

INSTITUTO TECNOLÓGICO DE BUENOS AIRES – ITBA

ESCUELA DE POSTGRADO

# Modelo de diagnóstico por imágenes de estudios endoscópicos capsulares

AUTOR: Pando, Lucas Emiliano (Leg. N° 104244)

TUTOR: Gambini, Maria Juliana

TRABAJO FINAL PRESENTADO PARA LA OBTENCIÓN ESPECIALISTA EN CIENCIA DE DATOS

BUENOS AIRES  
SEGUNDO CUATRIMESTRE, 2019

<b>Introducción</b>	<b>3</b>
<b>Marco Conceptual y Antecedentes</b>	<b>3</b>
Marco Conceptual	3
Antecedentes de Deep Learning en el estudio de imágenes médicas	7
<b>Problema</b>	<b>8</b>
<b>Justificación del estudio</b>	<b>8</b>
<b>Alcances del trabajo y limitaciones</b>	<b>8</b>
<b>Hipótesis y Variables</b>	<b>9</b>
Hipótesis	9
Variables	9
Variable dependiente	9
<b>Variable independiente</b>	<b>9</b>
Variable de contexto	9
<b>Objetivos</b>	<b>9</b>
Objetivo General	9
<b>Objetivos Específicos</b>	<b>10</b>
<b>Metodologías</b>	<b>11</b>
Técnicas	11
Herramientas	15
<b>Resultados</b>	<b>16</b>
<b>Conclusiones</b>	<b>21</b>
<b>Referencias Bibliográficas</b>	<b>22</b>

# Introducción

En este trabajo se suscita una solución o modificación en el proceso del análisis de los estudios endoscópicos capsulares. Hoy en día el diagnóstico a través del estudio es realizado por un especialista que debe observar las imágenes o grabaciones obtenidas del estudio. Dicha tarea es extensa y monótona.

Se propone automatizar dicho proceso mediante la utilización de un modelo, acortando el tiempo de intervención humana. La participación del médico especialista seguirá siendo indispensable pero le permitirá ser más eficiente en la tarea. Con dicha finalidad, la solución pretende detectar la existencia o no de patologías en las imágenes por medio del estudio. Las patologías que se trata de detectar son: esofagitis, pólipos y colitis ulcerosa.

El modelo se construye utilizando metodologías de *Machine Learning*.

La ambición del proyecto es que el modelo al que se llegue, pueda ser utilizado por médicos y trabajadores de la salud en el análisis y el diagnóstico de estudios endoscópicos.

## Marco Conceptual y Antecedentes

### Marco Conceptual

El estudio endoscópico es un procedimiento por el cual un médico especialista introduce un instrumento, denominado endoscopio, en el cuerpo humano con el fin de poder hacer una observación del interior del mismo. Dependiendo qué órgano se necesita examinar, existen diversas clases de endoscopias.

Nombre del procedimiento	Órgano explorado
Colonoscopia	Colon y recto
Broncoscopia	Tráquea y bronquios de los pulmones
Colonoscopia flexible	Mayor longitud del colon e intestino grueso
Histeroscopia	Uterina y cuello uterino
Cistoscopia	Interior de la vejiga

gastrosocopia	estómago
esofagosocopia	esófago y duodeno (comienzo del intestino delgado)
laparoscopia	estómago, hígado u otros órganos abdominales, además los órganos reproductivos femeninos (útero, trompas de Falopio)
otoscopia	oído (caja sonora)
neuroendoscopia	senos del cerebro
colonoscopia	esófago y colon sigmoide
sigmoidoscopia	recto y colon sigmoide (parte inferior del colon)
broncosocopia	bronquios que recubre los pulmones y las estructuras adyacentes al corazón

Tabla 1 - Tipos de endoscopia - Junta Editorial de Cáncer.Net. (2017).

El endoscopio gástrico tiene una cámara unida a una estructura tubular delgada y flexible, similar a una manguera, que permite al médico avanzar a través de las diversas cavidades interiores del cuerpo. También, dicho instrumento, es utilizado para realizar ciertas cirugías como la remoción de pólipos intestinales o la cauterización de lesiones que produzca sangrado. El endoscopio se conecta a un monitor y transmite la imagen captada por la cámara que se encuentra en el otro extremo. En la imagen 1 se muestra un endoscopio Pentax Medical Emea.



Imagen 1 - Endoscopio - Gabrielle. (2017).[2]

Durante el estudio, el o los especialistas observan las imágenes captadas en vivo pudiendo realizar capturas como evidencia de alguna patología hallada.

Como se mencionó anteriormente, dependiendo del órgano, se requiere una endoscopia diferente ya sea por la anatomía o por la ubicación del mismo. El intestino delgado presenta un gran desafío al momento de ser examinado mediante los endoscopios tradicionales.

Solo se puede observar la zona del duodeno (comienzo del mismo), imposibilitando avanzar y cubrir su longitud completa. La endoscopia capsular ayuda a los médicos a ver dentro del intestino delgado. En este estudio, el paciente debe ingerir una cápsula que contiene una pequeña cámara y un conjunto de luces. A medida que la cápsula recorre el tracto digestivo, la cámara toma miles de imágenes y las envía a una grabadora que se coloca alrededor de la cintura del paciente. En promedio la cápsula toma dos imágenes por segundo, ofreciendo en total alrededor de 55.000 imágenes por estudio. La Imagen 2, muestra la composición y el tamaño de una cápsula endoscópica.

