

Detección de tapabocas en imágenes para la prevención del COVID-19 a través de redes neuronales

Detection of face masks in images for the prevention of COVID-19 through neural networks

Luis Anillo*, Moises Mejia*, María Jose Melendez*, Silvia Moreno-Trillos**, Franklin Ruiz*

{smoreno12@unisimonbolivar.edu.co}

Universidad Simón Bolívar, Barranquilla-Colombia

Resumen

A finales del año 2019 apareció un nuevo virus denominado COVID-19, el cual ha afectado a muchos países alrededor del mundo y ha generado muchas muertes. Este virus entra al cuerpo por tres medios: ojos, nariz y boca. La organización mundial de la salud ordenó el uso indispensable de mascarillas en espacios públicos, personal de la salud y en personas infectadas, y el lavado constante de las manos para así prevenir la expansión de este virus y evitar mayores consecuencias a la población en general.

Debido a la falta de concientización acerca del virus, y por ende el uso inadecuado o simplemente el no usar mascarillas en espacios públicos, se ha generado un mayor número de contagios en este país, ocasionando un aumento en el sistema de salud. A pesar de todas estas normas, una pequeña parte de la población aún no se concientiza y estos siguen propagando el virus. En este trabajo proponemos un algoritmo que procese las diferentes imágenes que recibe y analiza a través de redes neuronales si la persona tiene o no mascarilla para así hacer su respectiva detección y llamado de atención y por ende prevenir la expansión del covid-19.

Palabras clave:

Visión Computacional, Redes Neuronales, Rede Neuronal convolucional.

Abstract

At the end of 2019, a new virus called COVID-19 appeared, which has affected many countries around the world and has caused many deaths. This virus enters the body by three means: eyes, nose, and mouth. The world health organization ordered the essential use of masks in public spaces, health personnel and infected people, and the constant washing of hands in order to prevent the spread of this virus and avoid greater consequences for the general population.

Due to the lack of awareness about the virus, and therefore the inappropriate use or simply not wearing masks in public spaces, a greater number of infections has been generated in this country, causing an increase in the health system. Despite all these norms, a small part of the population is still not aware and they continue to spread the virus. In this work we propose an algorithm that processes the different images that it receives and analyzes through neural networks whether or not the person has a mask in order to make their respective detection and call for attention and therefore prevent the spread of covid-19.

Key-words:

Computational Vision, Neural Networks, Convolutional Neural Network.



Para referenciar este artículo (IEEE):

L. Anillo, M. Mejia, M. Melendez*, F. Ruiz & S. Moreno-Trillos, "Detección de tapabocas en imágenes para la prevención del COVID-19 a través de redes neuronales", *Investigación y Desarrollo en TIC*, vol. 12, no. 2, pp. 1 – 12., 2021.

I. INTRODUCCIÓN

El 30 de enero del 2020, el director general de la organización mundial de la salud, el doctor Tedros Adhamon Ghebreyesus anunció que el Covid-19 se caracterizaba como una pandemia [1]. Este apareció a finales del año 2019 en la ciudad de Wuhan (China), el cual ha afectado a muchos países alrededor del mundo y ha generado más de 2,5 millones de muertes a nivel mundial, a nivel continental por lo que va del año 2021 el número de personas fallecidas son las siguientes: América con 1.282.028, Europa con 897.671, Asia con 371.037, África con 107.826 y Oceanía con 1.234 [2]; En Sudamérica la directora de la organización panamericana de la salud (OPS), Carissa F. Etienne tildó la situación actual de la pandemia en Sudamérica como, emergencia de salud pública activa, a pesar de que ya se han entregado diversas dosis de vacunas contra el virus todavía faltan varios meses para que la mayoría de las personas puedan acceder a ellas, la doctora Etienne advirtió que el virus va en peligroso aumento en muchos países de Sudamérica[3]. En nuestro país hasta el momento van 64.492 muertos, y está comenzando el tercer pico de la pandemia en muchas ciudades siendo las principales víctimas las personas de la tercera edad, Colombia al 4 de abril del 2021 todavía cuenta con 2.456.409 casos activos siendo los territorios más afectados del país. Bogotá con 690.844 casos activos, Antioquia con 380.299 casos activos, Valle del Cauca con 209.698 casos activos, Atlántico con 156.343 casos activos y Cundinamarca con 111.526 casos activos [4].

