

# Impact of melanocytic lesion image databases on the pre-training of segmentation tasks using the UNET architecture

- **Ing. Laura Raquel Bareiro Paniagua**
- Dr. José Luis Vázquez Noguera
- Msc. Luis Salgueiro Romero
- Ing. Deysi Natalia Leguizamón Correa
- Dr. Diego P. Pinto-Roa
- Msc. Julio César Mello-Román
- Dr. Sebastián A. Grillo
- Dr. Miguel García-Torres
- Dr. Lizza A. Salgueiro Toledo
- Dr. Jacques Facón

# Contenido

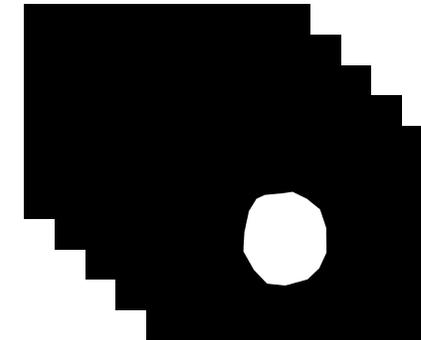
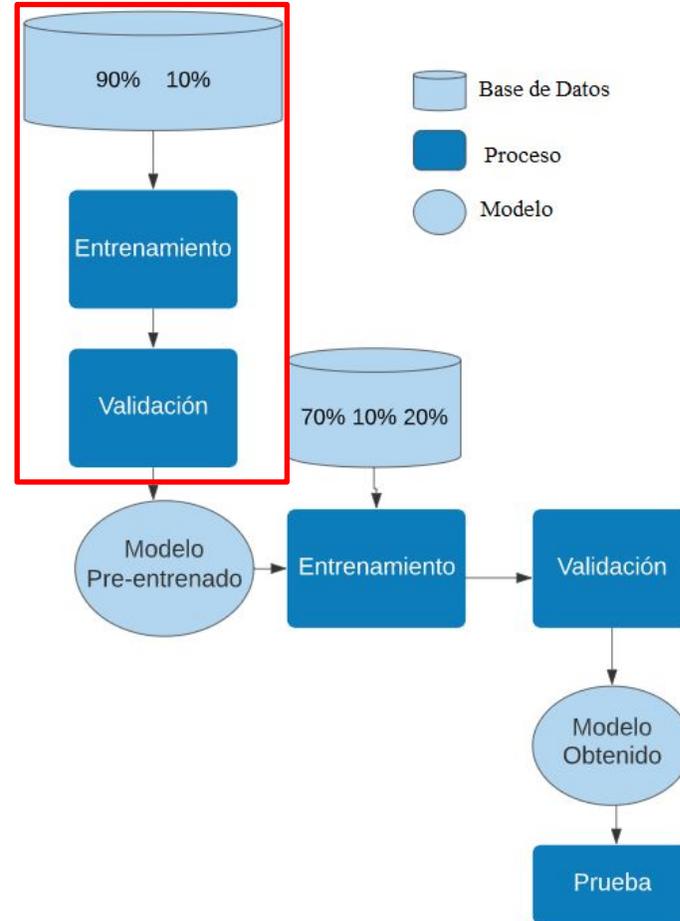
- **Conceptos Previos**
- **Preguntas de investigación y Objetivos**
- **Materiales y Métodos**
- **Métricas de Desempeño**
- **Resultados**
- **Conclusiones**

# Conceptos Previos

- ¿Qué es Imagenet?
- ¿Qué es una red pre-entrenada?

