

**UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**

**Colegio de Ciencias e Ingenierías**

**Towards Acne Marks Identification Using Deep Learning**

**Jordan Estalin Aguilar Campos**

**Ingeniería Eléctrica/ Electrónica**

Trabajo de fin de carrera presentado como requisito  
para la obtención del título de  
Ingeniero electrónico

Quito, 02 de Junio de 2022

**UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**

**Colegio de ciencias e ingenierías**

**HOJA DE CALIFICACIÓN  
DE TRABAJO DE FIN DE CARRERA**

**Towards Acne Marks Identification Using Deep Learning**

**Jordan Estalin Aguilar Campos**

**Nombre del profesor, Título académico**

**Diego Benitez, PHD**

Quito, 03 de junio de 2022

## © DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombres y apellidos: Jordan Estalin Aguilar Campos

Código: 137703

Cédula de identidad: 1715740377

Lugar y fecha: Quito, 03 de junio de 2022

## **ACLARACIÓN PARA PUBLICACIÓN**

**Nota:** El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETHeses>.

## **UNPUBLISHED DOCUMENT**

**Note:** The following capstone project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETHeses>.

## RESUMEN

En el presente trabajo se hace un estudio de personas con acné de entre 17-26 años de distintas provincias del Ecuador para poder predecir si dicha persona tendrá o no secuelas debido al acné y de ser el caso, saber si las secuelas serán leves o severas. Debido a que se tiene una cantidad de 386 fotografías de 135 personas se necesita incrementar la cantidad de imágenes para alimentar la red neuronal y poder tener mejores resultados tanto para el entrenamientos así como para el testeo, para esto se ha tomando muestras de puntos de acné de las personas y se ha incrementado significativamente la cantidad de imágenes. De esta manera también se puede determinar la probabilidad de que cada punto de acné deje secuelas en un futuro.

La clasificación del nivel de severidad de las huellas del acné se ha realizado mediante tres dermatólogos cualificados en las que se ha elegido aquellas fotografías donde al menos dos de los tres dermatólogos están de acuerdo en el nivel de severidad.

El software utilizado es PYTHON y la librería utilizada para la clasificación de imágenes es tensorflow 2.8.0.

**Palabras clave:** deep learning, inteligencia artificial, machine learning, clasificación de imágenes, redes convolucionales, red neuronal convolucional, acné, cicatrices por el acné.

## ABSTRACT

In the present work, a study of people with acne between 17-26 years of age from different provinces of Ecuador is carried out in order to predict whether or not said person will have sequelae due to acne and, if this is the case, to know if the sequelae will be mild or severe. . Due to the fact that there are a number of 386 photographs of 135 people, it is necessary to increase the number of images to feed the neural network and be able to have better results both for training and for testing, for this acne point samples have been taken. of people and the number of images has increased significantly. In this way you can also determine the probability that each acne point will leave sequels in the future.

The classification of the severity level of the acne marks has been carried out by three qualified dermatologists in which those photographs have been chosen where at least two of the three dermatologists agree on the level of severity.

The software used is PYTHON and the library used for image classification is tensorflow 2.8.0.

**Key words:** deep learning, artificial intelligence, machine learning, image classification, convolutional networks, convolutional neural network, acne, acne scars

**TABLA DE CONTENIDO**

Introducción .....	12
Desarrollo del Tema.....	15
Conclusiones .....	22
Referencias bibliográficas .....	24

## ÍNDICE DE TABLAS

	Cantidad_datos	train	test
<b>A</b>	156	120	36
<b>PL</b>	165	120	44
<b>PS</b>	65	50	15
<b>TOTAL</b>	386		

*Tabla 1. Imágenes totales para cada clasificación donde (A=sin huella, PL=huella leve, PS=huella severa)*

Tipo de clasificación	A			PL			PS		
	1 perfil	2 perfiles	3 perfiles	1 perfil	2 perfiles	3 perfiles	1 perfil	2 perfiles	3 perfiles
<b>Perfiles</b>	1 perfil	2 perfiles	3 perfiles	1 perfil	2 perfiles	3 perfiles	1 perfil	2 perfiles	3 perfiles
<b>Número de personas</b>	2	5	48	1	5	51	1	2	20
<b>Total Personas</b>	135								

*Tabla 2. Descripción de la cantidad de personas junto a la cantidad de perfiles que fueron tomadas las fotos.*

## ÍNDICE DE FIGURAS

Clasificación binaria.