Debido a que este virus se transmite por las pequeñas gotas que salen tanto de la nariz o la boca de una persona infectada al toser, estornudar o hablar. Es más fácil contagiarse debido a que las personas que se encuentran infectadas no presentan síntomas si no después de 8 días, pero sigue contagiando una persona puede infectarse si inhala las gotículas de una persona infectada. Este virus entra al cuerpo por tres medios: ojos, nariz y boca; por ende la organización mundial de la salud ordenó el uso indispensable de mascarillas en espacios públicos, personal de la salud y en personas infectadas, y el lavado constante de las manos para así prevenir la expansión de este virus y evitar mayores consecuencias a la población en general; aunque con todas estas recomendaciones y cifras aún se encuentran personas que no toman las medidas de bioseguridad, no se lavan las manos y tampoco usan tapabocas o simplemente no lo usan de forma correcta.

Con este proyecto proponemos un algoritmo que procese las diferentes imágenes que recibe y analiza a través de redes neuronales si la persona usa o no mascarilla para así hacer su respectiva detección y llamado de atención y por ende prevenir la expansión del covid-19.

De igual manera se tiende a maximizar la bioseguridad en espacio público y privados mediante el correcto uso de las mascarillas, reduciendo en gran manera la expansión de este virus.

II. MARCO TEÓRICO

Visión computacional.

La visión computacional es un asunto relativamente nuevo que va conectado con el aprendizaje de las máquinas. Concepto conocido también como visión por computador, es el área de la ciencia que desarrolla teorías y métodos hacia la extracción automática de información de servicio o útil contenida en imágenes.

Se sabe que la visión humana trabaja con base en un análisis de la imagen que llega a la retina y es enviada a la corteza visual. La visión computacional se basa totalmente en la visión humana y trabaja con el proceso

de modelado y réplica de esa visión usando software y hardware súper avanzados. La visión computacional trabaja con tareas que son aplicadas al proceso de visión computacional a fin de realizar la identificación total de las imágenes de forma amplia y sin esfuerzo. Los avances en estas áreas ya son perceptibles y el futuro de la visión computacional es integrar sistemas poderosos y específicos del cual se tiene grandes expectativas. [5]

Redes neuronales.

Las redes neuronales artificiales (también conocidas como sistemas conexionistas) son un modelo computacional el que fue evolucionando a partir de diversas aportaciones científicas que están registradas en la historia. Las redes neuronales artificiales están basadas en el funcionamiento de las redes de neuronas biológicas. Las neuronas que todos tenemos en nuestro cerebro están compuestas de dendritas, el soma y el axón: Las dendritas se encargan de captar los impulsos nerviosos que emiten otras neuronas. Estos impulsos, se procesan en el soma y se transmiten a través del axón que emite un impulso nervioso hacia las neuronas contiguas.

En el caso de las neuronas artificiales, la suma de las entradas multiplicadas por sus pesos asociados determina el “impulso nervioso” que recibe la neurona. Este valor, se procesa en el interior de la célula mediante una función de activación que devuelve un valor que se envía como salida de la neurona.

Del mismo modo que nuestro cerebro está compuesto por neuronas interconectadas entre sí, una red neuronal artificial está formada por neuronas artificiales conectadas entre sí y agrupadas en diferentes niveles que denominamos capas:

"Una capa es un conjunto de neuronas cuyas entradas provienen de una capa anterior (o de los datos de entrada en el caso de la primera capa) y cuyas salidas son la entrada de una capa posterior."

Las neuronas de la primera capa reciben como entrada los datos reales que alimentan a la red neuronal. Es por eso por lo que la primera capa se conoce como capa de entrada. La salida de la última capa es el resultado visible de la red, por lo que la última capa se conoce como la capa de salida. Las capas que se sitúan entre la capa de entrada y la capa de salida se conocen como capas ocultas ya que desconocemos tanto los valores de entrada como los de salida.