# Preguntas de Investigación y Objetivos

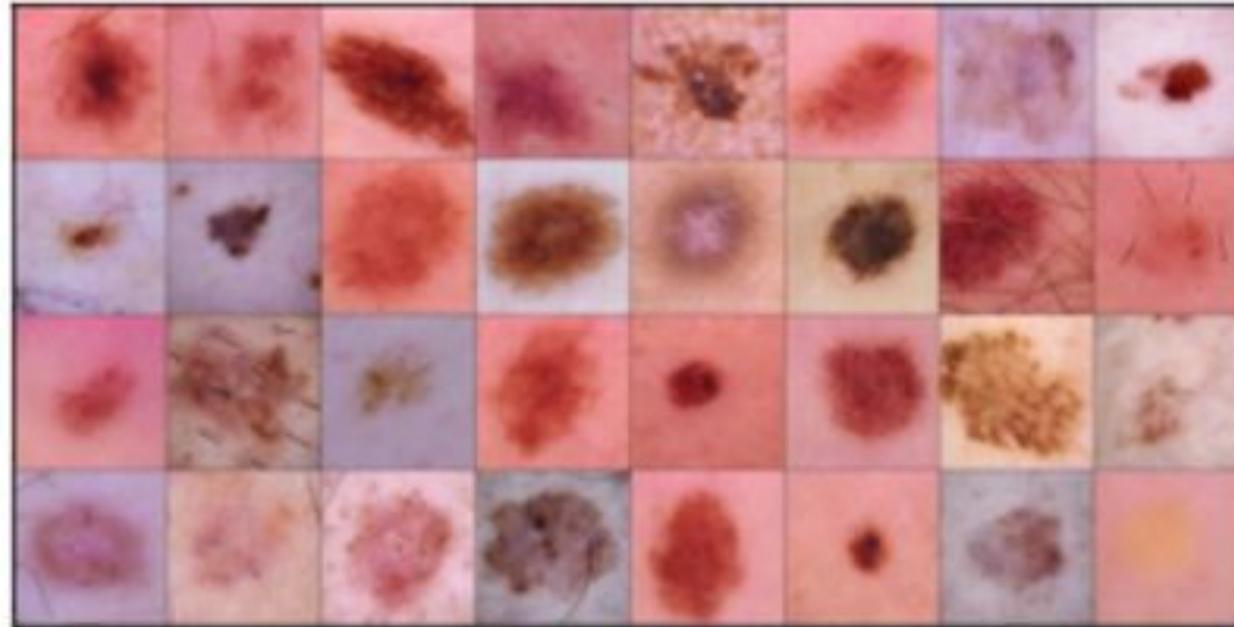
Fase de  
Pre-entrenamiento



# Objetivos

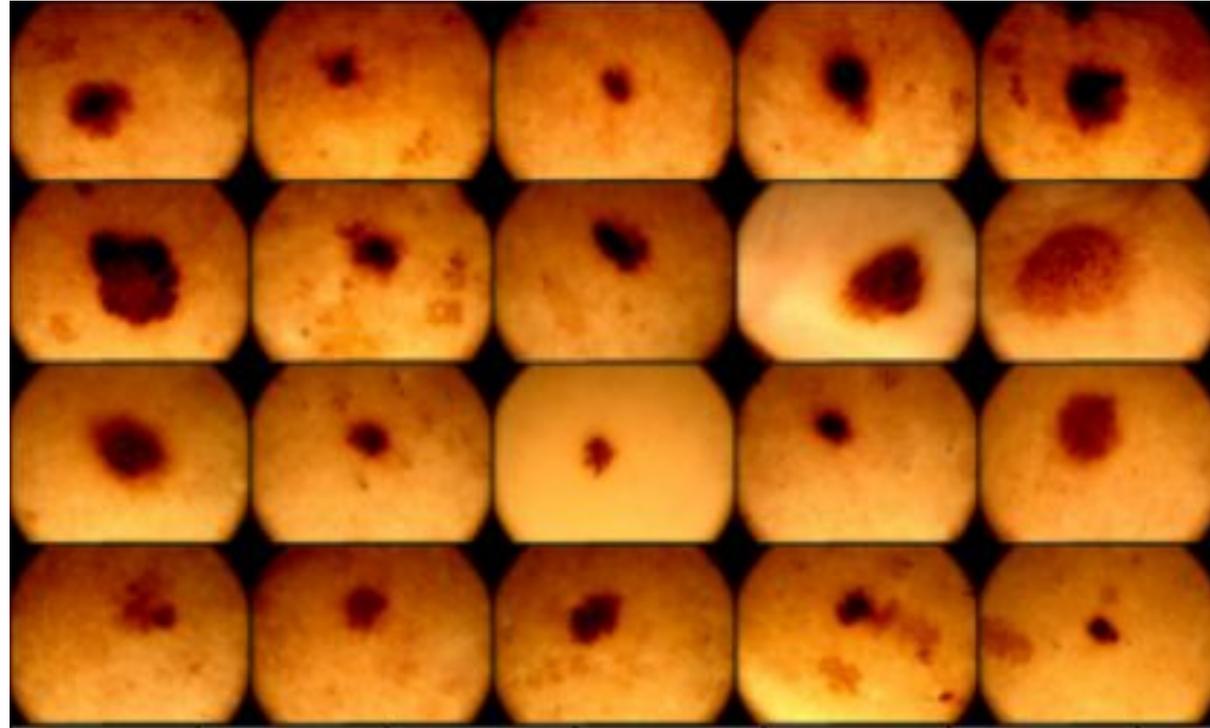
- Determinar si el pre-entrenamiento con Imagenet ayuda a obtener mejores resultados para bases de datos de lesiones melanocíticas.
- Determinar si al realizar pre-entrenamientos con diferentes bases de datos de lesiones melanocíticas se obtiene un mejor modelo.
- Determinar si usar base de datos de lesiones melanocíticas sumado a Imagenet obtiene mejores resultados que utilizar solamente Imagenet.

