

Redes Neuronales Convolucionales en la identificación de melanomas benignos y malignos

Juan José Rangel-Cortes¹, José Sergio Ruiz-Castilla¹, Farid García-Lamont¹, Jair Cervantes-Canales¹.

juan991029@gmail.com, jsergioruizc@gmail.com, fglamont@gmail.com, chazarra17@gmail.com

¹Universidad Autónoma del Estado de México, Centro Universitario UAEM Texcoco, Av. Jardín Zumpango s/n El Tejocote, C. P. 56259, Texcoco, Estado de México, México.

Pages: 15–27

Resumen: El cáncer de piel más común es el de tipo melanoma, que ha aumentado en múltiples partes del mundo. Por lo anterior, se trabajó en la clasificación de melanomas para apoyar la posible detección de melanomas malignos. Se utilizaron Redes Neuronales Convolucionales o Convolutional Neural Networks por sus siglas en inglés. Se utilizaron imágenes del *Dataset* disponibles en *International Skin Imaging Collaboration*. Se aplicaron tres técnicas: 1) Se clasificaron melanomas añadiendo metadatos de edad, género y tamaño del melanoma, en la matriz de píxeles. 2) Con las imágenes sin la piel. 3) Con un tamaño de 300 x 300 píxeles y con 2000 imágenes. Se llevó a cabo el entrenamiento y validación en cada técnica. Al final, se probó cada técnica con imágenes nuevas y se obtuvieron resultados, en los cuales, se obtuvo un mejor resultado en la tercera técnica cuando se añadieron más imágenes en el entrenamiento.

Palabras-clave: cáncer de piel; melanoma; red neuronal convolucional; clasificación; aprendizaje profundo.

CNN: Convolutional Neural Networks in the identification of benign and malignant melanomas

Abstract: The most common skin cancer is melanoma, which has increased in multiple parts of the world. Therefore, we worked on the classification of melanomas to support the possible detection of malignant melanomas. We use a Convolutional Neural Networks. We use a Dataset images available in *International Skin Imaging Collaboration*. Three techniques were applied: 1) Melanomas were classified by adding metadata of age, gender and size of melanoma, in the pixel matrix. 2) With the images without the skin. 3) With 2000 images and a size of 300 x 300 pixels. We were carried out Training and validation in each technique. Finally each technique was tested with new images and results were obtained, a better result was obtained in the third technique when more images were added on training.

Keywords: skin cancer; melanoma; convolutional neural network; classification; deep learning.

1. Introducción

Según Brinker et al. (2018), en la última década, de 2008 a 2018, el número anual de casos de melanoma ha aumentado en un 53%, en parte debido al aumento de la exposición a los rayos ultravioleta (UV). También la exposición prolongada al arsénico inorgánico, a través del uso y consumo de agua contaminada o comida preparada y cultivos alimentarios regados con agua rica en arsénico puede causar intoxicación crónica; los efectos más característicos son la aparición de lesiones cutáneas y cáncer de piel (Organización Mundial de la Salud, 2018). El melanoma es uno de los tipos más letales de cáncer de piel (Brinker et al., 2018; Mahbod, Ecker, & Ellinger, 2017; Chang, 2017). Sin embargo, un diagnóstico oportuno incrementa el índice de supervivencia (Brinker et al., 2018; Tarriba et al., 2017; Yang et al., 2017).

La presente investigación se enfoca en la labor de médicos en clínicas rurales como las de México donde el Sistema Nacional de Salud tiene tres niveles para la atención al público. En el primer nivel se brindan servicios básicos de salud. En el segundo nivel son atendidos para realizar procedimientos de diagnóstico, así como procesos terapéuticos y de rehabilitación. En el tercer nivel, se tratan las enfermedades de baja prevalencia, alto riesgo y enfermedades más complejas. A este nivel, son pasados los pacientes desde el primer y segundo nivel (Burr, Piñó, Quiroz, & Martín-Lunas).

La forma de diagnóstico de una lesión maligna por un médico es el examen visual del área de piel sospechosa (Brinker et al., 2018). La inteligencia artificial y los modelos de aprendizaje profundo se han aplicado para ayudar a los médicos que no tienen tanta experiencia (Yu et al., 2018).

Con este trabajo se presenta una propuesta para clasificar los melanomas con el objetivo de ayudar en el diagnóstico previo del cáncer de piel tipo melanoma. Se utiliza una red neuronal convolucional así como metadatos del Dataset ofrecido por la *ISIC (The International Skin Imaging Collaboration)*. Se exploran algunos parámetros de la CNN y se lleva a cabo un pre-procesamiento de las imágenes.