Una red neuronal, por lo tanto, siempre está compuesta por una capa de entrada, una capa de salida (si solo hay una capa en la red neuronal, la capa de entrada coincide con la capa de salida) y puede contener 0 o más capas ocultas. El concepto de Deep Learning nace a raíz de utilizar un gran número de capas ocultas en las redes. [6]

Aplicación de RNA.

Las tareas se aplican a las redes neuronales artificiales tienden a caer dentro de las siguientes categorías generales:

Aproximación de funciones, o el análisis de regresión, incluyendo la predicción de series temporales, funciones de aptitud y el modelado.

Clasificación, incluyendo el reconocimiento de patrones y la secuencia de reconocimiento, detección y de la toma de decisiones secuenciales.

Procesamiento de datos, incluyendo el filtrado, el agrupamiento, la separación ciega de las señales y compresión. Robótica, incluyendo la dirección de manipuladores y prótesis. Ingeniería de control, incluyendo control numérico por computadora.

Las áreas de aplicación incluyen la identificación de sistemas y el control (control del vehículo, predicción de trayectorias, el control de procesos, manejo de recursos naturales), la química cuántica, juegos y la toma de decisiones (backgammon, ajedrez, póquer), el reconocimiento de patrones (sistemas radar, reconocimiento facial, clasificación de señales, reconocimiento de objetos y más), de reconocimiento de secuencia (gesto, voz, reconocimiento de texto escrito a mano), diagnóstico médico, aplicaciones financieras (por ejemplo, sistemas automatizados de comercio (trading algorítmico)), minería de datos (o descubrimiento de conocimiento en bases de datos, "KDD"), la visualización, traducción automática, diferenciando entre informes deseados y no deseados en redes sociales, prevención de spam (correo basura) de correo electrónico.

El software de la red neuronal se utiliza para simular, investigación, desarrollo y aplicación de redes neuronales artificiales, redes neuronales biológicas y, en algunos casos, una gama más amplia de sistemas adaptativos.

Tipos de redes neuronales artificiales: Tipos de redes neuronales artificiales varían de aquellos con sólo una o dos capas de lógica única dirección, para muchos bucles complejos multi-direccionales de entrada de realimentación y capas. En general, estos sistemas utilizan algoritmos en su programación para determinar el control y la organización de sus funciones. La mayoría de los sistemas utilizan "pesos" para cambiar los parámetros del rendimiento y las diferentes conexiones con las neuronas. Las redes neuronales artificiales pueden ser autónomas y aprender mediante el aporte de "maestros" externos o incluso auto-enseñanza de las reglas escritas de entrada. Redes neuronales estilo Cubo Neural primera por primera vez por Gianna Giavelli proporcionan un espacio dinámico en el que las redes se recombinan dinámicamente información y enlaces a través de miles de millones de nodos independientes que utilizan la adaptación neuronal darwinismo, una técnica desarrollada por Gerald Edelman, que permite sistemas más modeladas biológicamente. [7]

Rede neuronal convolucional.


Es un algoritmo de Deep Learning que está diseñado para trabajar con imágenes, tomando estas como input, asignándole importancias (pesos) a ciertos elementos en la imagen para así poder diferenciar unos de otros. Este es uno de los principales algoritmos que ha contribuido en el desarrollo y perfeccionamiento del campo de Visión por computadora.

Las redes convolucionales contienen varias hidden layers, donde las primeras puedan detectar líneas, curvas y así se van especializando hasta poder reconocer formas complejas como un rostro, siluetas, etc. Las tareas comunes de este tipo de redes son: Detección o categorización de objetos, clasificación de escenas y clasificación de imágenes en general.

