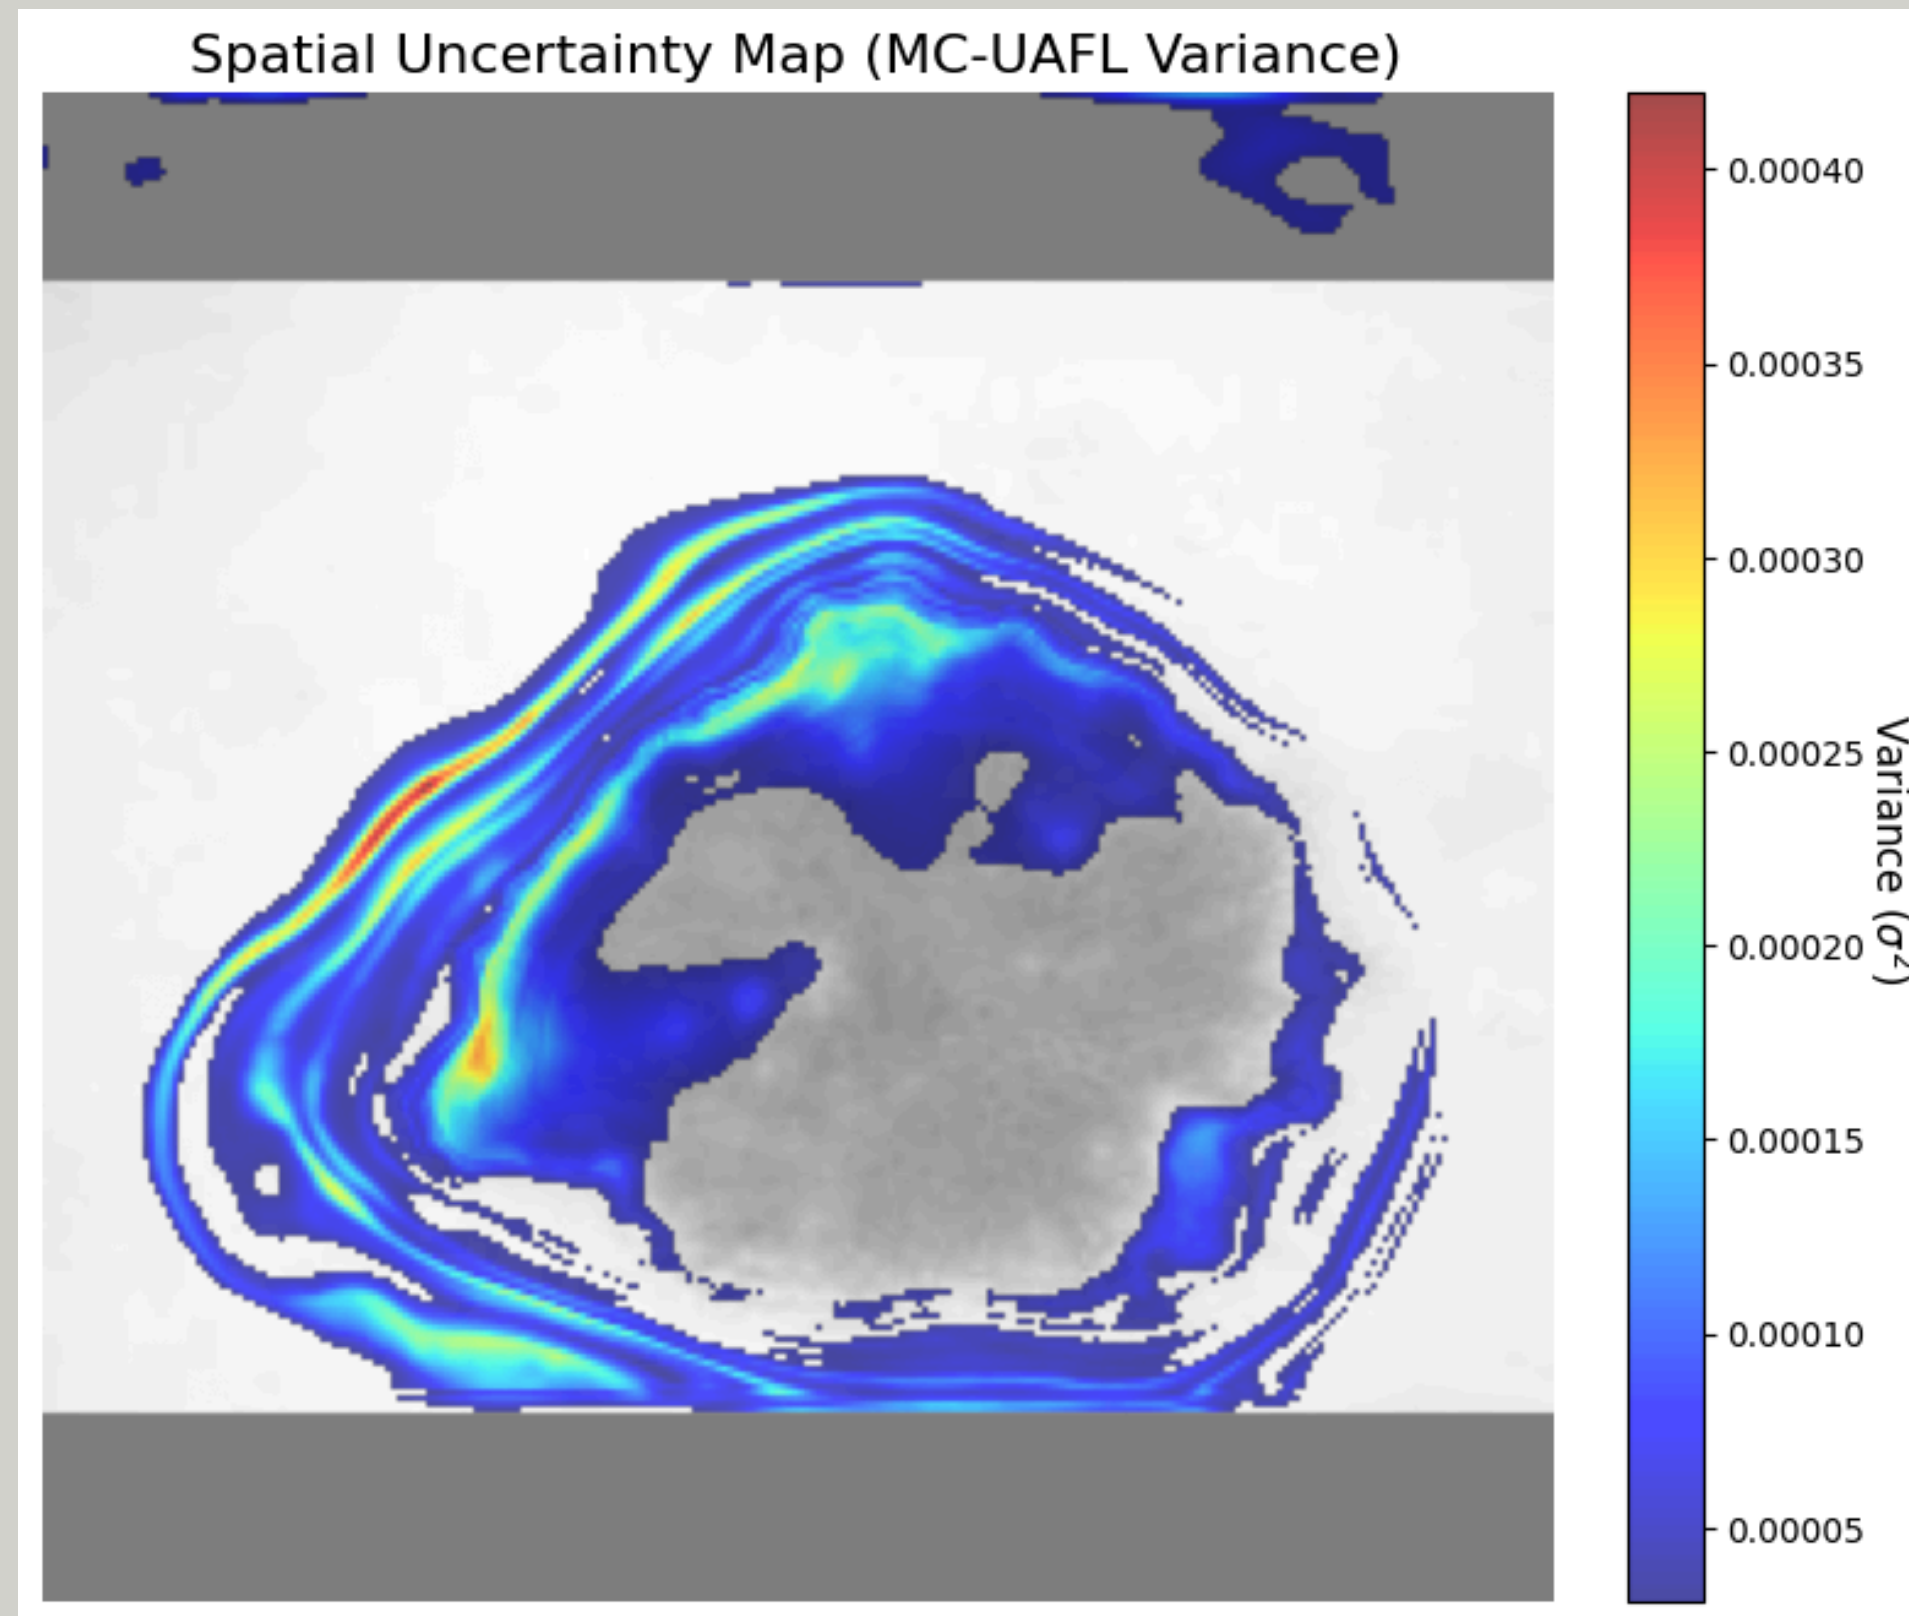
Attention Gate (AG)