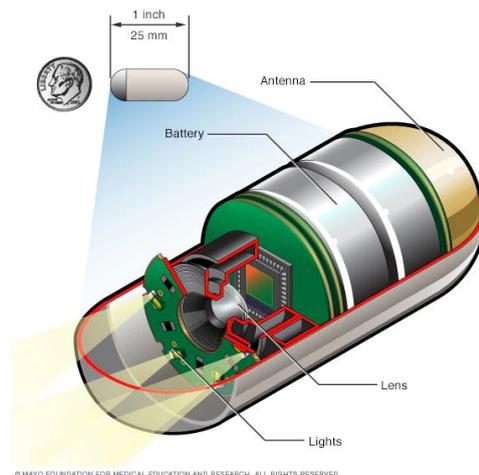


Imagen 2 - Cámara de endoscopia capsular - Personal de Mayo Clinic.(2019) [3]

La cápsula sirve sólo para diagnosticar y no permite obtener biopsias, aplicar tratamiento ni marcar las anomalías para posteriores cirugías. La cápsula no puede ser controlada, a diferencia de las endoscopias tradicionales, por lo tanto, si atraviesa por algún sector de interés, no es posible hacer ningún tipo de maniobra para visualizar mejor la zona. Sin embargo, pese a estas limitaciones, la endoscopia por cápsula a menudo es el examen preferido para descubrir la fuente de un sangrado en el intestino delgado. Así como también detectar pólipos, enfermedades inflamatorias del intestino (enfermedad de Crohn), úlceras y tumores.

Una vez finalizado el estudio, las imágenes que se guardan en la grabadora se transfieren a una computadora en donde se las une para crear un video. El médico mirará el video para detectar anomalías dentro del tracto digestivo.

Recientes reportes han evaluado la endoscopia capsular sola y en comparación con otras modalidades. Una revisión retrospectiva de 35 pacientes con pérdida de sangre gastrointestinal no identificada y una investigación endoscópica estándar negativa mostró que la endoscopia capsular identificó lesiones (úlceras, angiectasia y tumores) en el 83% de los casos. Los autores percibieron que la modalidad identificó una fuente de sangrado en el 63%.

Múltiples estudios han comparado la endoscopia capsular con la enteroscopia por empuje del intestino delgado. En una serie de 29 pacientes sometidos a ambos procedimientos, la endoscopia capsular identificó el sangrado en el 59% y la enteroscopia por empuje lo hizo en el 29%.

En la Imagen 3 se puede observar dos ejemplos de las fotografías que se toman en este tipo de estudios. El cuadro de la izquierda muestra un intestino sano, mientras que a la derecha puede observarse un intestino con una patología (Esofagitis).

#### Ejemplos de imágenes de estudios gastroenterológicos:

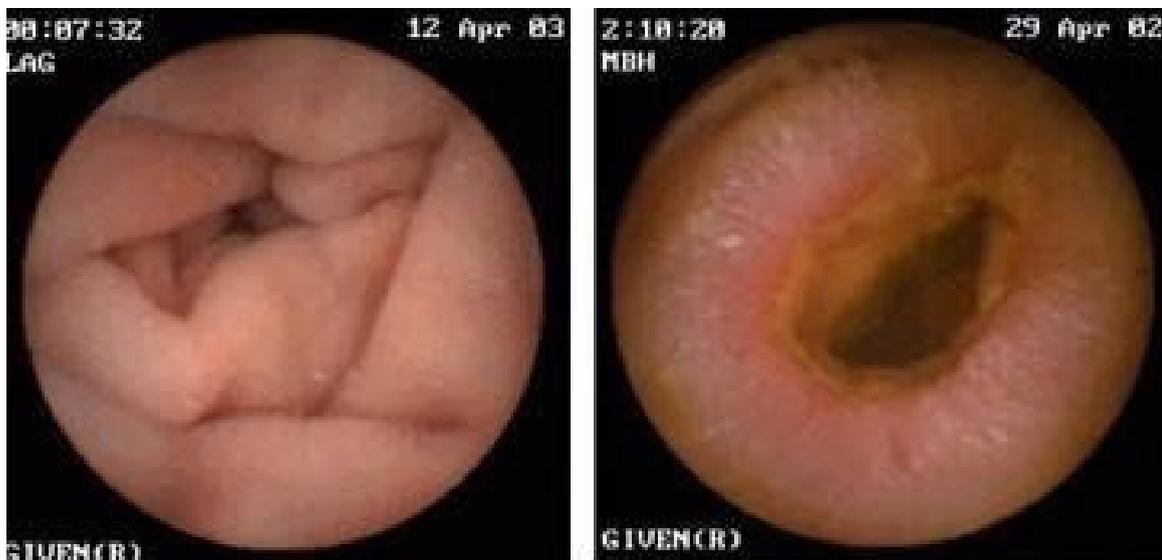


Imagen 3 - Imágenes de estudio endoscópico capsular - Centro Médico Teknon.(2019) [4]

Antecedentes de *Deep Learning* en el estudio de imágenes médicas

Con el objetivo de mejorar la velocidad y la precisión de diagnósticos médicos, equipos de investigadores han utilizado deep learning para entrenar un algoritmo capaz de utilizar reconocimiento de imágenes para diagnosticar tumores.