# Materiales y Métodos



Muestra de imágenes del conjunto de datos de ISIC [1] [2]

# Base de Datos

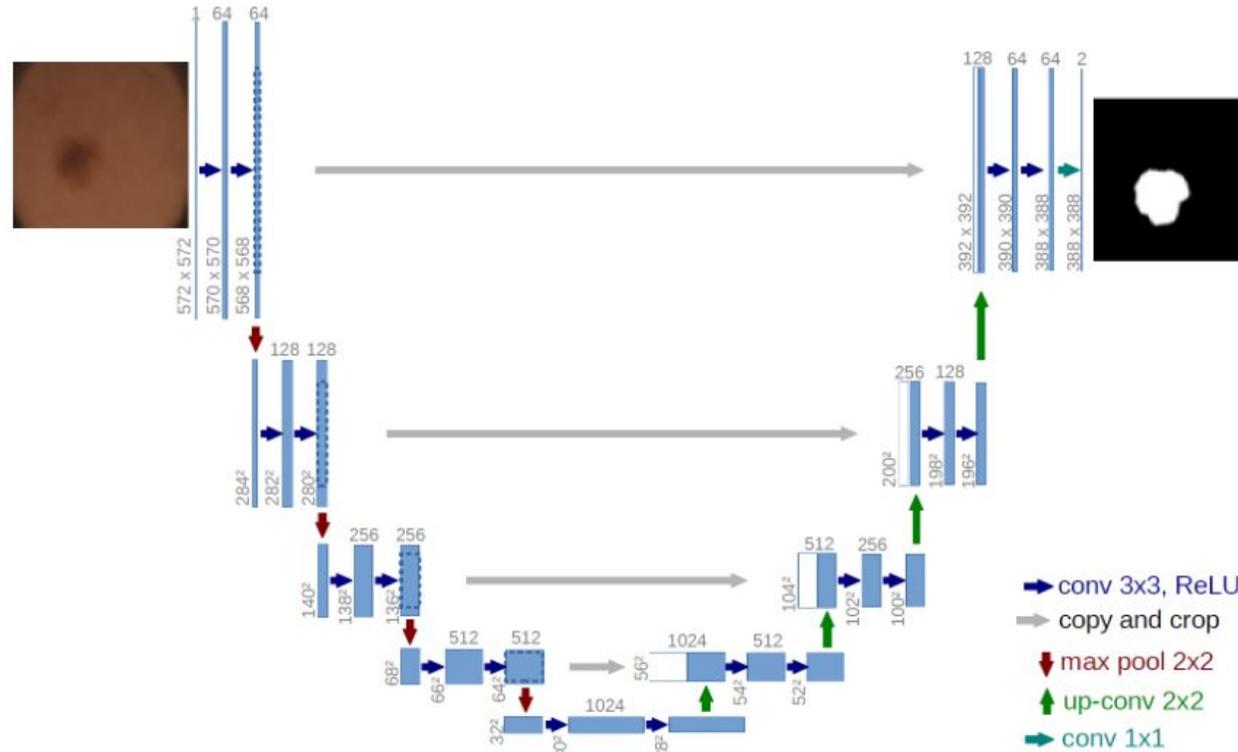


Muestra de imágenes del conjunto de datos de Torres et al. [3]