En la grafica que se presenta a continuación se puede visualizar las curvas de de perdida y exactitud tanto para los datos de entrenamiento (los - accuracy) así como para los datos de evaluación (val\_loss-val\_accuracy)

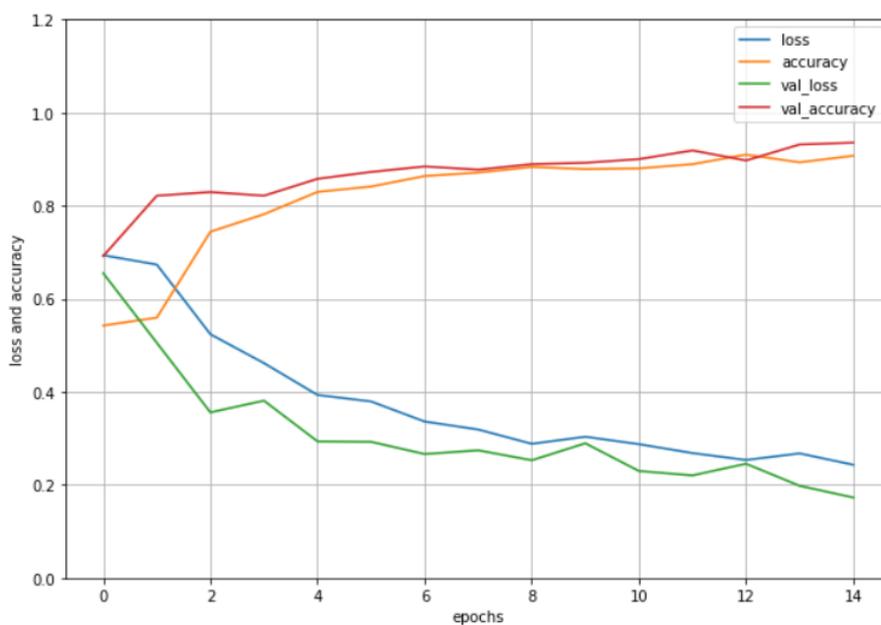


Figura 1. Curvas de los datos de entrenamiento y testeo, en la grafica se puede visualizar el error y la exactitud para los datos de entrenamiento así como el error y la exactitud para los datos de evaluación.

Matriz de confusión

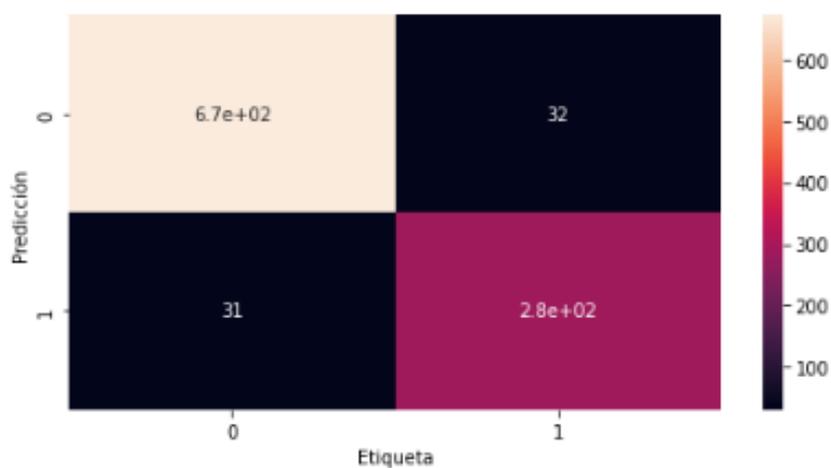


Figura 2. Matriz de confusión para la clasificación binaria, es decir, si le va a quedar huella o no.

Clasificación triple:

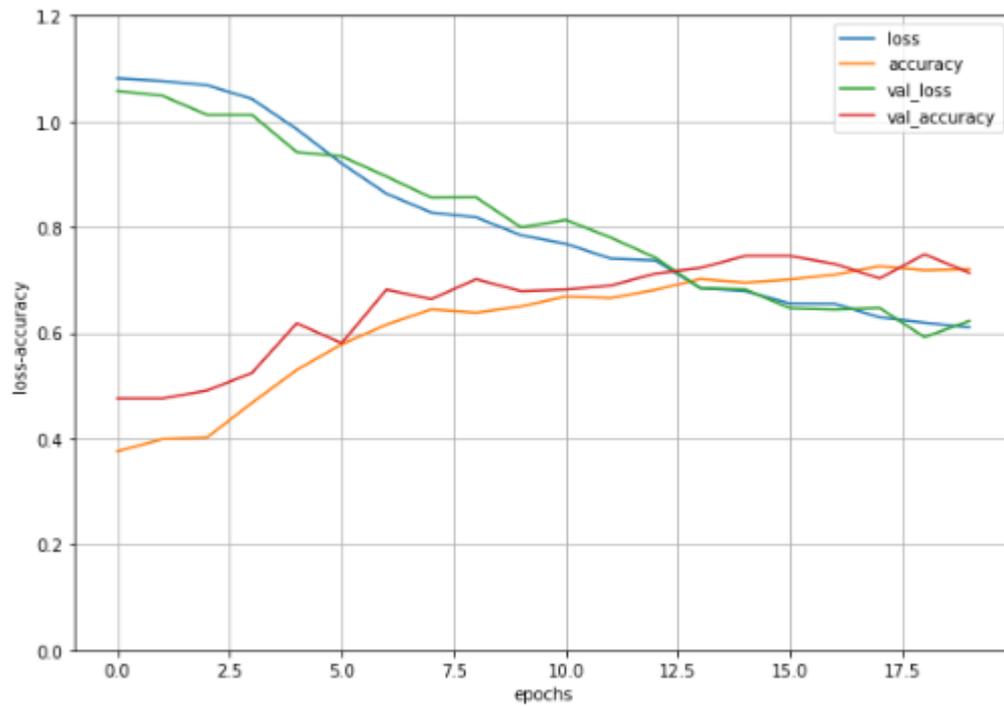


Figura 3. Graficas de los valores de los y accuracy tanto para los datos de entrenamiento así como los datos de evaluación.

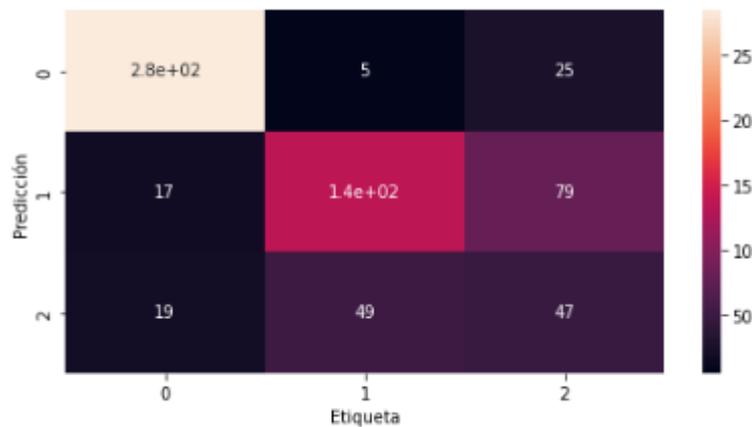


Figura 4. Matriz de confusión para la clasificación triple

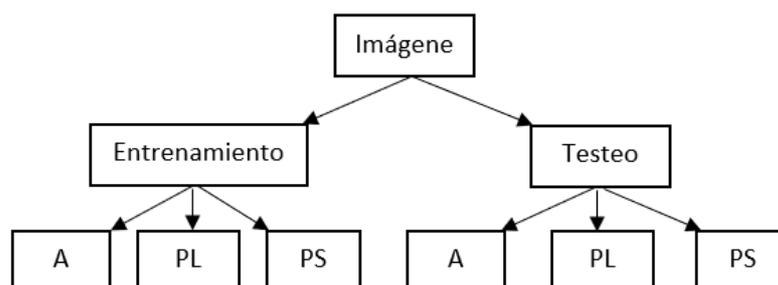
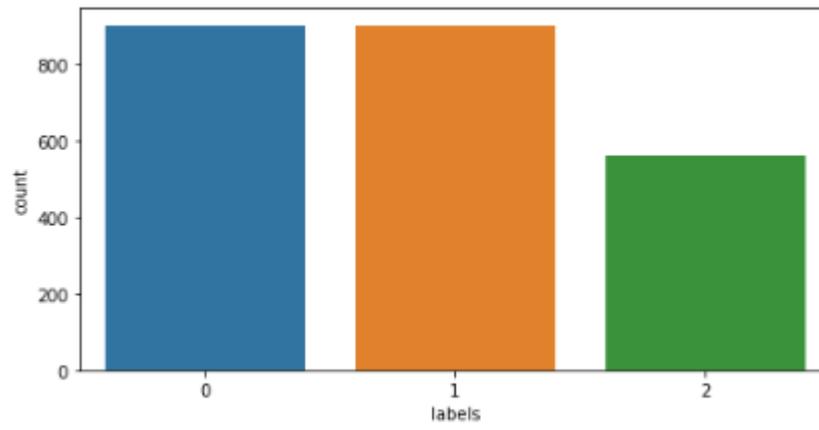


Figura 5. Esquema de como se encuentran clasificadas las imágenes en la base de datos a entrenar y testear.