Para llevar a cabo dichos proyectos, se precisaron cientos de imágenes con regiones determinando si poseían o no células cancerígenas. Luego de identificar regiones claves, se tomaron muestras generando millones de ejemplos como base de los datos con los que se entrenaría el modelo. La investigación demostró que es posible desarrollar un algoritmo que alcance un porcentaje de éxito de diagnóstico del 92 por ciento. Y utilizando el algoritmo en combinación con el factor humano se llegaría a un 99,5 porcentaje de éxito.

Hoy en día, este tipo de investigaciones y de aplicaciones en la medicina es más frecuente, gracias a la evolución y el crecimiento de machine learning y data science.

## Problema

Se insume gran cantidad de tiempo manual de un experto en la revisión del conjunto de imágenes y grabaciones que resultan de un estudio endoscópico capsular. Esta tarea repetitiva puede producir la omisión de la detección de anomalías.

## Justificación del estudio

El origen del trabajo se basa en la detección de un proceso extenso y repetitivo al cual se deben someter los especialistas a la hora de analizar y evaluar un estudio endoscópico capsular. La observación de las imágenes o grabaciones de dichos estudios consumen una gran cantidad de tiempo que podría ser utilizado para otros fines o en tareas más productivas y gratificantes. Planteando una modificación en el proceso de análisis, mediante la introducción de la automatización utilizando un modelo de clasificación, se pretende acortar los tiempos de intervención de los especialistas. La generación del modelo tiene como premisa la aplicación general del mismo y la obtención de resultados esperados.

## Alcances del trabajo y limitaciones

El objetivo del trabajo sólo se limita a imágenes de estudios endoscópicos capsulares, dejando de lado otras imágenes que se obtienen en otros tipos de estudios. El resultado de la aplicación del modelo a nuevas imágenes será una clasificación. dentro de las 4 categorías determinadas (Sano, Esofagitis, Pólipos y Colitis Ulcerosa). Este trabajo solamente apunta al análisis automático de imágenes con el objetivo de asistir al médico y de ninguna forma pretende suplantarlo.

## Hipótesis y Variables

### Hipótesis

Es posible detectar la existencia de una patología intestinal a partir del análisis automático de imágenes de estudios endoscópicos capsulares, mediante la utilización de un modelo o algoritmo que permita automatizar el proceso y disminuir el tiempo manual que el mismo conlleva.

### Variables

#### Variable dependiente

Resultado del análisis de la imagen (Sano, Esofagitis, Pólipos y Colitis Ulcerosa).

#### Variable independiente

Características de la imagen: color del pixel, distribución de colores.

#### Variable de contexto

Imágenes correspondientes a endoscopias capsulares.

# Objetivos

## Objetivo General

Desarrollar un modelo que tenga la capacidad de detectar con un 85% de certeza la ocurrencia de alguna patología en las imágenes que se obtienen como resultado de un estudio endoscópico capsular.

En las imágenes siguientes, podemos ver ejemplos que se obtuvieron de los datos con los que se va a entrenar el modelo. El primer conjunto de imágenes corresponde a capturas de zonas sanas, mientras el segundo conjunto son patologías.

Sano:



Patológico:



Imágenes 5,6,7,8,9,10 - Imágenes de estudio endoscópico - Imágenes obtenidas del conjunto de datos con los que se desarrolla el modelo

## Objetivos Específicos

- > Generar un cuerpo de imágenes representativo para poder realizar el modelo.
- > Desarrollar un modelo que identifique la existencia de una patología.

- > Validar el modelo obtenido y determinar el grado de certeza.
- > Realizar mejoras al modelo, en caso de ser posible.

## Metodologías

### Técnicas

La composición del cuerpo de imágenes es el primer objetivo que se debe cumplir para poder avanzar con la construcción del modelo. Para ello, se realiza un análisis de las imágenes o grabaciones de los estudios obtenidos. En caso de los videos, se descompone el mismo en imágenes para poder ser utilizado como dato de entrada. Se lleva a cabo una tarea de limpieza de las imágenes, que consiste en el recorte y la suavización de las mismas para evitar introducir ruido en el modelo. Los datos obtenidos se centralizan en un repositorio.

Una vez obtenido el dataset, se comienza a desarrollar el modelo a través de la aplicación de redes neuronales profundas (*Deep Learning*). Estos métodos de aprendizaje son un subcampo de *Machine Learning*, en el cual se utilizan redes neuronales que contienen más de una capa oculta y permiten una representación más compleja de modelos. Particularmente en este trabajo, se utiliza redes neuronales convolucionales (CNN), las cuales consisten en múltiples capas de filtros convolucionales de una o más dimensiones. La CNN es un tipo de Red Neuronal Artificial con aprendizaje supervisado que procesa sus capas imitando al córtex visual del ojo humano para identificar distintas características en las entradas que en definitiva hacen que pueda identificar objetos. Para ello, la CNN contiene varias capas ocultas especializadas y con una jerarquía: esto quiere decir que las primeras capas pueden detectar líneas, curvas y se van especializando.