Muestra de imágenes del conjunto de datos de Beuren et al. [4]

# Arquitectura U-Net

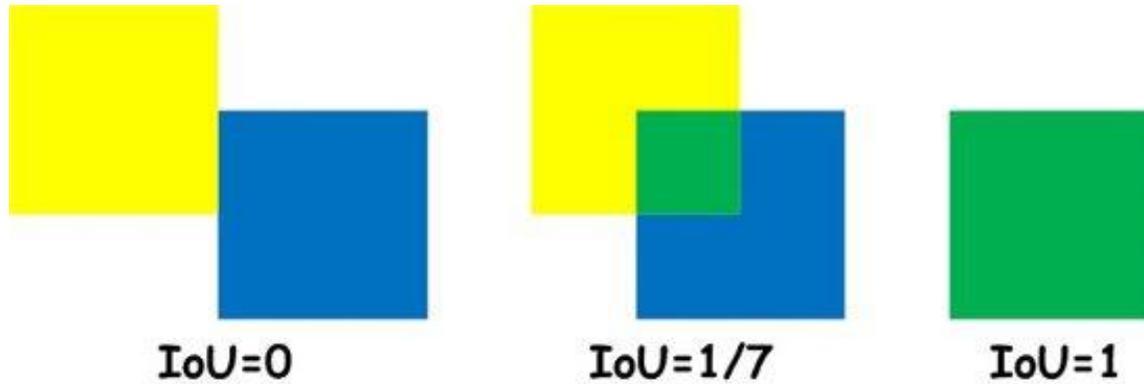


Arquitectura de la red utilizada U-Net [5]

# Métricas de Evaluación

# Métricas – Segmentación

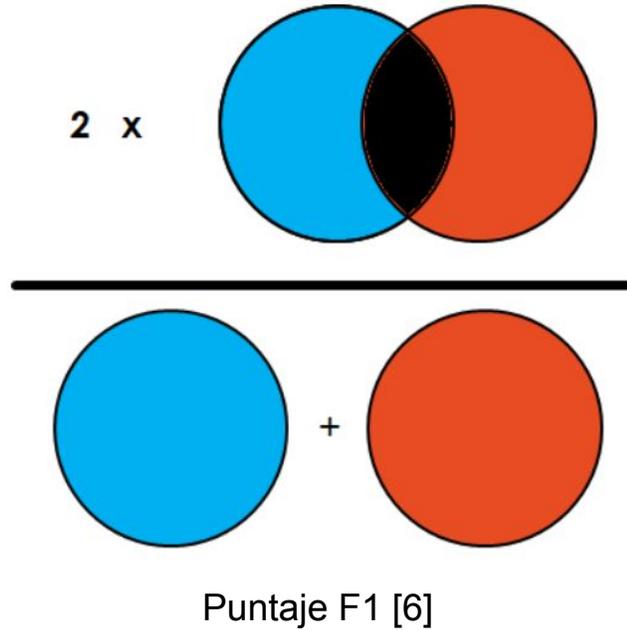
- Interception over Union (IoU)



Métricas para la segmentación [6]