La red toma como entrada los píxeles de una imagen. Si tenemos una imagen con apenas 28×28 píxeles de alto y ancho, eso equivale a 784 neuronas. Y eso es si sólo tenemos 1 color (escala de grises). Si tuviéramos

una imagen a color, necesitaríamos 3 canales (red, green, blue) y entonces usamos $28 \times 28 \times 3 = 2352$ neuronas de entrada. Esa es nuestra capa de entrada. Pero antes es necesario normalizar la “data”, es decir que nuestros pixeles que ahora tienen valores entre 0 y 255, tengan valores entre 0 y 1, podemos lograrlo dividiendo cada uno de los pixeles al valor más alto que estos tienen es decir 255.

Kernel: El kernel en las redes convolucionales se considera como el filtro que se aplica a una imagen para extraer ciertas características importantes o patrones de esta. Entre las características importantes para lo que sirve el kernel son detectar bordes, enfoque, desenfoco, entre otros. Esto se logra al realizar la convolución entre la imagen y el kernel.



Específicamente, en el caso de la visión por computador, muchos modelos previamente entrenados (muchos entrenados en el conjunto de datos ImageNet) ahora están disponibles públicamente para su descarga y se pueden usar para crear potentes modelos de visión con muy pocos datos. [8]

Los principales componentes de una red neuronal convolucional son las capas convolucionales, agrupación, y totalmente conectadas como se muestra a continuación:

Las redes neuronales convolucionales están conformadas por una serie de capas, como se pudo ver anteriormente. Estas pueden producir un conjunto de puntuaciones de clase para una imagen determinada, las capas convolucionales de redes neuronales convolucionales actúan como extractores de características; estos extraen patrones de forma y color de los valores de píxeles de las imágenes de entrenamiento. una red neuronal convolucional aprende a encontrar los mejores pesos durante el entrenamiento usando un proceso llamado backpropagation, que examina cualquier error de clasificación que una red neuronal convolucional comete durante el entrenamiento, encuentra que pesos en esa red neuronal convolucional son responsables de ese error y cambia esos pesos en consecuencia. [9]

Backpropagation, también conocida como retro-programación en español es un algoritmo que nos indica cuánto de culpa tiene cada neurona del error global cometido, este algoritmo determina la culpa del error, calculando las derivadas parciales de la función de coste con respecto a cada una de las variables. [10]

Este algoritmo se introdujo originalmente en 1970 pero su importancia llegó con el famoso artículo de 1986 de David Rumelhart, Geoffrey Hinton y Ronald Williams en el cual se describen varias redes neuronales en la que la retro propagación funciona mucho más rápido que los enfoques de aprendizaje anteriores, lo cual hace posible utilizar redes neuronales para resolver problemas que anteriormente no tenían solución. [11].

Open CV

Open Source Computer Vision es una librería software open-source de visión artificial y machine learning. La cual provee una infraestructura para aplicaciones de visión artificial.

Esta tiene una licencia BSD, lo que permite utilizar y modificar el código, tiene una comunidad de más de 47000 personas y más de 7 millones de descargas. Es una librería muy usada a nivel comercial, desde Google, Yahoo, Microsoft, Intel, IBM, Sony, Honda, Toyota, Applied Minds, VideoSurf, Zeitera...

La librería tiene más de 2500 algoritmos, que incluye algoritmos de machine learning y de visión artificial para usar.

Estos algoritmos permiten identificar objetos, caras, clasificar acciones humanas en vídeo, hacer tracking de movimientos de objetos, extraer modelos 3D, encontrar imágenes similares, eliminar ojos rojos, seguir el movimiento de los ojos, reconocer escenarios, etc.

Se usa en aplicaciones como la detección de intrusos en vídeos, monitorización de equipamientos, ayuda a navegación de robots, inspeccionar etiquetas en productos, etc. [12]

III. ESTADO DEL ARTE

Otros autores han intentado detectar tapabocas en imágenes para prevención del COVID. Por ejemplo, en el trabajo presentado por Said Y. [13], que fue basado en una red neuronal convolucional (CNN) liviana y el marco de detección de objetos YOLO Uno de los mejores algoritmos para procesar imágenes en tiempo real se llama YOLO. YOLO viene de «You Only Look Once», o sólo se mira una vez. [14] para implementarlo en un dispositivo integrado de baja potencia.