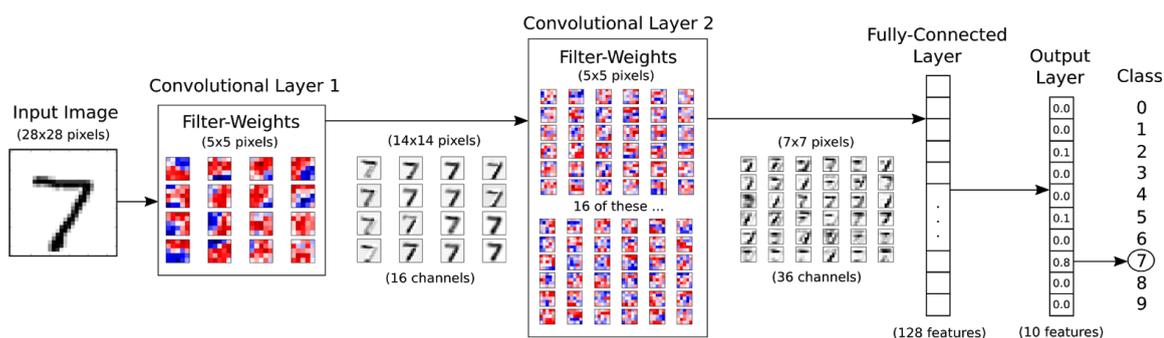


Imagen 11 - Esquema de red neuronal convolucional - Juan Carlos González.(2018) [5]

Como se observa en la Imagen 11, el gráfico de entrada (un 7 con una resolución de 28 x 28) se procesa en la primera capa convolucional utilizando los pesos de los filtros. Esto da como resultado 16 nuevas imágenes, una para cada filtro en la capa convolucional. Luego las imágenes se procesan de manera tal, que la resolución de éstas se reduce de 28 x 28 a 14 x 14.

Estas 16 imágenes más pequeñas se procesan en la segunda capa convolucional. En esta capa necesitamos un filtro para cada uno de estos 16 canales proveniente de la primera capa convolucional, y precisamos ponderar cada filtro para cada canal de salida de esta capa, es decir  $6 \times 6 = 36$ , que corresponden al número de canales de salida. Puesto que tenemos 36 canales de salida, tendremos un total de  $16 \times 36 = 576$  filtros en la segunda capa convolucional. Luego, las imágenes resultantes se procesan de nuevo para reducir la resolución a 7 x 7 píxeles.

La salida de la segunda capa convolucional es de 36 imágenes de 7 x 7 píxeles cada una. Estos se transforman a un único vector de longitud  $7 \times 7 \times 36 = 1764$ , que se utiliza como la entrada a una capa completamente conectada con 128 neuronas. Esto alimenta a otra capa totalmente conectada con 10 neuronas, una para cada una de las clases.

Como modelo a construir se utilizará una Red Residual de 50 capas (ResNet50). En la imagen 12 se puede observar como es la arquitectura de una ResNet de 34 capas.

### 34-layer residual

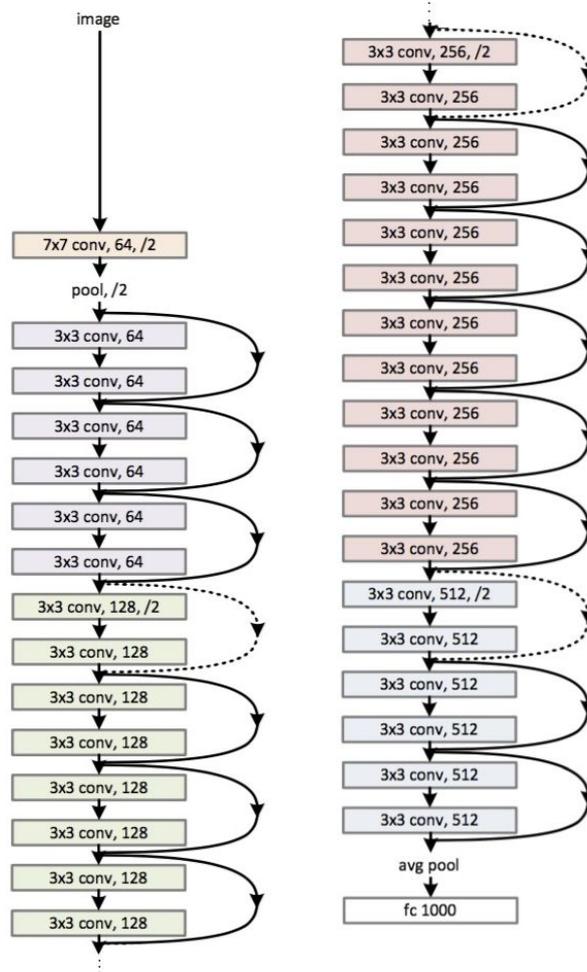


Imagen 12 -Arquitectura Resnet 34 Layers- Juan Carlos González.(2018) [6]

La imagen 12 muestra las diferentes capas que componen la Arquitectura Resnet, cada caja representa una capa convolucional con sus respectivos tamaños de imágenes y su cantidad de canales. Y por último vemos una caja que representa la capa *Fully Connected*, donde los diferentes valores son representados en un solo vector y es utilizado como entrada de un red completamente conectada.