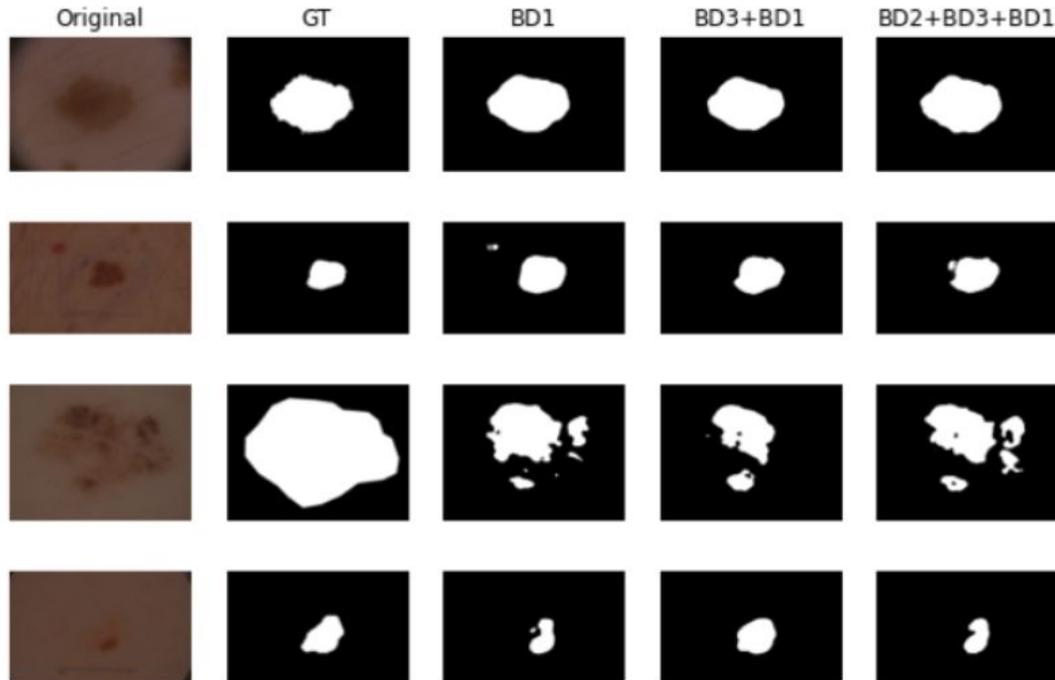
# Métricas – Segmentación

- Puntaje F1



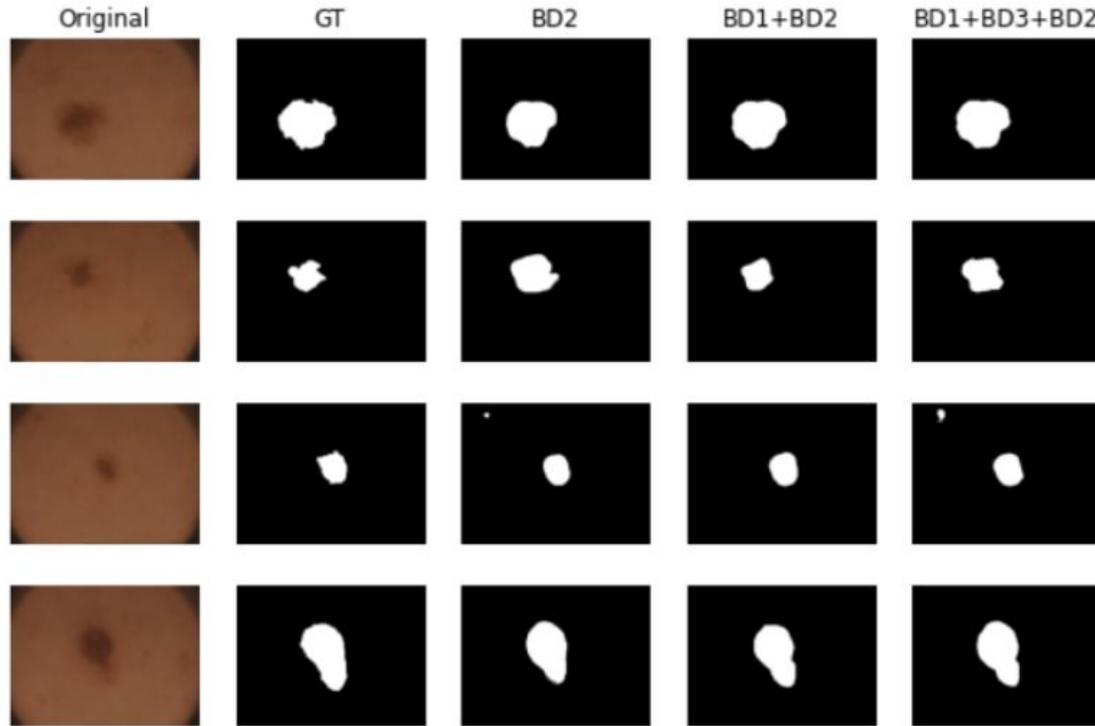
# Resultados Experimentales

# Resultados con BD1



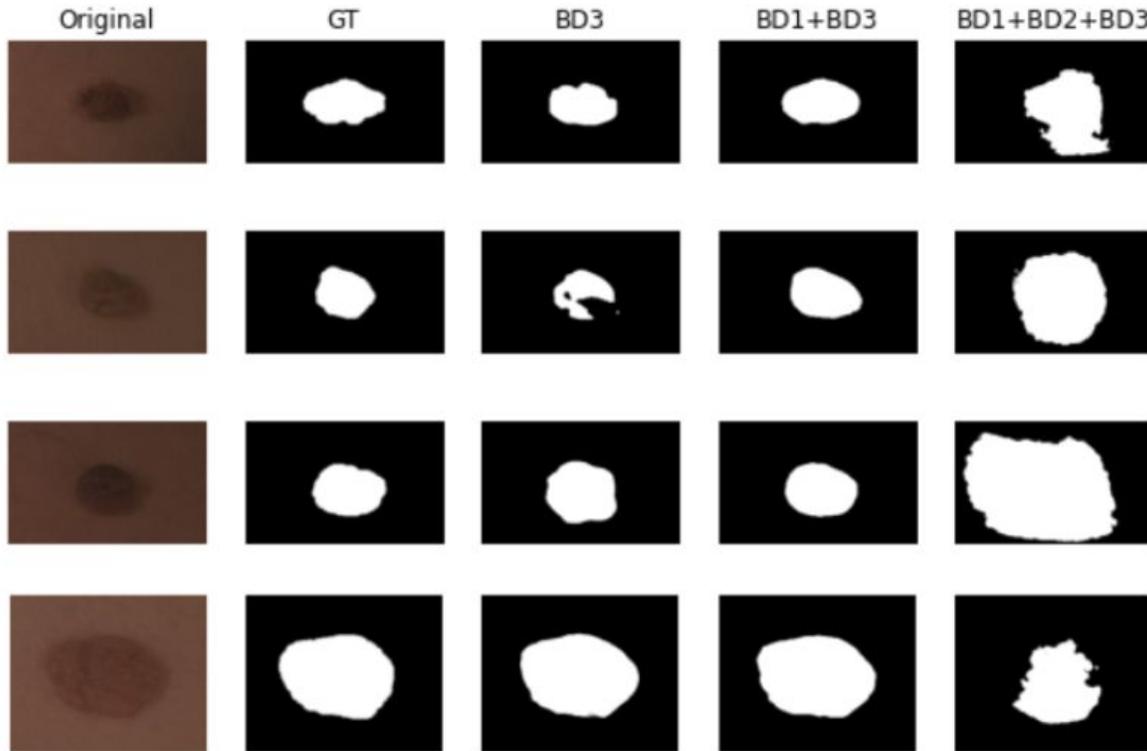
Pre-entrenamiento	Modelo	Jaccard	F1
Imagenet	Imagenet+BD1	0.59	0.69
No	BD1	0.57	0.67
Imagenet+BD2	Imagenet+BD2+BD1	0.58	0.69
BD2	BD2+BD1	0.57	0.68
Imagenet+BD3	Imagenet+BD3+BD1	0.61	0.71
BD3	BD3+BD1	0.56	0.66
Imagenet+BD2+BD3	Imagenet+BD2+BD3+BD1	<b>0.62</b>	<b>0.72</b>
BD2+BD3	BD2+BD3+BD1	0.58	0.69