El artículo se estructura de la siguiente manera. Como parte de la introducción, se incluyen conceptos del cáncer de piel y de las CNN. Luego se muestran algunos trabajos publicados relacionados. Posteriormente, se detalla el método en el cual se aplican tres técnicas: primero, con metadatos dentro de la misma matriz de píxeles, otra quitado de la piel de la imagen y la tercera con imágenes originales. Finalmente, se presentan los resultados y se arriba a conclusiones sobre los mejores resultados.

1.1. Cáncer de piel

El cáncer de piel se ha clasificado en dos grandes grupos: el cáncer de piel no melanoma y el melanoma maligno. El cáncer de piel melanoma maligno es el más letal (responsable del 75% de las muertes por cáncer cutáneo) y frecuente. En todo el mundo, cada año, se diagnostican cerca de 160,000 casos nuevos de melanoma. La Clínica de Melanoma del *Instituto Nacional de Cancerología (INCAN)* reporta que en México ha aumentado este tipo de cáncer en casi un 500% en los últimos años. Es de esperarse que esta tendencia continúe así hasta el año 2020 por lo que, el melanoma será el tipo de cáncer más

cotidiano. El melanoma es una enfermedad heterogénea, tiene cuatro principales tipos histopatológicos: acral lentiginoso, nodular, diseminado superficial y lentigo maligno. En México, el tipo que más ocurre es el acral lentiginoso (Herrea G., 2010).

1.2. Red neuronal convolucional (CNN Convolutional neural network)

La convolución de una señal temporal o espacial con otra señal produce una versión modificada de la señal inicial. La señal modificada puede tener una mejor representación de características que la señal original adecuada para una tarea específica. Por ejemplo, al convertir una imagen en escala de grises como una señal 2D con otra señal, generalmente llamada filtro o kernel, se puede obtener una señal de salida que contiene los bordes de la imagen original. Los bordes de una imagen pueden corresponder a los límites de los objetos, cambios en la iluminación, cambios en las propiedades del material, discontinuidades en profundidad, etc., que pueden ser útiles para varias aplicaciones. Las CNN se basan en la convolución de imágenes y en la detección de características basadas en filtros que la CNN aprende a través de su entrenamiento (Pattanayak, 2017).

Las CNN, también son conocidas como *convnets*, son un tipo de modelo de aprendizaje profundo que se usa casi universalmente en aplicaciones de visión artificial. Los *convnets* se pueden aplicar a problemas de clasificación de imágenes, particularmente aquellos que involucran conjuntos de imágenes de entrenamiento. Las capas de convolución de una *convnet* aprenden de patrones locales. La característica anterior es clave y le da a los *convnets* dos propiedades interesantes (Chollet, 2018):

1. Los patrones que aprenden son invariantes. Después de aprender un cierto patrón en la esquina inferior derecha de una imagen, un *convnet* puede reconocerlo en cualquier lugar: por ejemplo, en la esquina superior izquierda. Una red densamente conectada tendría que aprender el patrón nuevamente si apareciera en una nueva ubicación.
2. Pueden aprender jerarquías espaciales de patrones. Una primera capa de convolución aprenderá pequeños patrones locales como el borde; una segunda capa de convolución aprenderá patrones más grandes hechos de las características de las primeras capas, y así sucesivamente.

2. Trabajos relacionados

Mahbod et al. (2017) tomaron imágenes disponibles del *ISIC* en 2017. Aplicaron tres pasos de pre-procesamiento en las imágenes. Primero, normalizaron las imágenes restando el valor RGB promedio del conjunto de datos, ya que las redes pre-entrenadas fueron optimizadas para esas imágenes. A continuación, las imágenes se redimensionaron al tamaño apropiado utilizando interpolación bicúbica para alimentar las redes (227 X 227 y 224 X 224). Finalmente, las imágenes aumentaron para tener un conjunto de entrenamiento más grande. Dado que los clasificadores fueron entrenados para un problema de clasificaciones múltiples para las clases de: *melanoma*, *queratosis seborreica* y clases de *nevus* benignos. El rendimiento del clasificador, en términos de precisión (ACC), se midió para 150 imágenes de prueba. El logro de resultados de 79.9% a 89.2% del valor de precisión.