Previamente a la construcción del modelo, se debe subdividir el dataset y apartar una cantidad determinada de datos para luego poder hacer una verificación de la solución obtenida. Este subconjunto de datos, se llama Set de Prueba, y nos permite, no solo validar el modelo, sino también determinar grado de certeza del mismo. El proceso de validación consta de la utilización del modelo para clasificar el Set de Entrenamiento y verificar el resultado obtenido con la clasificación real en cada ejemplo. Además se utiliza Transferencia de Conocimiento para el entrenamiento de la red, dicha técnica permite tomar el conocimiento aprendido por otra red neuronal y utilizarlo como base para

generar nuevos aprendizajes. El conocimiento de la red que se emplea se realizó con el dataset ImageNet (<http://www.image-net.org/>), el cual contiene más de 14 millones de imágenes etiquetadas con más de 20000 categorías.

Como último paso en esta metodología, se busca mejorar el modelo. La optimización de un modelo puede enfocarse en varios aspectos del mismo. Como por ejemplo el *Accuracy*, la Precisión o el Recall que forman parte de algunas de las métricas que obtenemos al utilizar el conjunto de prueba.

*Accuracy*: Cantidad de elementos están bien clasificados sobre la cantidad total.

$$Accuracy = \frac{TP+TN}{TP+TN+FN+TN}$$

Precisión: número de verdaderos positivos que son realmente positivos en comparación con el número total de valores positivos predichos.

$$Precision = \frac{TP}{TP+FP}$$

TP: Verdaderos Positivos, FP: Falsos Positivos

*Recall*: cantidad de verdaderos positivos que el modelo ha clasificado en función del número total de valores positivos.

$$Recall = \frac{TP}{TP+FN}$$

TP: Verdaderos Positivos, FN: Falsos Negativos

F1: combinación de las métricas de precisión y exhaustividad y sirve de compromiso entre ellas. La mejor puntuación F1 es igual a 1 y la peor a 0.

$$F1 = 2 * \frac{precision * recall}{precision + recall}$$

En este trabajo, se busca la optimización del valor de *Accuracy* del modelo. Aunque cada caso puede tener sus particularidades, hay ciertas técnicas que nos ayudan a encontrar el camino para la mejora del modelo. Una de dichas técnicas es el análisis de los errores que realiza el modelo en la

clasificación de las imágenes. De esta forma es posible detectar un patrón y realizar un nuevo entrenamiento de la red neuronal, haciendo que la misma aprenda la norma identificada.

Otra técnica de optimización es el aumento de los ejemplos de entrenamiento. En caso que los datos sean difíciles o costosos de obtener, existe una técnica llamada *Data Augmentation*, que permite obtener nuevos ejemplos a partir de los datos que tenemos. Para ello, se aplica diferentes transformaciones a la imágenes (recortes, rotaciones, zooms, cambio de color, etc) generando nuevas. También existen técnicas generales que se aplican a cualquier metodología de Machine Learning, como por ejemplo el ajuste de los hiperparámetros. Los hiperparámetros son valores de configuración que afectan la performance del modelo. Algunos de los hiperparámetros más utilizados son:

- *Tasa de aprendizaje*: es un valor que controla el cambio de los pesos en cada nueva iteración al momento de entrenamiento de una red neuronal.
- *Tamaño de los batches*: es la cantidad de datos que se utiliza en las diferentes etapas del desarrollo del modelo. Por ejemplo: se puede determinar el tamaño de conjunto de imágenes que se va a utilizar para realizar una iteración del proceso de aprendizaje.
- *Cantidad de iteraciones*: cantidad de veces que el proceso de aprendizaje se va a repetir en búsqueda de mejorar las métricas del modelo.
- *Profundidad de los árboles*: valor que limita el crecimiento del árbol en forma vertical.

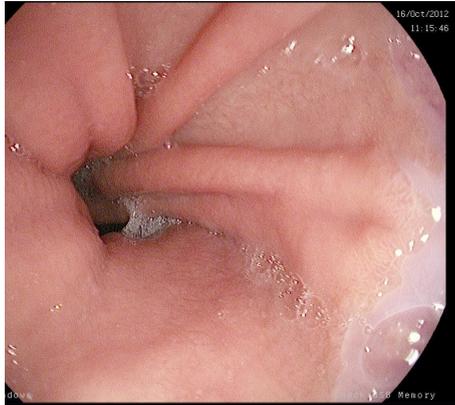
El proceso de ajuste de parámetros se realiza mediante pruebas y comparación de resultados.

## Herramientas

- Lenguaje de Programación: Python 3.
- Plataforma de desarrollo y prueba: Databrick, PaperSpace o solución similar.
- Repositorio de código e imágenes: GitHub.
- Herramientas de análisis y edición de Imágenes: Illustrator o Inkscape

## Resultados

A partir de los datos que se obtuvieron para la construcción del modelo, se identificaron cuatro posibles clases objetivo o resultados (Sano, Esofagitis, Pólipos y Colitis Ulcerosa). En las imágenes 13, 14, 15 y 16 se observa un ejemplo de las 4 clases que el modelo utiliza para catalogar el conjunto de datos.