Resultados



Resultados



Resultados

Se presenta una comparación de los resultados con el conjunto de Test en distintos modelos basados en Attention U-Net frente a la arquitectura propuesta, utilizando métricas de segmentación para evaluar la precisión y calidad de las predicciones.

Métricas	Att U-Net (BCE)	Att U-Net (BCE +Dice)	Att U-Net (Focal Loss)
	Épocas = 50 Early stopped = 24	Épocas = 50 Early stopped = 32	Épocas = 50 Early stopped = 26
Accuracy	0.963	0.967	0.963
Precision	0.924	0.920	0.916
Recall	0.846	0.874	0.856
IoU	0.791	0.812	0.794
Dice	0.880	0.896	0.880
HD95	15.056	13.992	16.440

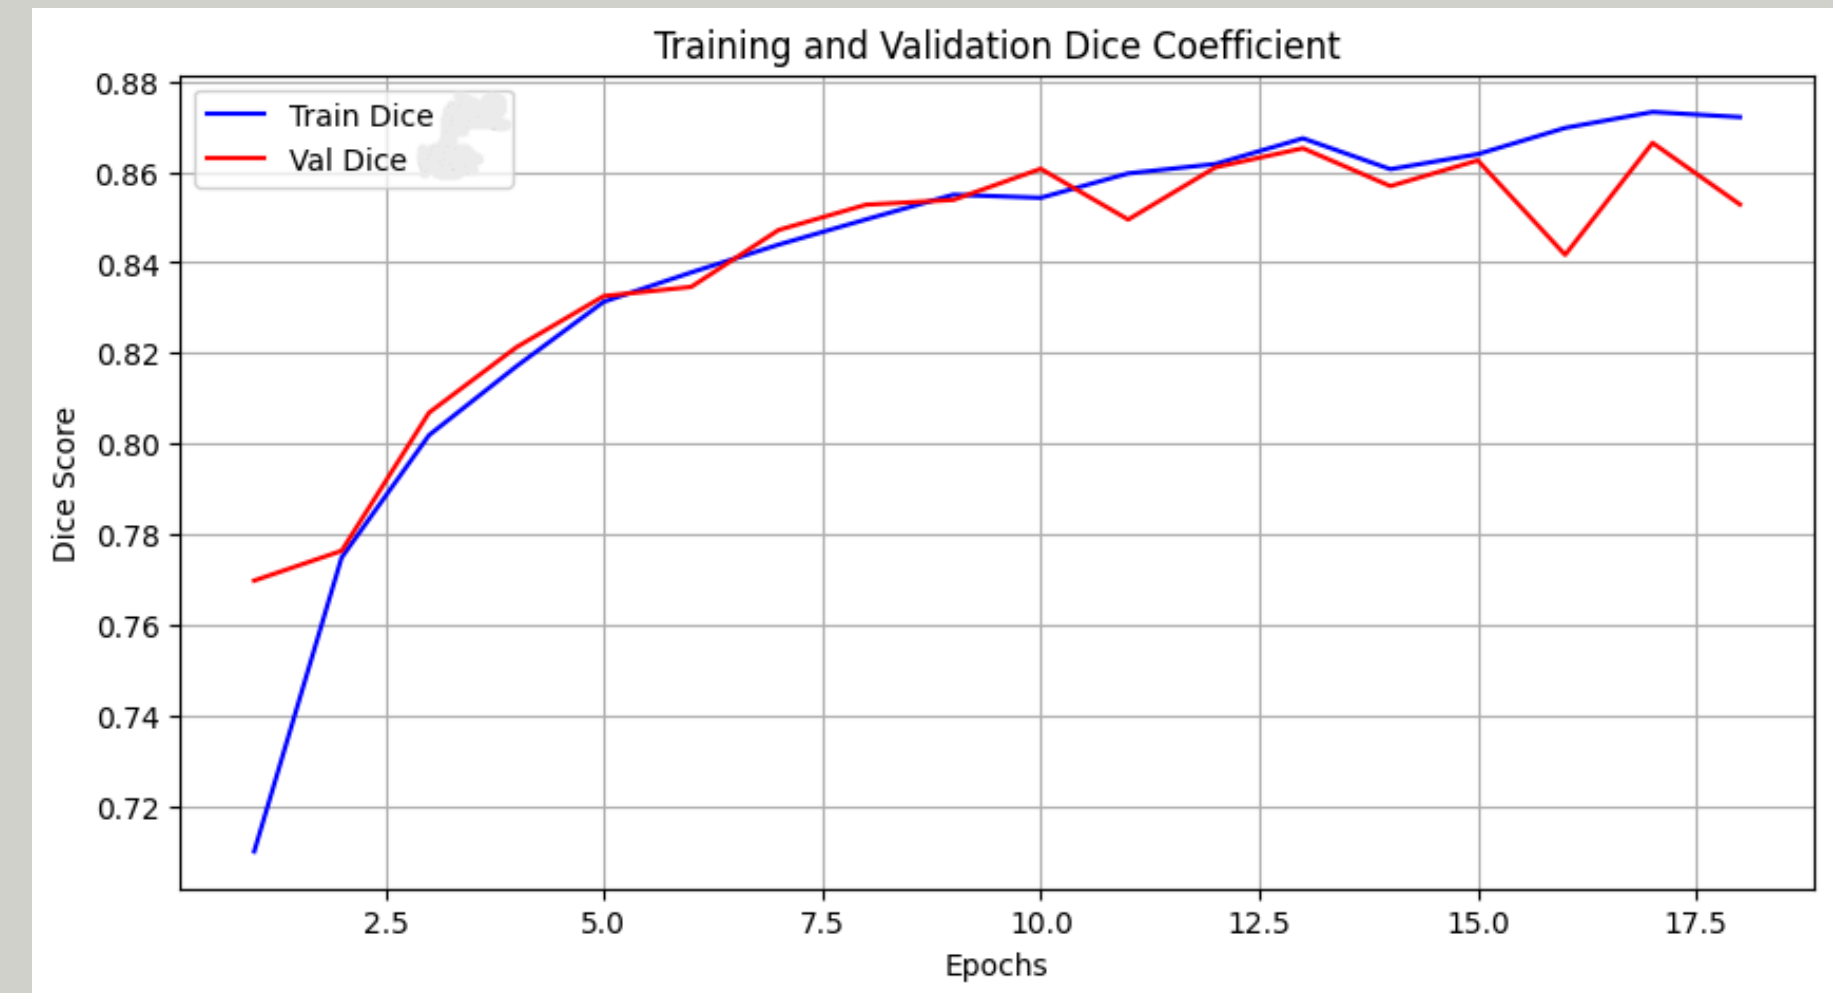
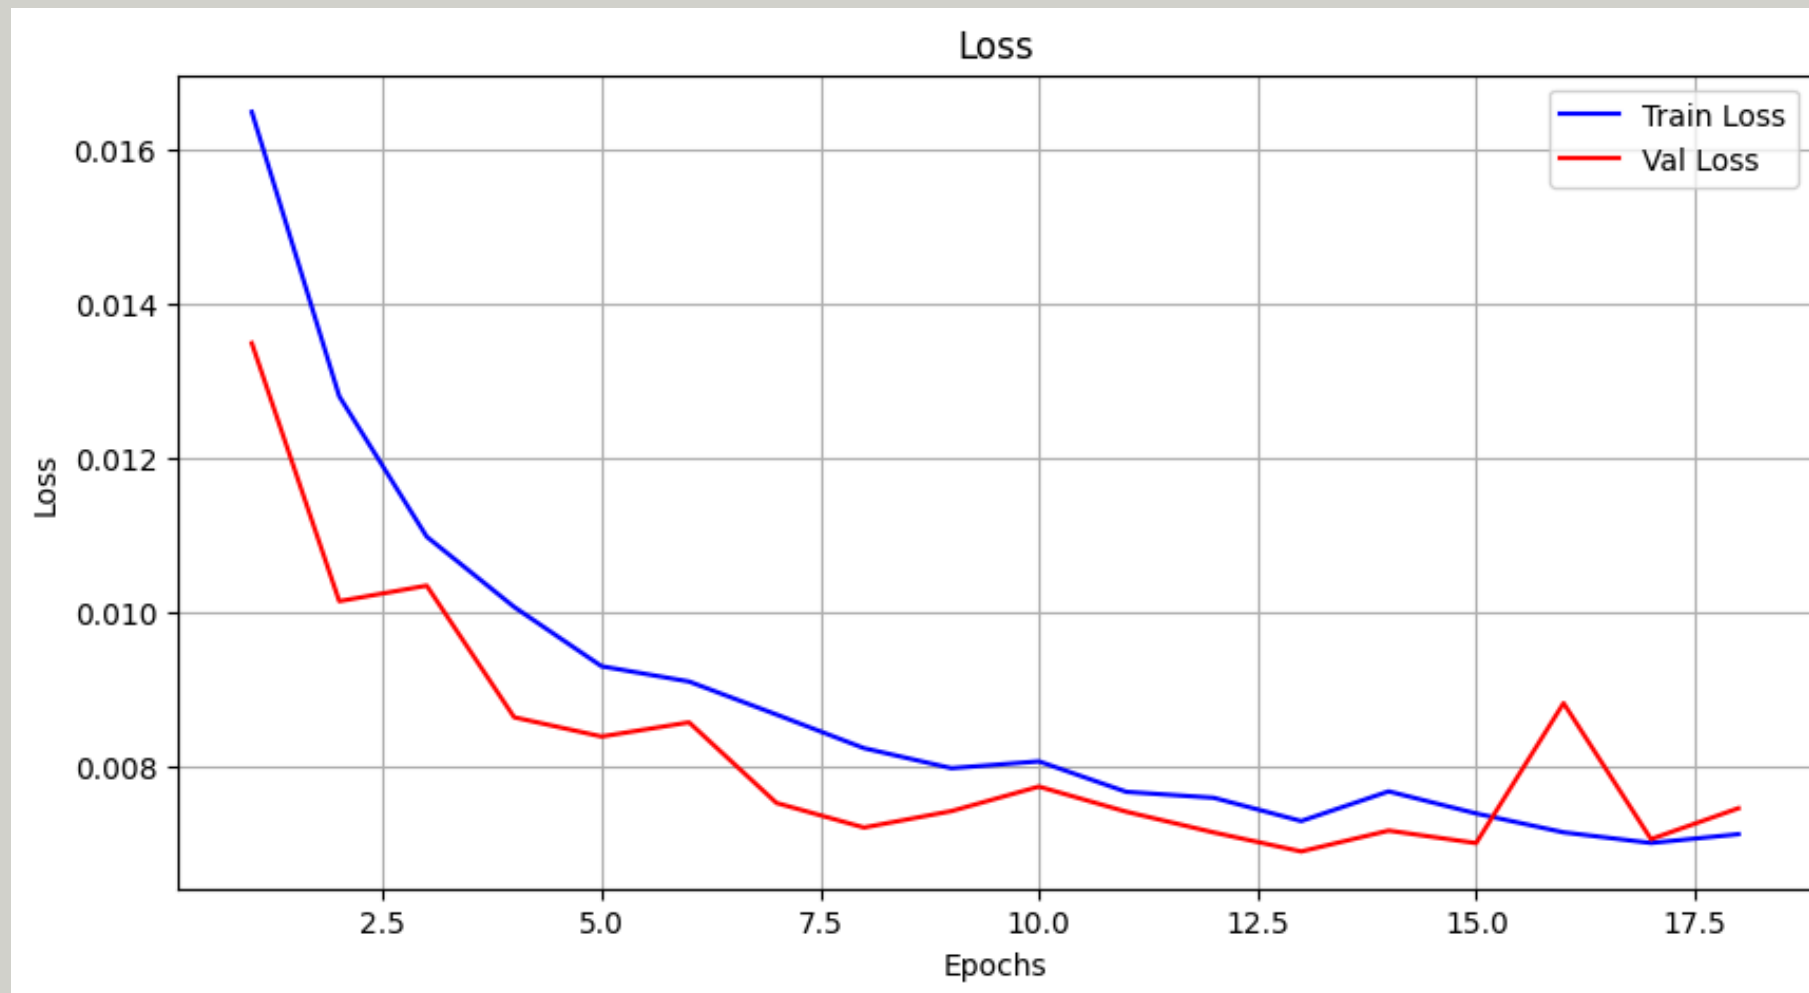
Resultados

Se presenta una comparación de los resultados con el conjunto de Test en distintos modelos basados en Attention U-Net frente a la arquitectura propuesta, utilizando métricas de segmentación para evaluar la precisión y calidad de las predicciones.

Métricas	Att U-Net (Focal Tversky Loss)	Att U-Net (UFL)	Att U-Net (MC-UAFL)
	Épocas = 50 Early stopped = 20	Épocas = 50 Early stopped = 16	Épocas = 50 Early stopped = 17
Accuracy	0.958	0.957	0.964
Precision	0.946	0.938	0.917
Recall	0.791	0.792	0.858
IoU	0.757	0.753	0.797
Dice	0.859	0.852	0.879
HD95	17.228	18.171	15.422

Resultados

Se muestra el desempeño de la arquitectura durante 17 épocas, el índice de Dice alcanza un valor de 0.87, podemos identificar que la pérdida tiene un acercamiento a cero, además se nota la importancia del early stopping en la pérdida.



Gracias

Expresamos un agradecimiento especial a J.A Chin Cantillo por su apoyo en la mejora y revisión de este proyecto.