Shoieb et al. (2016) tomaron una *CNN* pre-entrenada en su última fase para clasificar la lesión de piel infectada de acuerdo con las características de la *CNN* para entrenar a un clasificador de múltiples clases y clasificar con una *SVM* (*Support Vector Machine*). Seleccionaron cuatro clases de enfermedades de la piel para la validación del sistema. Estas clases son *melanoma*, *carcinoma* de células basales, *eczema* e *impétigo*. El conjunto de datos comprende 134 imágenes, 72 de ellas representan *melanoma*, 64 para *carcinoma* de células basales, 74 *eccemas* y 31 para la enfermedad de la piel por *impétigo*. Los resultados de la clasificación de melanoma y lesiones no melanoma a partir de los datos obtenidos del fueron 94% de precisión, 94% de especificidad y 94% de sensibilidad para melanoma y para no melanomas fue de 94% de precisión, 94% de especificidad y 94 % de sensibilidad.

Yu et al. (2018) hicieron una clasificación del melanoma *acral lentiginoso*, ya que es el tipo más común de melanoma en los asiáticos, y generalmente resulta en un mal pronóstico debido a un diagnóstico tardío. Aplicaron una red neuronal convolucional a las imágenes de dermatoscopia de melanoma *acral* y *nevus* benignos. Analizaron un total de 724 imágenes de dermatoscopia que comprendían melanoma *acral* (350 imágenes de 81 pacientes) y *nevus* benignos (374 imágenes de 194 pacientes), confirmados mediante examen histopatológico. Para realizar la validación cruzada doble, dividieron en dos subconjuntos mutuamente exclusivos: la mitad del conjunto de datos de la imagen fue seleccionada para el entrenamiento y el resto para la prueba, y calcularon la precisión del diagnóstico comparándolo con el del dermatólogo y el de no expertos en este tipo de evaluación. La precisión (porcentaje de verdaderos positivos y verdaderos negativos de todas las imágenes) de la red neuronal convolucional fue de 83.51% y 80.23%, que fue mayor que la evaluación de los no expertos (67.84%, 62.71%) y cercana a la de los expertos (81.08%, 81.64%).

Pomponiu y otros utilizaron solo 399 imágenes de una cámara estándar para la clasificación de melanomas versus *nevus* benignos (Brinker et al., 2018). En primer lugar, realizaron el aumento de datos y pre-procesamiento. Posteriormente, aplicaron una *AlexNet* pre-entrenada para la extracción de características representativas. Las lesiones se clasificaron luego con un clasificador vecino más cercano utilizando métricas de distancia de coseno. El algoritmo no se probó con un conjunto de datos de prueba independiente; solo se realizó una validación cruzada. El algoritmo alcanzó una sensibilidad del 92,1%, una especificidad del 95,18% y una precisión del 93,64% (Brinker et al., 2018).

Codella et al. (2015) experimentaron con el método de validación cruzada y realizaron 40 experimentos con 334 imágenes de melanoma y 144 imágenes de *nevus* atípicos, así como 2146 lesiones claramente benignas (2624 en total) tomadas de *ISIC*. Las imágenes se redimensionan a dimensiones de 128x128. Para entrenar a los clasificadores utilizaron un *SVM* no lineal que usa un histograma de intersección de núcleo y *sigmoide*. Las puntuaciones de *SVM* se asignaron a las probabilidades mediante regresión logística en los datos de entrenamiento. Usaron una probabilidad del 50% como un umbral de clasificación binaria. La fusión se lleva a cabo mediante una puntuación media de *SVM* no ponderada (fusión tardía). Los resultados obtenidos con *Caffe CNN* fueron 91.9% de precisión, 90.3% de especificidad y 92.10% de sensibilidad.

Dorj et al. (2018) hicieron una clasificación de los cánceres de piel utilizando una red neuronal convolucional profunda. El conjunto de datos en este estudio se originó en

sitios de Internet relacionados. En este estudio, utilizaron imágenes RGB de cáncer de piel con 500–1000 píxeles, *jpg* y *tiff*. Con un total de 3753 imágenes, que se recopilan de Internet (*google.com* y *naver.com*, *baidu.com* y *bing.com*). Algunas imágenes recopiladas tienen ruidos, como otros órganos o herramientas. Esas imágenes se recortaron para reducir los ruidos para un mejor resultado. Las imágenes se agrupan por cuatro tipos de cáncer de piel (*queratosis actínica*, *carcinoma de células basales*, *carcinoma de células escamosas* y *melanoma*) Las imágenes adquiridas se procesaron mediante una red neuronal convolucional profunda, y las características de la red neuronal convolucional obtenida se clasifican en cuatro grupos: *queratosis actínica*, *carcinoma de células basales*, *carcinoma de células escamosas* y *melanoma*. Usaron para la clasificación *ECOC SVM* y utilizaron un modelo de red neuronal convolucional pre-entrenada *AlexNet*. Los resultado fueron para acc: *queratosis Actínicas* 0.92, *carcinoma basocelular* 0.91, *carcinoma de células escamosas* 0.95 y *melanoma* 0.94.