# Resultados con BD2



Pre-entrenamiento	modelo	Jaccard	F1
Imagenet	Imagenet+BD2	0.70	0.81
No	BD2	0.70	0.81
Imagenet+BD3	Imagenet+BD3+BD2	0.75	0.85
BD3	BD3+BD2	0.78	0.87
Imagenet+BD1	Imagenet+BD1+BD2	<b>0.80</b>	<b>0.88</b>
BD1	BD1+BD2	0.74	0.84
Imagenet+BD1+BD3	Imagenet+BD1+BD3+BD2	<b>0.80</b>	<b>0.88</b>
BD1+BD3	BD1+BD3+BD2	0.74	0.83

# Resultados con BD3



Pre-entrenamiento	Modelo	Jaccard	F1
Imagenet	ImageNet+BD3	0.56	0.63
No	BD3	0.61	0.69
ImageNet+BD2	ImageNet+BD2+BD3	0.68	0.75
BD2	BD2+BD3	0.68	0.76
ImageNet+BD1	ImageNet+BD1+BD3	0.65	0.71
BD1	BD1+BD3	<b>0.73</b>	<b>0.81</b>
ImageNet+BD1+BD2	ImageNet+BD1+BD2+BD3	0.53	0.65
BD1+BD2	BD1+BD2+BD3	0.64	0.71

En los experimentos se pudo observar que:

- Los modelos pre-entrenados con imágenes de lesiones melanocíticas obtienen mejores resultados que aquellos modelos que no utilizan pre-entrenamiento para la segmentación.
- Agregando más modelos pre-entrenados con base de datos de lesiones melanocíticas se obtienen mejores resultados en la mayoría de los casos.
- Para la mayoría de las pruebas realizadas se puede observar que utilizar Imagenet solamente en el pre-entrenamiento obtiene peores resultados que combinando el pre-entrenamiento con otras bases de datos de lesiones melanocíticas.

Los pesos del mejor modelo obtenido que corresponde al pre-entrenamiento Imagenet+BD1 se encuentra disponible en <http://zenodo.org/record/5230556>.

# Agradecimientos

Ésta investigación fue realizada en el marco del proyecto PINV18-1199 financiada por CONACYT-Paraguay.

[1] Noel Codella, Veronica Rotemberg, Philipp Tschandl, M. Emre Celebi, Stephen Dusza, David Gutman, Brian Helba, Aadi Kallou, Konstantinos Liopyris, Michael Marchetti, Harald Kittler, Allan Halpern: "Skin Lesion Analysis Toward Melanoma Detection 2018: A Challenge Hosted by the International Skin Imaging Collaboration (ISIC)", 2018; <https://arxiv.org/abs/1902.03368>

[2] Tschandl, P., Rosendahl, C. & Kittler, H. The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Sci. Data* 5, 180161 doi:10.1038/sdata.2018.161 (2018).

[3] W. Torres, M. Landrove, M. Torreyes, and M. López, "Segmentación de imágenes dermatoscópicas en el espacio cielab utilizando filtros morfológicos SML," in XII Congreso Internacional de Métodos Numéricos en Ingeniería y Ciencias Aplicadas, 2014

[4] Beuren, A. T., Janasievicz, R., Pinheiro, G., Grando, N., & Facon, J. (2012, August). Skin melanoma segmentation by morphological approach. In *Proceedings of the international conference on advances in computing, communications and informatics* (pp. 972-978).

[5] Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Springer, Cham.

[6] Tiu, Ekin. "Metrics to evaluate your semantic segmentation model." *Towards datascience*, recuperado de: [https://towardsdatascience.com/metrics-to-evaluate-your-semantic-segmentation-model-6bcb99639aa2#:~:text=%20Simply%20put%20C%20the%20Dice%20Coefficient,%20of%20pixels%20in%20both%20images%20\(2019\).](https://towardsdatascience.com/metrics-to-evaluate-your-semantic-segmentation-model-6bcb99639aa2#:~:text=%20Simply%20put%20C%20the%20Dice%20Coefficient,%20of%20pixels%20in%20both%20images%20(2019).)

Grabación de la presentación: <https://youtu.be/AGbbyeAzAvk>