### itis Ulcerosa



Imágenes 13,14,15,16 - Imágenes de estudio endoscópico - Imágenes obtenidas del conjunto de datos con los que se desarrolla el modelo

Por lo tanto, la finalidad del modelo es la clasificación de las imágenes dentro de estas cuatro posibilidades.

Como se describió en la sección de Técnicas y aproximación inicial de una solución para el problema planteado, se utilizó un red neuronal convolucional (CNN) pre entrenada llamada ResNet50. Como resultado obtuvimos un valor de accuracy del modelo de 65%, lo cual nos da un indicio que las imágenes proveen información suficiente para poder ser clasificadas mediante la utilización de un modelo. Pero el método utilizado podría no ser el adecuado para este caso particular.

El siguiente avance fue la implementación de una CNN sin previo entrenamiento, por lo tanto el aprendizaje de la misma se realizó íntegramente con las imágenes que se poseen de los estudios gastroenterológicos. Como nuevo resultado, se obtuvo un mejoramiento en el accuracy del modelo, alcanzando un 78%.

La imagen 17 nos describe el progreso del valor de *Accuracy*. Como podemos observar la curva de color azul o de entrenamiento es más suave que la curva naranja o de prueba. Esto significa que el modelo mejora en la medida que repite el proceso de entrenamiento. A mayor cantidad de épocas

(*epochs*) el modelo obtiene mayor *accuracy*. Una época es una iteración de entrenamiento en la cual el modelo utilizó todos los datos. En cambio, la curva de prueba no crece continuamente, sino que para ciertas cantidades de épocas, el *accuracy* disminuye. El comportamiento de dichas curvas se debe a que las predicciones que se realizan para graficar la curva de entrenamiento se obtienen de datos que el modelo utilizó para entrenar, por lo tanto se supone que son conocidos para él. Mientras que las predicciones para la curva de prueba se realizan con datos nuevos para el modelo. En caso que tengamos una diferencia aún mayor entre ambas curvas, donde la curva de entrenamiento obtenga un valor de *accuracy* muy superior, estaríamos en un estado de *Overfitting*. Lo que significa que el modelo solo puede predecir correctamente conjuntos de datos que haya visto y no nuevos.

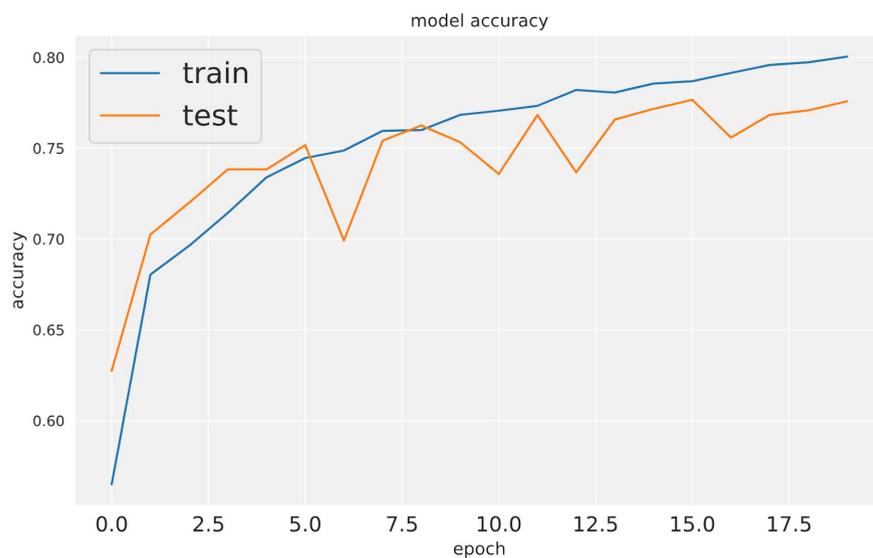


Imagen 17 - Gráfico de *Accuracy* en etapa de Entrenamiento y Prueba del modelo

En la imagen 18 podemos observar la pérdida o el error del modelo. Esto nos indica cuantas equivocaciones comete el modelo al momento de realizar predicciones. Al igual que ocurre en la imagen 17, la curva de entrenamiento es más suave y con una tendencia a decrecer continuamente. Mientras que la curva de prueba posee algunos picos en donde el error del modelo aumenta a medida que aumenta el número de épocas.

