
Impacto de bases de datos de lesiones melanocíticas en el pre-entrenamiento para tareas de segmentación utilizando una arquitectura Unet

Ing. Laura Bareiro
Octubre 2021

Contenido

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

Conceptos Previos

Conceptos Previos



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

Preguntas de Investigación y Objetivos

Preguntas de Investigación



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

Imagenet




Muestra de imágenes del conjunto de datos Imagenet

Base de Datos



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]

Base de Datos



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

Entorno

Google Colab Pro

- Nvidia T4 P100 graphics
- 25 Gb de ram
- Pytorch 1.7


Experimentos

- 50 epochs
- lr 0.005
- Pytorch 1.7
- Optimizador Adam

Codigo Fuente:

<https://github.com/uamericana/PINV18-1199>


Arquitectura U-Net



Arquitectura de la red utilizada U-Net [5]


Métricas de Desempeño

Interception Over Union (IoU)



Métricas para la segmentación [6]


Puntaje F1



Puntaje F1 [6]


Resultados

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	0.62	0.72
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	0.80	0.88
BD1	BD1+BD2	0.74	0.84
Imagenet+BD1+BD3	Imagenet+BD1+BD3+BD2	0.80	0.88
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	0.73	0.81
ImageNet+BD1+BD2	ImageNet+BD1+BD2+BD3	0.53	0.65
BD1+BD2	BD1+BD2+BD3	0.64	0.71

Conclusiones

Conclusiones

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>.

Muchas Gracias

Referencias

- [1] Noel Codella, Veronica Rotemberg, Philipp Tschandl, M. Emre Celebi, Stephen Dusza, David Gutman, Brian Helba, Aadi Kalloo, 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.

Referencias

[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%20%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%20%20pixels%20in%20both%20images%20(2019).)