3. Método propuesto

Para este trabajo, se obtuvieron imágenes del *Dataset* de *ISIC*, donde encontramos melanomas y sus metadatos desde “<https://isic-archive.com/>”. Se prepararon dos conjunto de datos: 600 con metadatos y 600 sin metadatos (ver la tabla 1).

Paquetes	Conjunto	Tipo de Melanoma	Imágenes
Imágenes sin metadatos	Entrenamiento	Melanomas Benignos	200
		Melanomas Malignos	200
	Validación	Melanomas Benignos	100
		Melanomas Malignos	100
Imágenes con metadatos	Entrenamiento	Melanomas Benignos	200
		Melanomas Malignos	200
	Validación	Melanomas Benignos	100
		Melanomas Malignos	100

Tabla 1 – Conjuntos de imágenes con y sin metadatos; las imágenes son las mismas

En este caso se usaron 600 imágenes del *Dataset* del *ISIC*. Se tomaron las 600 imágenes para el primer grupo. Luego, a las mismas imágenes se le agregaron los metadatos para el segundo grupo. Con las imágenes se aplicaron las siguientes tres técnicas. Al final de cada técnica se usaron 40 imágenes tomadas al azar (20 de melanomas benignos y 20 de melanomas malignos), las cuales no estuvieron presentes en entrenamiento ni validación de la CNN. Se tomó esta muestra de 40 imágenes para asegurarse que la CNN clasificara imágenes nunca antes vistas por ella misma.

3.1. Técnica 1

Para esta técnica se añadieron los metadatos de: edad, género y tamaño del melanoma dentro de la matriz de píxeles a 600 imágenes, duplicando dichos metadatos.

En la Figura 1 se muestran las imágenes con metadatos y sin metadatos. En a) se muestran las imágenes originales desde *ISIC* mientras que en b) se muestran las imágenes con los metadatos añadidos repetidamente en las últimas 50 filas, por lo que, se puede ver una banda de colores en cada imagen.




Figura 1 – A) Matriz de imágenes sin metadatos. B) Matriz de imágenes con metadatos

Se ejecutó una *CNN*, con los siguientes parámetros: 8 épocas, 350 de altura, 300 de ancho, para las imágenes con metadatos y 300 de altura, 300 de ancho para las imágenes sin metadatos; 128 de *batch_size*, 2 clases, 1000 *step_train*, 300 *step_validation*, 32 *filter_Conv1*, 64 *filter_Conv2*, (3, 3) de *size_Filter*, (2, 2) de *size_Filter2* y (2,2) de *size_Pool*. Dos capas de convoluciones, en la Figura 2 se observa la arquitectura de la *CNN*.

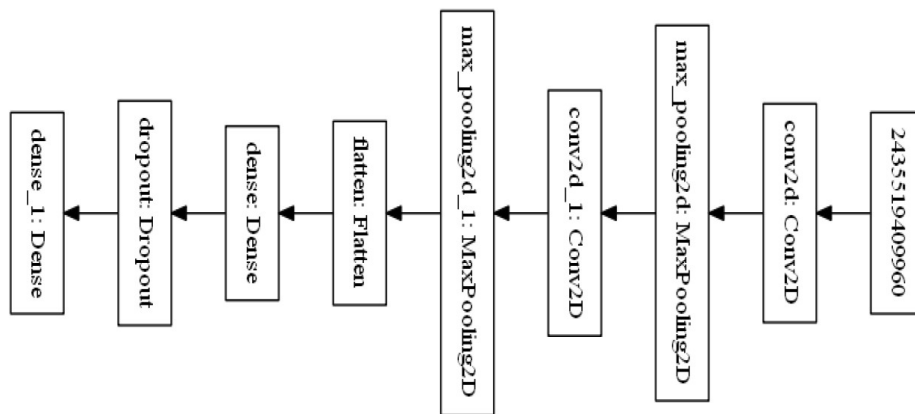


Figura 2 – Arquitectura de la *CNN*

Una vez que se hizo en entrenamiento con la *CNN* se obtuvieron las salidas que se muestran en la Tabla 2 en la que se observan los resultados sin metadatos; *Acc* se refiere a la *accuracy* (precisión) de 99.40%, *Val_Acc* del 64.00% a la precisión de la validación, por otro lado un 0.0177 del valor de *loss* se refiere a la función de pérdida, y un 2.7167 de *Val_loss* a la función de pérdida de la validación.