El marco de detección de objetos se diseñó utilizando una única red neuronal convolucional para la detección de objetos en tiempo real. En el desarrollo proponen construir una red neuronal convolucional ligera y cuantificar mediante la utilización de un solo bit para peso y 2 bits para activaciones. La red propuesta llamada Pynq-YOLO-Net se implementó en la plataforma Pynq Z1. El cálculo se dividió entre el software y hardware. La parte de extracción de características se ejecutó en el dispositivo de hardware y la parte de salida se ejecutó en el software. Esta configuración ha permitido alcanzar el procesamiento en tiempo real con una muy buena precisión de detección del 97% cuando se prueba en la combinación de conjuntos de datos recopilados.

Jiang et.al. [15] propusieron un conjunto de datos de detección de rostro enmascarado, que incluía 9205 imágenes de muestras de uso de máscara con tres categorías. Además, propusieron Squeeze and Excitation (SE) -YOLOv3, un detector de máscara con efectividad y eficiencia relativamente equilibradas en el cual se Integraron mecanismos de atención introduciendo el bloque SE en Darknet53, una red neuronal convolucional que actúa como columna vertebral del enfoque de detección de objetos YOLOv3 que cuenta con mejoras sobre su modelo anterior Darknet-19, incluyendo el uso de conexiones residuales, así como la aparición de más capas.[16] Los autores adoptaron GIoUloss, que tiene la capacidad de describir mejor la

diferencia espacial entre los cuadros para mejorar la estabilidad de la regresión del cuadro delimitador. Utilizaron La pérdida focal para resolver el desequilibrio de las clases entre el primer plano y el fondo.

Los resultados experimentales mostraron que SE-YOLOv3 al evaluarse obtuvo 62.8 mAP que superó a YOLO 3 y detectores de última generación en PWMFD y logró un 8,6% más alto de mAP, en comparación con YOLOv3 que al evaluarse en su última versión alcanzó 57.9 mAP. [17]

mAP (mean Average Precision) en español media de precisión, que es la métrica utilizada para medir la precisión de detectores de objetos como Faster R-CNN, SSD, entre otros. [18].

El autor Jiang, X., Xiang, especifica que es de gran valor resolver el problema de detección de objeto multi-área de máscara sin usar de forma correcta, se implementó un YOLOv 3 Slim de red basado en YOLOv 3. Es más rápido que YOLOv3 puesto que la velocidad de detección aumento de 15,67 fps a 16,89 fps. mientras tanto el error de la clase interna reduce la precisión del modelo y hace que el mecanismo de detección sea eficaz. Así que después de cambiar las etiquetas del tercer conjunto de datos se añadieron al módulo ECA a la red, YOLOv 3 Slim que, aunque se compare con YOLOv4 es más preciso en el reconocimiento de acuerdo al conjunto de datos de ellos. El MAP aumento del 89,45% al 92,50% deduce en gran manera el margen de error de las otras versiones. [19]

IV. MATERIALES Y MÉTODOS

Este proyecto fue realizado con Python y OpenCV para implementar un detector de mascarilla, esta función detecta rostros humanos y luego aplica nuestro clasificador de mascarillas en los rostros de cada persona, en el cual los puntos de referencia faciales nos permiten inferir automáticamente a la ubicación de las estructuras faciales, los cuales nos permiten hacer puntos de referencia para construir un conjunto de datos de rostros con máscaras.

Para el entrenamiento de la red neuronal, este proyecto cuenta con un dataset de 1406 imágenes que se dividen en dos clases: 701 imágenes sin mascarilla, 705 imágenes con mascarilla. Las imágenes utilizadas fueron imágenes reales de rostros con y sin mascarilla

El conjunto de datos/ directorio contiene los datos del “Conjunto de datos de detección de máscara COVID-19”, en el cual se proporcionan tres ejemplos de imágenes para que este pueda probar el detector de máscara de imagen estática. Nuestra red neuronal convolucional utiliza una red pre-entrenada: MobileNetV2, entrenada en la base de datos de Imagenet y ajustada a nuestro dataset por medio del entrenamiento con unas capas adicionales. Para esto se utilizaron 3 Scripts de Python.