*Figura 6.. cantidad de imagenes totales utilizadas para la clasificacion triple*

## INTRODUCCIÓN

El Deep Learning (DL) es un subconjunto del machine learning (ML) que a su vez es un subconjunto de la Inteligencia Artificial (IA). Mediante la aplicación del DL se han logrado resolver problemas muy complejos y tiene aplicaciones en los diferentes campos como puede ser: Anuncios dirigidos, marketing, clasificación de imágenes, reconocimiento de audio, conversión de texto a voz, conducción autónoma, entre otras. Para resolver cada uno de estos problemas se hace uso de un tipo específico de red neuronal, en este caso en particular se hace uso de la red neuronal convolucional (CNN por sus siglas en inglés) ya que es la red que mejores resultados proporciona al momento de realizar la clasificación de imágenes. Es importante mencionar también que dentro de los algoritmos que se tienen, estos se pueden clasificar en: supervisado, no supervisado, semi-supervisado y reforzado. Para este caso se hace uso de la técnica de aprendizaje supervisado ya que se posee una base de datos (fotografías) las cuales se las proporciona a la red neuronal para que extraiga las características principales basándose en las etiquetas que se le proporciona para cada fotografía y que la red aprenda por su propia cuenta para posteriormente proporcionarle un conjunto de imágenes sin etiquetas y que la red sea capaz de predecir la etiqueta correspondiente a cada fotografía.

La CNN es ideal para realizar clasificación de imágenes y se ajusta muy bien para poder tratar de manera adecuada la clasificación por niveles de severidad de las cicatrices debido al acné que presenta una persona ya que las secuelas del acné en muchos casos puede llegar a ser un gran problema social debido a que dichas marcas en el rostro de una persona pueden conllevar problemas tanto físicos como psicológicos así como de autoestima [1].

El acné es una afección que afecta al 80% de los jóvenes en el mundo con un impacto significativo en su calidad de vida; sin embargo, solo entre el 20% y el 30% tiene acceso a asesoramiento médico [2]. Dado que gran porcentaje de aquellas personas con acné no asisten

a un médico para llevar su tratamiento, muchos de ellos deciden automedicarse generando así un mayor problema porque los tratamientos deben ir de acuerdo con el tipo de piel de cada persona. Existen numerosos tratamientos: peelings químicos, dermoabrasión/microdermoabrasión, tratamiento con láser, técnicas punch, injertos dérmicos, punción y terapias combinadas para cicatrices atróficas: geles de silicona, esteroides intralesionales, crioterapia y cirugía de lesiones hipertróficas y queloides [3].

Teniendo en cuenta que las cicatrices del acné pueden llegar a ocurrir en hasta un 95% de las personas con acné vulgar debido a la pérdida o ganancia de colágeno cuando el cuerpo está curando los daños de la piel causados por la inflamación del acné [1] Se debe poner mucha más atención a este problema social; las cicatrices del acné pueden ser más problemáticas para los pacientes con acné vulgar, y pueden tener efectos psicológicos y emocionales adversos sustanciales en la vida social de los pacientes. Debilita la calidad de vida y puede provocar ira, depresión, vergüenza, mala imagen de sí mismo, bajo rendimiento académico, aislamiento social y oportunidades laborales limitadas [4].

La razón por la que estas personas deciden no asistir a un médico pueden ser varias entre las que se encuentran: motivos económicos, herencia familiar de no asistir a médicos para dicho tratamiento, falta de tiempo, etc. Es por esta razón que al implementar la tecnología en la detección temprana de la probabilidad de que le quede cicatrices a esa persona se puede disminuir los costos económicos y el tiempo que la persona debe estar con el médico hasta que pueda detectar el nivel de severidad de las cicatrices que le quedarán disminuyendo de esta forma que las personas se automediquen sin tener un diagnóstico previo.