Épocas	Salidas sin metadatos				Salidas con metadatos			
	Acc	Val_Acc	Loss	Val_loss	Acc	Val_Acc	Loss	Val_loss
1	80.55%	68.50%	57.72%	89.27%	87.27%	78.50%	31.89%	57.47%
2	94.61%	65.00%	14.86%	131.44%	96.28%	77.00%	9.96%	92.77%
3	98.25%	65.00%	5.65%	179.03%	98.08%	78.50%	5.58%	120.50%
4	99.00%	62.00%	3.26%	201.52%	98.89%	79.50%	3.41%	129.10%
5	99.05%	65.50%	3.04%	203.11%	99.28%	79.00%	2.12%	129.93%
6	99.19%	66.00%	2.43%	250.44%	99.06%	82.50%	2.79%	124.01%
7	99.33%	65.00%	2.21%	228.89%	99.48%	76.50%	1.53%	160.71%
8	99.40%	64.00%	1.77%	271.67%	99.54%	80.50%	1.35%	154.90%

Tabla 2 – Salidas sin metadatos y con metadatos

Durante las ocho épocas se puede observar un mejor comportamiento sobre todo en Val_Accuracy. En la Figura 3 se observan las gráficas de la tabla en la cual se muestra el comportamiento de Accuracy y Val_Accuracy.

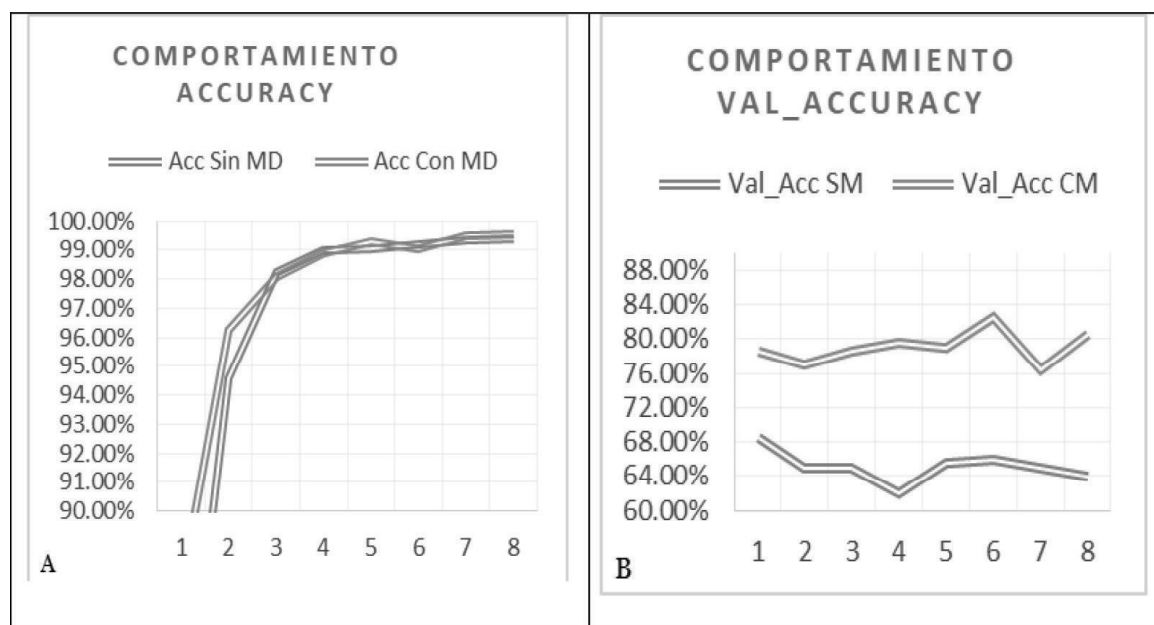


Figura 3 – Gráficas: A) con metadatos (Con MD) y sin metadatos (Sin MD) de Accuracy y B) con metadatos (CM) y sin metadatos (SM) Val_Accuracy

Al final, se hicieron pruebas con 40 imágenes (20 con metadatos y 20 sin metadatos, 10 malignas y 10 benignas para cada caso) no incluidas en el entrenamiento ni validación y los resultados fueron una precisión 77.5% en el escenario sin metadatos y 77.5% en el escenario con metadatos.