El primero es `train_mask_detector.py`: El cual acepta el conjunto de datos de entrada y ajusta el MobileNetV2 para crear nuestro `mask_detector.model`. Al mismo tiempo, se genera un gráfico del historial de entrenamiento que contiene la curva de precisión/perdida. MobileNetV2 es una mejora significativa sobre MobileNetV1 e impulsa el estado del arte para el reconocimiento visual móvil, incluida la clasificación, la detección de objetos y la segmentación semántica. MobileNetV2 se publica como parte de tensorflow-Slim Image Classification Library. MobileNetV2 también está disponible como módulos en TF-Hub, y los puntos de control preentrenados se pueden encontrar en github. [20, 21, 22, 23, 24]

MobileNetV2 se basa en las ideas de MobileNetV1, utilizando la convolución separable en profundidad como bloques de construcción eficientes.

Sin embargo, V2 introduce dos nuevas características a la arquitectura:

- 1) cuellos de botella lineales entre las capas
- 2) conexiones de acceso directo entre los cuellos de botella.

Segundo detect_mask_image.py: Este realiza la detección de máscaras usando imágenes estáticas.

Y por último detect_mask_video.py: el cual usa la transmisión de la cámara.

Para realizar el entrenamiento del clasificador se utiliza Keras y TensorFlow para que detecte automáticamente si una persona está usando una máscara o no. La red MobileNetV2 se encuentra disponible también como parte de Keras.

Para la detección del uso de mascarilla en tiempo real, este proyecto está utilizando herramientas de aprendizaje automático. El objetivo es que el programa detecte si una persona porta o no mascarilla. Esto lo hacemos utilizando Deep Learning, lo primero que se realiza es entrenar nuestro algoritmo y que este logre distinguir si lo que ve es una persona y después si porta mascarilla o no, esto se hace con imágenes y fotografías de personas con y sin mascarilla, luego de ver muchas veces las imágenes el sistema habrá capturado las características de estas.

Para hacer la prueba de este proyecto se escogieron 30 imágenes, 15 con tapabocas y 15 sin tapabocas.

V. RESULTADOS

Presentamos los resultados dados por el programa, donde se probaron imágenes de personas usando mascarilla y personas sin mascarillas.

Se evaluó un total de 30 imágenes (15 con mascarilla y 15 sin mascarilla) en las que se logra ver un porcentaje calificativo en la parte superior.



Figura 2. Prueba con mascarilla un solo individuo



Figura 3. Prueba con mascarilla 2 individuos



Figura 4. Prueba sin mascarilla un solo individuo



Figura 5. Prueba sin mascarilla 3 individuos

De las imágenes anteriores se seleccionaron 2 de cada grupo (con mascarilla/sin mascarilla) donde se muestra que para las imágenes de personas **usando mascarilla** se calcula un promedio de acierto del 100% y para las imágenes de personas **sin mascarillas** se calcula un promedio del 100%, es decir, para ambos grupos los promedios de aciertos presentan resultados iguales.

VI. CONCLUSIONES

Este proyecto fue elaborado para identificar personas utilizando o no mascarillas, y tiene como objetivo evitar de manera indirecta que se propague el contagio del virus mortal COVID-19, el cual tuvo inicio a finales del 2019 en china y que al día de hoy se encuentra en todo el mundo; Para revertir los daños que el virus género en la humanidad, con la ayuda de la tecnología se desarrolló este proyecto basándose en una de las normas de prevención impuestas a nivel mundial, como es el uso de la mascarilla o tapabocas en lugares públicos.

De este proyecto se tiene buenas expectativas y se espera un gran impacto a nivel general, puesto que su implementación tiene como objetivo facilitar a las autoridades y al personal de vigilancia a identificar aquellas personas que se encuentren en lugares públicos sin mascarilla o usándola de manera incorrecta, para que sean ellos quienes se encarguen de hacer el llamado de atención; De esta manera se busca hacer que las personas que se encuentren en lugares públicos sean más conscientes del uso de las mascarilla y por ende evitar la propagación y el contagio del virus.