Aunque el conocimiento sobre el impacto del acné vulgar en la calidad de vida ha aumentado en los últimos años, relativamente pocos estudios han evaluado el efecto de un cambio en la gravedad clínica sobre el estado psicosocial [5].

Aunque ya se ha propuesto un sistema automatizado de clasificación de cicatrices de acné basado en un modelo profundo de red neuronal convolucional (CNN). Donde cuatro dermatólogos experimentados recopilan y etiquetan un conjunto de datos de 250 imágenes de cinco clases diferentes donde los resultados experimentales demuestran la viabilidad del método propuesto con una precisión, especificidad y puntuación kappa del 92,53%, 95,38% y 76,7%, respectivamente [1]. Es importante mencionar que las imágenes proporcionadas en este caso corresponden a una porción bastante grande del rostro que puede llegar a cubrir un lateral del rostro o incluso el rostro completo.

La base de datos utilizadas para entrenar y testear la CNN son fotografías que fueron tomadas a personas de diferentes regiones del Ecuador. La cantidad total de fotografías proporcionadas son de 437, sin embargo, se han descartado aquellas fotografías en las cuales al menos dos de los tres dermatólogos no coinciden en su diagnóstico por lo cual la cantidad de fotografías utilizadas son 385 correspondientes a 135 personas las cuales para este análisis están clasificadas de la siguiente forma:

A=156; PL=164; PS=65

De esta cantidad de imágenes se ha obtenido únicamente segmentos de acné logrando así aumentar la cantidad de imágenes de manera significativa obteniendo los siguientes conjuntos de datos:

A=1214; PL=1137; PS=675

La forma y la cantidad de imágenes que se separo para el entrenamiento y el testeo se presenta en la parte de metodología-base de datos.

En este trabajo se presenta dos tipos de resultados obtenidos, por un lado, se realiza una clasificación binaria para obtener resultados de: presenta huella, no presenta huella.

Por otro lado, se hace una clasificación triple para obtener resultados de: no presenta huella, huella leve, huella severa.

## DESARROLLO DEL TEMA

### MATERIALES Y MÉTODOS

#### Base de datos

La base de datos utilizadas para entrenar y testear la CNN son fotografías que fueron tomadas a personas de diferentes regiones del Ecuador. La cantidad total de fotografías proporcionadas son de 437, sin embargo, se han descartado aquellas fotografías en las cuales al menos dos de los tres dermatólogos no coinciden en su diagnóstico por lo cual la cantidad de fotografías utilizadas son 387 de 135 personas. Para poder expandir esta base de datos se ha tomado segmentos de acné de cada una de las fotografías aumentando así de manera significativa la cantidad de imágenes, estas nuevas imágenes se han redimensionado y tienen 50\*50 píxeles y están en formato RGB. Estas nuevas imágenes se han tomado como la base de datos para el entrenamiento de la CNN y se realiza dos tipos de clasificaciones: clasificación doble: presenta huella o no; clasificación triple: no presenta huella (A), presenta huella leve (PL), presenta huella severa (PS). Cada una de estas clasificaciones se detalla a continuación.

1) Clasificación Triple: De un total de: A=1214; PL=1137; PS=675 imágenes se han segmentado de la siguiente manera:

A: train=900; test=314,

PL: train=900; test=231,

PS: train=560; test=115

Para esta clasificación se ha tratado de poner cantidades similares de imágenes para la parte de “train” para de esa manera evitar algún tipo de sesgo que pueda generar el algoritmo, sin embargo, en la subdivisión de PS el menor número de imágenes con lo cual se ha segmentado de dicha forma.

Para esta clasificación se ha tratado de poner cantidades similares de imágenes para la parte de “train” para de esa manera evitar algún tipo de sesgo que pueda generar el algoritmo, sin embargo, en la subdivisión de PS el menor número de imágenes con lo cual se ha segmentado de dicha forma. Los detalles de la CNN implementada se presentan en la sección de Materiales y Métodos, subsección “Modelo de Deep Learning implementado”

2) Clasificación Doble: Para este tipo de clasificación se han tomado las imágenes correspondientes a PL y PS y se han agrupado en una sola carpeta denominada "con\_huella" mientras que la carpeta A se ha quedado de la misma forma que para la clasificación triple y únicamente se le ha cambiado el nombre de la carpeta por: "sin\_huella", de esta manera la cantidad de imágenes para cada una de estas dos formas de clasificación quedan de la siguiente manera:

Con huella: train=1100; test=704

Sin huella: train=900 ; test=314

Debido a que la cantidad de imágenes está desbalanceada en los dos grupos, para la etapa de entrenamiento se ha puesto cantidad de imágenes que no tengan mucha diferencia ya que la CNN podría generar un sesgo.