3.2. Técnica 2

Para la siguiente técnica, se quitó la piel de las imágenes. Se usaron 400 para el entrenamiento; 200 malignas y 200 benignas. Para la validación se usaron 200 imágenes 100 malignas y 100 benignas. En la Figura 4 se pueden observar ejemplos de algunas imágenes.




Figura 4 – Ejemplo de imágenes sin piel

El algoritmo usado permitió detectar la piel y segmentar los melanomas. En este caso en lugar de piel existe un fondo negro. Los parámetros para esta ejecución fueron los siguientes: Epocas 8, altura 300, ancho 300, *batch_size* 32, pasos 1000, pasos_ validacion 600, *filtrosConv1* 32, *filtrosConv2* 64, *tamano_filtro1* (3, 3), *tamano_filtro2* (2, 2), *tamano_pool* (2, 2).

Se aplicó la CNN con 8 épocas y se obtuvieron salidas que se muestran en la Tabla 3.

Épocas	Acc	Val_Acc	Loss	Val_loss
1	0.8585	0.6798	0.3264	0.3264
2	0.9769	0.6598	0.0686	1.7079
3	0.9873	0.6702	0.0359	1.8166
4	0.9898	0.6201	0.0269	2.1192
5	0.9926	0.6449	0.0202	2.2588
6	0.9937	0.6350	0.0172	2.5145
7	0.9942	0.6900	0.0163	2.5394
8	0.9954	0.6551	0.0111	2.9813

Tabla 3 – Resultados de imágenes sin piel

Se observa una alta precisión en el entrenamiento, pero muy bajo durante la validación. Al evitar la piel, se esperaban mejores resultados que la técnica 1. En la Figura 5 y 6 se observa las gráficas con el comportamiento de *Accuracy* y *Val_Accuracy*.




Figura 5 – Gráfica de acc y val_acc de la técnica 2 imágenes sin piel

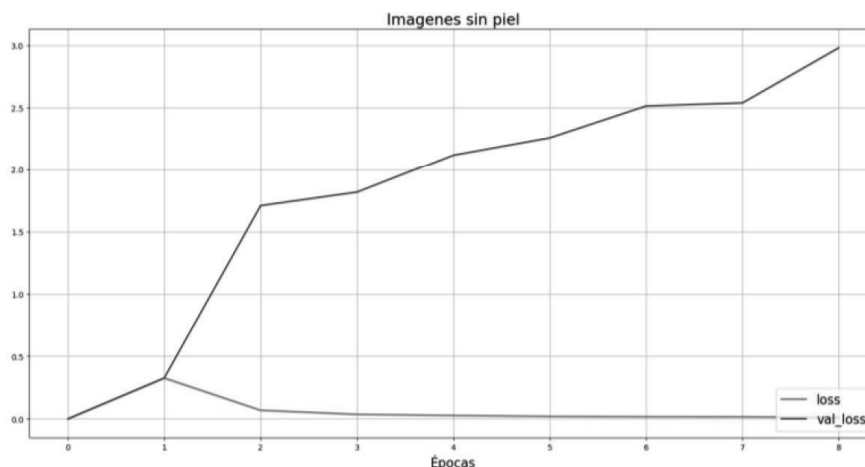


Figura 6 – Gráfica de loss y val_loss de la técnica 2 imágenes sin piel

Los valores de *Accuracy* se estabilizaron en más del 99% mientras que *Val_Accuracy* una vez que superó el 80% se estabilizó. En la Figura 6 es posible observar que el valor de *loss* tiende a cero, pero no así en la validación.

Se prosiguió a probar con 40 imágenes (20 malignas y 20 benignas) no incluidas en el entrenamiento ni validación y los resultados fueron 67.50% en el Acc.

3.3. Técnica 3

Para la tercera técnica, se usaron 600 imágenes obteniendo salidas poco satisfactorias, por lo que atendiendo a la filosofía de las CNNs de que se requieren una gran cantidad de imágenes. Por lo que, se procedió a aumentar al doble. Su ejecutó la CNN con los

siguientes parámetros: 1200 imágenes (400 malignas y 400 benignas) de entrenamiento. 400 imágenes de validación (200 malignas y 200 benignas), se aumentó la cantidad de imágenes. Longitud = 300, altura = 300, $batch_size = 20$ pasos = 1000 pasos validacion = 300 $filtrosConv1 = 32$ $filtrosConv2 = 64$. Se pueden observar el tipo de imágenes en la Figura 7.