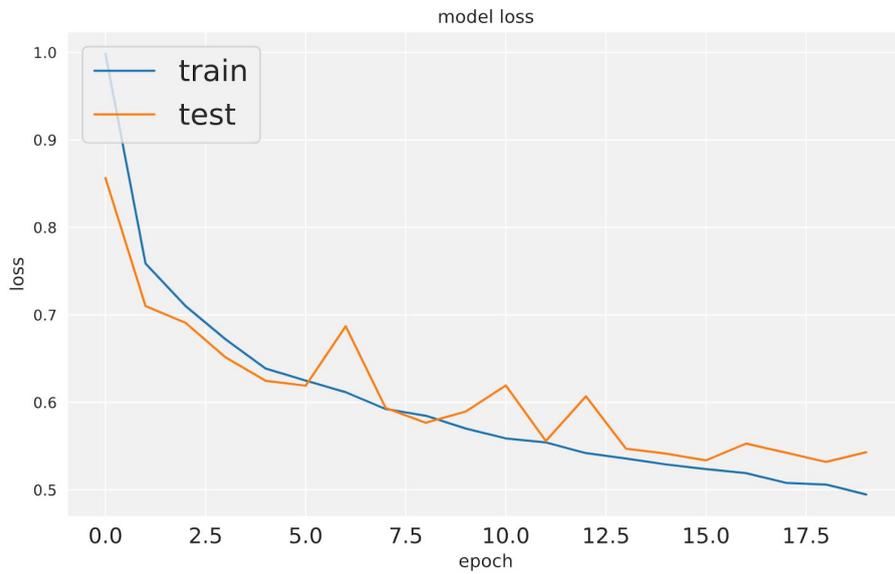


Imagen 18 - Gráfico de Error en etapa de Entrenamiento y Prueba del modelo

Es importante aclarar que los valores de las épocas son enteros. Aunque el eje x [Epoch] posee valores decimales, si observamos los puntos utilizados para conformar la curva podemos distinguir que realmente toma valores enteros únicamente.

Tabla 1: Matriz de confusión CNN

		Valores Reales			
		agitis	p	pos	is Ulcerosa
res ichos	agitis				
	p				
	pos				
	is Ulcerosa				

Mediante la matriz de confusión podemos obtener otras métricas que nos sirven para describir el modelo y poder identificar posibles errores.

Tabla 2: Métricas CNN

		ision	all	
agitis	p			

pos			
is Ulcerosa			

Con la finalidad de mejorar las métricas obtenidas con las CNNs se utiliza un modelo de *support vector machine* (SVM).

Una SVM es clasificador formalmente definido por un hiperplano de separación. En otras palabras, dado un conjunto de datos supervisados, el algoritmo obtiene un hiperplano óptimo que categoriza los ejemplos. En dos dimensiones el hiperplano es una línea que divide al plano en dos en donde se encuentra cada clase en un lado. Como se ve representado en la Imagen 19.

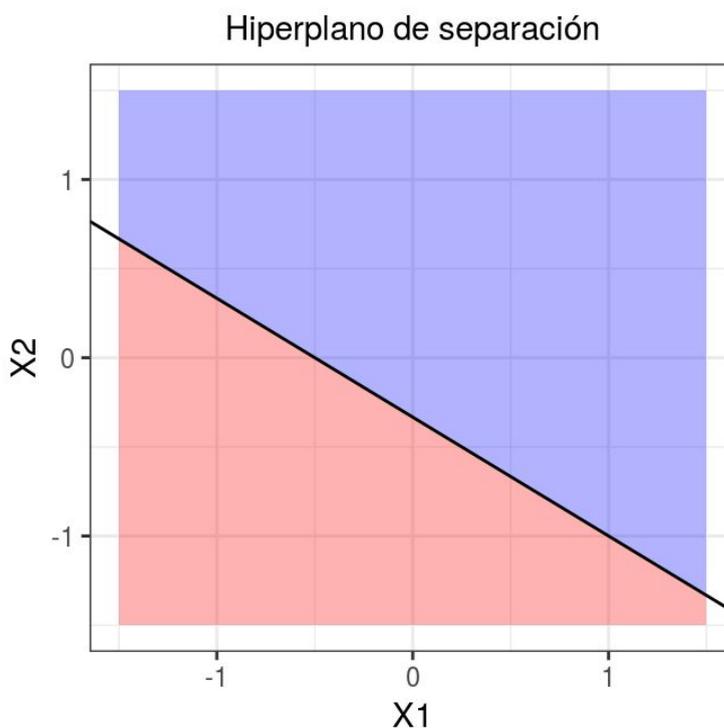


Imagen 19 - Hiperplano de un espacio bidimensional - Joaquín Amat Rodrigo.(2017) [12]

Cuando los problemas no son lineales, como se muestra en la Imagen 6, se utilizan funciones Kernel para poder alcanzar una solución adecuada. En el caso del problema planteado, utilizamos un Kernel Sigmoidal para hallar la solución. Existen otros Kernels como el RBF (función de base), el lineal y el polinomial.

Mediante este método se obtuvo un accuracy de 81% y una matriz de confusión como la siguiente:

Tabla 3: Matriz de confusión SVM

		Valores Reales			
		agitis	p	os	is Ulcerosa
res ichos	agitis				
	p				
	os				
	is Ulcerosa				

De la cual se calcularon las siguiente métricas:

Tabla 4: Métricas SVM

	ision	all	
agitis			
p			
os			
is Ulcerosa			

## Conclusiones

Se obtuvo un resultado con el que podemos asegurar que es posible la generación de un modelo que sea de utilidad para la clasificación de imágenes de estudios gastroenterológicos. De las diferentes soluciones que se realizaron en este trabajo, se concluyó que el modelo SVM obtuvo un mejor comportamiento al momento de clasificar las imágenes del conjunto presentado.