Base de datos

El Deep Learning es un subconjunto del Machine Learning. Una red neuronal se considera de DEEP LEARNING cuando se tiene al menos dos capas profundas, en este tipo de algoritmo se tiene en cuenta la relación que existe entre cada una de las variables

El tipo de aprendizaje más común que se puede hacer con Deep Learning es el “aprendizaje supervisado”. Este tipo de aprendizaje automático consiste en aprender una función que mapea una entrada a una salida basada en pares de entrada-salida [7].

Las imágenes proporcionadas para el entrenamiento deben estar etiquetadas para posteriormente, en la etapa de testeo pasarle únicamente una imagen de entrada y esperar que la CNN proporcione una salida.

### **Generalización del funcionamiento de una red neuronal profunda (CNN)**

Generalidades del modelo

El modelo de Deep Learning se implementa haciendo uso de Python y sus principales librerías para la clasificación de imágenes como son: Tensorflow, Keras, pandas, numpy. Para el preprocesar las imágenes se hace uso de la librería “sklearn” y para generar las gráficas se hace uso de “matplotlib”. El proceso que se sigue para la implementación de la red neuronal es el siguiente:

- 1) Definición del conjunto de datos de entrenamiento tanto para la entrada como para la salida.
- 2) Pre-procesamiento de las imágenes
- 3) Definición de la arquitectura de la red neuronal
- 4) Se configura el aprendizaje de la red mediante diversas funciones como son: función de error, optimización, activación. Se hace uso de capas convolucionales, filtros, capa aplanadora.
- 5) Se compila el modelo con las funciones de pérdida, optimizador y las métricas
- 6) Se entrena la red neuronal.

### **Descripción del modelo implementado para la clasificación triple**

En una carpeta del computador se han guardado las imágenes separadas en diversas carpetas como se muestra en la Fig 5.

Las imágenes se cargan a Python y se almacenan en vectores, estas imágenes son cargadas y se almacenan en dos variables denominadas “train\_dir y test\_dir” y se cargan sus respectivas carpetas.

Para evitar cargar las imágenes desde el ordenador en cada entrenamiento se aplica a la función “LOAD\_FROMIMAGE=TRUE”, de esta manera, una vez que las imágenes se carguen se van a quedar almacenadas en vectores en la memoria RAM y posterior a esto se cambia el TRUE por FALSE para que en un nuevo entrenamiento no se vuelvan a cargar las imágenes desde el ordenador.

Se define una función y se le pasa las carpetas de “X\_train y X-test” y se define las etiquetas para cada subcarpeta: en este caso se han realizado las siguientes asignaciones: A=0, PL=1, PS=2. Se genera un bucle “For” para ir iterando carpeta por carpeta y se genera un reescalado de las imágenes de 50\*50\*3 en el caso que se inserten imágenes de otras dimensiones, el numero 3 corresponden a la profundidad de la imagen, en este caso las imágenes están en RGB.

Una vez termine de cargarse las imágenes se generan 4 archivos numpy en la carpeta principal donde tenemos almacenadas las otras carpetas con las imágenes, estos archivos son: “xtest.npy, xtrain.npy, ytest.npy, ytrain.npy” en los cuales se encuentran los vectores correspondientes a las imágenes de cada set de datos.

Mediante la función “seaborn” se genera un mapa de características donde se le pasa las imágenes con sus etiquetas, esta es una forma de visualizar las imágenes para darse cuentas de que tan balanceadas están los porcentajes de imágenes como se muestra en la Fig 6.