Figura 7 – Tipo de imágenes usadas para la técnica 3

En esta técnica se tomaron las imágenes si algún pre-procesamiento desde ISIC. Los resultados de la prueba se observan en la Tabla 4

Épocas	ACC	VAL_ACC	Loss	Val_loss
1	0.7160	0.8100	0.6311	0.4821
2	0.7701	0.8725	0.4622	0.3744
3	0.8108	0.8650	0.4016	0.3667
4	0.8517	0.8325	0.3301	0.4619
5	0.8863	0.8525	0.2695	0.5041
6	0.9152	0.8475	0.2097	0.617
7	0.9361	0.7825	0.1678	0.7229
8	0.9489	0.8225	0.1313	0.7594

Tabla 4 – Resultados de la prueba 3

En este caso el valor más alto obtenido fue de 94.89% y apenas del 82.25% durante la validación. En la Figura 8 se observa el comportamiento de *Accuracy* y *Val_Accuracy*.

La tendencia de Accuracy muestra una tendencia ascendente. Con más épocas podría mejorar la precisión, sin embargo, se ejecutaron solo 8 épocas para coincidir con las

técnicas 1 y 2. En esta tercera técnica, se hicieron pruebas las 40 imágenes (20 malignas y 20 benignas) no incluidas en el entrenamiento ni validación y los resultados fueron 80% en el Acc.

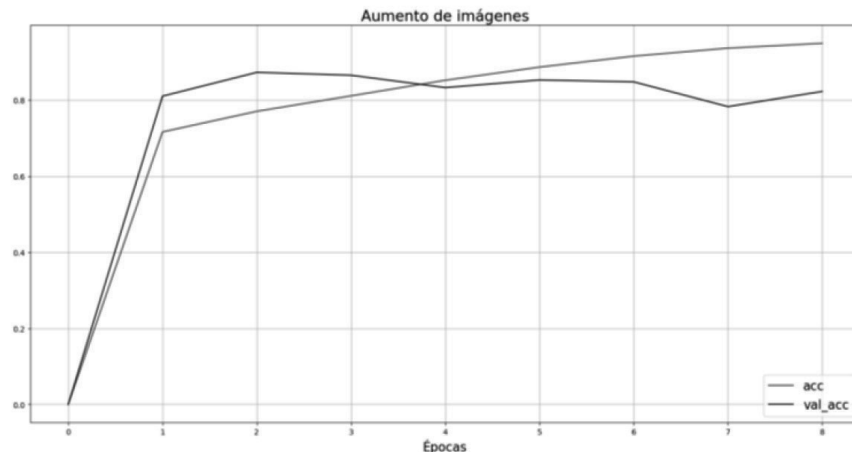


Figura 8 – Gráfica de acc y val_acc de la técnica 3

4. Resultados y comparación

En la Tabla 5 se muestran los resultados obtenidos durante los entrenamientos comparativos de las tres técnicas usadas, y otros trabajos.

Nuestros resultados	ACC	Val_Acc
1 Sin metadatos	99.40	64.00
1 Con metadatos	99.54	80.50
2 Sin piel	99.54	65.51
3 Sin pre-procesamiento	94.89	82.25
Otros trabajos		
Mahbod (Mahbod, Ecker & Ellinger, 2017)	0.89	
Shoieb (Shoieb, Youssef & Aly, 2016)	0.94	
Yu (Yu et al., 2018)	0.83	
Pomponiu (Brinker et al., 2018)	0.93	
Codella (Codella, Cai, & Garnavi, 2015)	0.91	
Dorj (Dorj, Lee y Choi, 2018)	0.94	

Tabla 5 – Comparativa de las tres técnicas con otros trabajos

En el caso de otros trabajos relacionados se encontraron resultados reportados de *Accuracy* y *Val_Accuracy*, pero no reportaron pruebas con otras imágenes. En la Tabla

6 se muestran los resultados comparativos de las tres técnicas usadas, con imágenes nunca vista por el entrenamiento ni validación de la CNN.