Con el fin de mejorar los modelos obtenidos, se podría hacer un preprocesamiento de las imágenes para conseguir un conjunto de datos más limpios y con menor ruido. Al preprocesar las imágenes para la creación del modelo, también debemos repetir los mismos pasos al utilizar imágenes nuevas, ya sea para realizar predicciones como para actualizar el modelo. Otra acción a realizar en busca de un aumento en la performance del modelo sería la obtención de un conjunto más grande de imágenes, lo que nos permitiría aumentar el dataset de entrenamiento, lo que produciría que el modelo posea más ejemplos con los que pueda aprender.

Específicamente en este tipo de utilización de modelos, se debe tener en cuenta el costo de los diferentes tipos de errores. Donde un Falso Negativo es mucho más riesgoso que un Falso Positivo, el cual puede ser descartado posteriormente. A través de este análisis y de las métricas del modelo, se pueden plantear objetivos para el mejoramiento de la solución.

La solución obtenida, podría ayudar a los especialistas en endoscopia a agilizar su trabajo permitiendo que el modelo haga una clasificación de las imágenes previa, para que luego ellos tengan un conjunto más acotado para supervisar. Particularmente en el caso de las endoscopias capsulares, el modelo permitiría hacer una revisión del estudio y delimitar los segmentos de interés para ser controlados por un especialista.

## Referencias Bibliográficas

- [1] Junta Editorial de Cáncer.Net. (2017).Tipos de endoscopia. Recuperado de <https://www.cancer.net/es/desplazarse-por-atenci%C3%B3n-del-c%C3%A1ncer/diagn%C3%B3stico-de-c%C3%A1ncer/pruebas-y-procedimientos/tipos-de-endoscopia>
- [2] Gabrielle. (2017). Pentax Medical Emea.[Imagen]. Recuperado de <https://nutreaunnino.com/pentax-medical-vnl1190/pentax-medical-emea>
- [3] Personal de Mayo Clinic.(2019). Cámara de endoscopia capsular. [Imagen]. Recuperado de [https://www.mayoclinic.org/-/media/kcms/gbs/patient-consumer/images/2013/11/15/17/43/ds00319\\_my00139\\_im04443\\_mcdc7\\_capsuleendoscopythu.jpg.jpg](https://www.mayoclinic.org/-/media/kcms/gbs/patient-consumer/images/2013/11/15/17/43/ds00319_my00139_im04443_mcdc7_capsuleendoscopythu.jpg.jpg)
- [4] Centro Médico Teknon(2019). Imagen estudio endoscópico capsular. [Imagen]. Recuperado de <http://www.teknon.es/es/pruebas-diagnosticas/endoscopia/capsula-endoscopica>
- [5] Juan Carlos González.(2018). Esquema red neuronal convolucional. [Imagen]. Recuperado de <https://www.apsl.net/blog/2018/02/02/tensor-flow-para-principiantes-vi-uso-de-la-api-keras/>
- [6] TitoOrt. (2018). Arquitectura ResNet 34 Layers. Recuperado de <https://datascience.stackexchange.com/questions/33022/how-to-interpert-resnet50-layer-types>
- [7] Laura J. Martin. (2017). Endoscopia. Recuperado de <https://medlineplus.gov/spanish/ency/article/003338.htm>
- [8] Personal de Mayo Clinic.(2019). Endoscopia capsular. Recuperado de [https://www.mayoclinic.org/-/media/kcms/gbs/patient-consumer/images/2013/11/15/17/43/ds00319\\_my00139\\_im04443\\_mcdc7\\_capsuleendoscopythu.jpg.jpg](https://www.mayoclinic.org/-/media/kcms/gbs/patient-consumer/images/2013/11/15/17/43/ds00319_my00139_im04443_mcdc7_capsuleendoscopythu.jpg.jpg)
- [9] ASGE.(2018). Cómo Comprender la Endoscopia Capsular. Recuperado de <https://www.asge.org/home/for-patients/patient-information/c%C3%B3mo-comprender-la-endoscopia-capsular>
- [10] Dres. Schmitt TM, Chua HK, Metzger PP.(2004). Endoscopía capsular para el diagnóstico de la hemorragia gastrointestinal oculta. Recuperado de <https://www.intramed.net/contenido.asp?contenidoID=31050&pagina=5>

[11] Dra. Anne C. Travis, Dr. John R. Saltzman. (2019). Sangrado del Intestino Delgado: Causas, Diagnóstico y Tratamiento. Recuperado de

<https://patients.gi.org/recursos-en-espanol/sangrado-del-intestino-delgado-causas-diagnostico-y-tratamiento/>

[12] Joaquín Amat Rodrigo. (2017). Máquinas de Vector Soporte (Support Vector Machines, SVMs)

[https://rpubs.com/Joaquin\\_AR/267926](https://rpubs.com/Joaquin_AR/267926)

[13] MathWorks (2019). Algoritmos de Machine Learning para clasificación (SVM)

<https://la.mathworks.com/discovery/support-vector-machine.html>

[14] Jana Alvarez (2016). Machine Learning y Support Vector Machines: porque el tiempo es dinero

<https://www.analiticaweb.es/machine-learning-y-support-vector-machines-porque-el-tiempo-es-dinero-2>

/