Posterior a esto se generan dos nuevas variables tanto para los datos de testeo así como para los de entrenamiento con las nuevas imágenes generadas y se le pasa las variables de “test\_dir y train\_dir” estas variables son aquellas que cargan las imágenes desde el ordenador, además

se le pasa el tamaño de las etiquetas, el modo de color, batch\_size (en este caso de 16), y el modo de clase(en este caso categorical)

Para generar el modelo se utiliza el modelo “Sequential()” y se generan tres capas convolucionales; la primera capa se describe a continuación:

```
model.add(Conv2D(filters=32, kernel_size=(3,3),input_shape=image_shape,  
activation='relu',))
```

también se aplica una capa de MaxPoolong con una ventana de 2x2 como se muestra a continuación:

```
model.add(MaxPooling2D(pool_size=(2, 2)))
```

En las dos siguientes capas únicamente cambian el filters=32 por filters=64

Después de estas tres capas convolucionales se aplica una capa aplanadora para pasar las dimensiones de las imágenes (50\*50) a un array de una sola dimensión.

```
model.add(Flatten())
```

Posterior a esto se aplica una capa densa y una función de activación como se muestra a continuación:

```
model.add(Dense(128))
```

```
model.add(Activation('relu'))
```

Finalmente se aplica la clasificación mediante la función "softmax" como se indica a continuación:

```
model.add(Dense(3, activation='softmax'))
```

Finalmente antes de entrenar la red neuronal se compila el modelo descrito anteriormente y se lo hace de la siguiente manera:

```
model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
```

Para poder almacenar posteriormente los pesos que proporcione el entrenamiento se genera una variable (en este caso "results") y se procede a entrenar la red como se muestra a continuación.

```
results = model.fit_generator(train_image_gen, epochs=20, validation_data=test_image_gen,  
callbacks=[early_stop])
```

Finalmente se presenta un esquema del modelo de funcionamiento de la red.

### **Descripción del modelo implementado para la combinación binaria**

El proceso y el esquema que se sigue para realizar esta clasificación es el mismo descrito para la clasificación triple, únicamente se cambia la capa densa encargada de realizar la clasificación, entonces, en lugar de 3 como el modelo anterior se escribe 2.

## **Resultados**

### **Clasificación triple (A,PL,PS)**

Los resultados proporcionados por este tipo de modelo de red neuronal son los mejores que se han podido obtener en cuanto al accuracy y a la función de pérdida (loss) tanto para los datos de entrenamiento y testeo. La red fue probada con distintos parámetros para obtener el mayor porcentaje de accuracy posible y el menor margen de error. Dicho esto, los hiperparámetros seleccionados son los que mejor se han podido adaptar al problema que se está resolviendo con la cantidad de imágenes disponibles.

### **Clasificación Binaria (con huella, sin huella)**

A continuación se presenta la clasificación binaria, en esta clasificación se puede observar que se obtiene un mayor margen de "accuracy" y un menor margen de "loss" en comparación a la clasificación triple. Esto se puede visualizar en las figuras 1 y 3 respectivamente.

A pesar de que en este tipo de clasificación se podría haber elegido una función "sigmoide" que es la adecuada para una clasificación binaria se eligió la función "softmax" ya que con esta función se obtuvo los mejores resultados.

## **Discusión**

Como se puede observar en las gráficas de los resultados en la parte superior, cuando se realiza una predicción binaria se obtiene mejores resultados que con la clasificación triple. Sin embargo, lo óptimo sería llegar a un porcentaje de exactitud de al menos un 98% pero a pesar de seleccionar de manera correcta los hiperparámetros no se ha podido alcanzar lo cual puede deberse a varias causas como son:

En la base de datos se tiene personas que tienen acné y los dermatólogos las han clasificado como que no les va a quedar huella y de igual manera existen imágenes de personas que tienen

muy poco acné (casi nulo a simple vista) que los dermatólogos los han seleccionado dentro de la clasificación PL es decir, que le va a quedar cicatriz severa. Al observar los resultados dentro de cada clasificación en ocasiones las imágenes no parecen pertenecer a dicho grupo, sin embargo, dado que son diagnósticos de dermatólogos especialistas en el tema no se ha manipulado las imágenes pasando a diferentes grupos ni se ha decidido elegir los puntos de acné a conveniencia para mejorar la red, todos los puntos de acné son elegidos de forma aleatoria sin poner énfasis en obtener únicamente los puntos de acné dependiendo al grupo que pertenezca, es decir, si pertenece a la clase PS no se ha decidido elegir únicamente los puntos que mas sobresalen sino también aquellos puntos de acné que son muy pequeños.

El porcentaje de exactitud para los dos tipos de clasificaciones también puede deberse a la baja cantidad de datos que se tiene ya que cuando se usa técnicas de deep learning, a mayor cantidad de datos mejor se comporta la red neuronal.