Técnica	ACC
1 Sin metadatos	77.50
1 Con metadatos	77.50
2 Sin piel	67.50
3 Aumento de imágenes	80.00

Tabla 6 – Comparativa de las tres técnicas

5. Conclusiones

Una vez obtenidas las salidas de los algoritmos podemos resumir que: durante el entrenamiento las técnicas arrojaron las siguientes salidas: 99.40% sin metadatos, 99.54% con metadatos, 99.54% sin la piel y 94.89 con más imágenes. Por otro lado, en la validación se observaron las siguientes salidas: el 64.00% sin metadatos, 80.50 con metadatos, 65.51% sin la piel y el 82.25% con más imágenes. Con estas salidas podríamos concluir que la mejor técnica es cuando se agregaron metadatos en las imágenes.

Sin embargo, se hicieron pruebas con imágenes que no estuvieron presente durante el entrenamiento ni durante la validación y se obtuvieron las siguientes salidas: el 77.50% sin metadatos, el 77.50% con metadatos, el 67.50 sin piel y el 80.00% con más imágenes. Por lo que, se puede concluir que la mejor técnica fue al añadir más imágenes a la CNN. Además, la tendencia del *Accuracy* es creciente, por lo que al aplicarse más épocas podría mejorar el 80% obtenido.

Por lo tanto, se concluye que el uso de una CNN no requiere pre-procesamiento especial en las imágenes y que basta usar el mayor número posible de imágenes así como de épocas con la finalidad de encontrar el mejor desempeño.

Como trabajos futuros se ha planteado: usar más imágenes y más épocas para mejorar el 80.00% de precisión; por otro lado, se usarán CNN pre-entrenadas con el fin de encontrar la mejor técnica para una implementación a nivel clínico.

Referencias

- Shoieb, A., D., Youssef M., S., & Aly M., W. (2016). Computer-Aided Model for Skin Diagnosis Using Deep Learning. *Journal of Image and Graphics*. (4), 116–121. doi:10.18178/joig.4.2.122-129
- Brinker, T. J., Hekler1, A., Utikal, J. S., Grabe, N., Schadendorf, D., Klode, J., & Kalle, C. V. (2018). Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review. *Journal of medical internet research*, 10. doi:10.2196/11936
- Burr, C., Piñó, A., Quiroz L. A., & Martín-Lunas, E. (s.f.). *Asociación de Salud y Bienestar Social De la Mujer y su Familia*. Recuperado el 01 de 04 de 2019, de <http://asbis.org.mx/PDF/guiapacienteparticipativo.pdf>

- Chang, H. (2017). *Cornell University*. Recuperado el 28 de 02 de 20019, de <https://arxiv.org/abs/1703.00534>
- Codella, N., Cai, J., & Garnavi, R. (2015). Deep Learning, Sparse Coding, and SVM for Melanoma Recognition in Dermoscopy Images de *Machine Learning in Medical Imaging*. Cham: *Springer*. Recuperado el 01 de 03 de 2018, de https://link.springer.com/chapter/10.1007/978-3-319-24888-2_15
- Herrea, G., N. E. (2010). El melanoma en México. *Revista de Especialidades Médico-Quirúrgicas*, 15(3), 161-164. Recuperado el 12 de febrero de 2018, de <http://www.redalyc.org/articulo.oa?id=47316054010>
- Mahbod, A., Ecker R., & Ellinger, I. (2017). *Cornell University*. Recuperado el 28 de 02 de 2019, de <https://arxiv.org/abs/1702.08434>
- Organización Mundial de la Salud*. (2018). Obtenido de <https://www.who.int/es/news-room/fact-sheets/detail/arsenic>
- Pattanayak, S. (2017). Pro Deep Learning with TensorFlow A Mathematical Approach to Advanced Artificial Intelligence in Python. India: *Apress*.
- Tarriba, J. E., Plata, A. M., Baldín, A. V., & Campo, A. A. (2017). Diagnóstico y tratamiento. *Acta médica Grupo Ángeles*. 15(2), 154-160. Recuperado el 12 de febrero de 2018, de <http://www.scielo.org.mx/pdf/amga/v15n2/1870-7203-amga-15-02-00154.pdf>
- Yang, X., Zen, Z., Yeo Yong, S., Tan, C., Tey Liang, H. & Su, Y. (2017). *Cornell University*. Recuperado el 01 de 02 de 2019, de <https://arxiv.org/abs/1703.01025>
- Yu, C., Yang, S., Kim, W., Jung4, J., Chung, K.-Y., Lee3, S. W. & Oh, B. (2018). Acral melanoma detection using a convolutional neural network for dermoscopy images. *PLoS ONE*. doi:<https://doi.org/10.1371/journal.pone.0193321>