## CONCLUSIONES

El objetivo principal de clasificar las imágenes de personas con acné en tres grupos, es decir, A=sin huella, PL=huella leve y PS= huella severa y por otro lado de clasificar de forma binaria, es decir, de si la persona con acné va a tener o no huella en un futuro se realizó de manera satisfactoria obteniendo para estos dos tipos de entrenamiento y predicción los resultados que se mostraron en la parte superior y que de igual manera se escribe en la parte inferior de este inciso.

Mediante las técnicas implementadas de Deep Learning para cada conjunto de imágenes, tanto para la clasificación binaria así como para la clasificación triple se obtuvo buenos resultados considerando la cantidad de imágenes con las cuales se realizó el trabajo, estos

resultados son: 93% de exactitud y un 19.79% de error para los datos de evaluación del modelo.

Por otro lado, para la clasificación triple se obtuvo un porcentaje de exactitud inferior ya que es de: 74.85%, mientras que para el error se obtuvo un porcentaje de error de: 59.19%, estos datos son de las imágenes de evaluación del modelo.

La importancia del algoritmo que se realizó recae en que se extrajo puntos de acné de las personas para realizar el análisis de forma individual y no se mandó a entrenar al algoritmo con las fotografías de la cara completa de la persona.

En el presente trabajo se optimizó en gran medida los parámetros a implementar en el algoritmo para de esta manera reducir el costo computacional y que sea factible implementar el algoritmo en un computador común.

El objetivo principal de clasificar las imágenes de personas con acné en tres grupos, es decir, A=sin huella, PL=huella leve y PS= huella severa y por otro lado de clasificar de forma binaria, es decir, de si la persona con acné va a tener o no huella en un futuro se realizó de manera satisfactoria obteniendo para estos dos tipos de entrenamiento y predicción los resultados que se mostraron en la parte superior y que de igual manera se escribe en la parte inferior de este inciso.

## REFERENCIAS BIBLIOGRÁFICAS

- [1] M.Junayed, MD. Baharul, A.Ahsan, A.Sadeghzadeh, T.Biswas and A.Shahen, ScarNet: Development and Validation of a Novel Deep CNN Model for Acne Scar Classification With a New Dataset, published in IEEE access, pages (1245 - 1258), 23 de Diciembre de 2021
- [2] A.Kanne, S.Niang, A.Diagne, F.Ly and B.Ndiaye, Epidemiologic, clinical, and therapeutic features of acne in Dakar, Senegal, International Journal of Dermatology 2007
- [3] G.Fabbroci, M.C. Annunziata, V.D'Arco, V. de Vita, G.Lodi, M.C.Mauriello, F.Pastore, G.Manfrecola, Acne scars: pathogenesis, classification and treatment, National Library of Medicine, 14 de Octubre del 2010
- [4] Koo, "El impacto psicosocial del acné: percepciones de los pacientes", J. Amer. Academia Dermatol, vol. 32, núm. 5, págs. S26–S30, mayo de 1995.
- [5] M.M.Mulder, V.Sigurdsson, E.J.Van Zuuren, E.J.Klaassen, J.A.Faber, J.B de Wit, W.A.Van Vloten, Psychosocial impact of acne vulgaris. evaluation of the relation between a change in clinical acne severity and psychosocial state, National Library of Medicine, 2001
- [6] Risk of acne-induced scars - Ecuador, Participant characteristics, 02/06/2021.
- [7] M. Mohri, A.Rostamizadeh, A.Talwalkar, (2012) Foundation of Machine Learning. The MIT press

[7] J. Estrella, M. Camacho, M. Viteri, K. Aguilar, D. Belhadi, V. Bettoli, A. Buestan, B. Dreno, P. Endara, Pilot study for the evaluation and adaptation of a Four Item Acne-Scar Risk Assessment Tool (4-ASRAT): a resource to estimate the risk of acne-induced scars [version 1; peer review: 2 approved], F1000 RESEARCH, 18 Agosto 2020.

[8] Risk of acne-induced scars – Ecuador, 1-Participan Characteristics, 2 de Junio del 2021

J. Lan, Goodfellow, Y. Bengio and A. Courville, Deep Learning, MIT Press, 2016.

[10] F. Chollet, Deep learning with Python, Manning Publications, Second edition, 10 de Abril del 2018.

[9] A. Vannieuwenhuyze, Inteligencia artificial fácil. Machine Learning y Deep Learning practicos. Ediciones ENI. Abril del 2020

[10] A. Garcia. INTELIGENCIA ARTIFICIAL Fundamentos, practica y aplicaciones. Segunda edición. Alfaomega, RC Libros. 2016.