I. REFERENCIAS

- [1] "La OMS caracteriza a COVID-19 como una pandemia - OPS/OMS | Organización Panamericana de la Salud", Paho.org, 2020. [Online]. Available: <https://www.paho.org/es/noticias/11-3-2020-oms-caracteriza-covid-19-como-pandemia> [Accessed: 06- Apr- 2021].
- [2] Abigail Orús (2021, Mar 20). Número de personas fallecidas a consecuencia del coronavirus a nivel mundial a fecha de 14 de marzo de 2021, por continente. [Online] Disponible: <https://es.statista.com/estadisticas/1107719/covid19-numero-de-muertes-a-nivel-mundial-por-region/>.
- [3] "OPS advierte sobre un repunte de COVID-19 en las Américas", Paho.org. [En línea]. Disponible en: <https://www.paho.org/es/noticias/23-3-2021-ops-advierete-sobre-repunte-covid-19-americas>. [Consultado: 28-sep-2021].
- [4] Semana.com Últimas Noticias de Colombia y el Mundo. 2021. Coronavirus en Colombia: MinSalud reportó 3.511 nuevos casos y 78 muertes este martes. [online] Available at: <https://www.semana.com/nacion/articulo/coronavirus-en-colombia-minsalud-reporto-3511-nuevos-casos-y-78-muertes-este-martes/202124/> [Accessed 8 March 2021].
- [5] Canal Comstor (2017, Dic 29) ¿Que es la visión computacional? [Online] Disponible: <https://blogmexico.comstor.com/que-es-la-vision-computacional>.
- [6] Oscar Garcia. (2019, Sep 16). Redes Neuronales artificiales: Qué son y cómo se entrenan [Online] Disponible: <https://www.xeridia.com/blog/redes-neuronales-artificiales-que-son-y-como-se-entrenan-parte-i>.

- [7] Damián M. (Mar 2001) Redes Neuronales: Conceptos Básicos y Aplicaciones. Recuperado de: https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograis/match-redesneuronales.pdf.
- [8] S. Silva y E. Feire (2019.Noviembre, 23), Intro a las Redes neuronales convolucionales.[Online] Disponible: <https://bootcampai.medium.com/redes-neuronales-convolucionales-5e0ce960caf8>.
- [9] C. Camacho, "Convolutional Neural Networks", Cezannec.github.io, 2018. [Online]. Available: https://cezannec.github.io/Convolutional_Neural_Networks/. [Accessed: 06- Apr- 2021].
- [10] D. Calvo, "Backpropagation – Redes neuronales", Diegocalvo.es, 2018. [Online]. Available: <https://www.diegocalvo.es/backpropagation-redes-neuronales/>. [Accessed: 06- Apr- 2021].
- [11] E. Blanco, "¿Cómo funciona el algoritmo Backpropagation en una Red Neuronal? - Think Big Empresas", Think Big, 2019. [Online]. Available: <https://empresas.blogthinkbig.com/como-funciona-el-algoritmo-backpropagation-en-una-red-neuronal/>. [Accessed: 06- Apr- 2021]
- [12] Gracia, L. (2013, 9 octubre). ¿Qué es OpenCV? Un poco de Java. <https://unpocodejava.com/2013/10/09/que-es-opencv/>
- [13] Said, Y.
Pynq-YOLO-Net: An embedded quantized convolutional neural network for face mask detection in COVID-19 pandemic era (2020).
- [14] 330 ohms (2020, Nov 17). ¿Cómo detectar objetos con YOLO? [Online]. Recuperado de: <https://blog.330ohms.com/2020/11/17/deteccion-de-objetos-con-yolo/#:~:text=El%20algoritmo%20YOLO&text=Uno%20de%20los%20mejores%20algoritmos,una%20rect%C3%A1ngulo%20el%20objeto%20detectado.>
- [15] Jiang, X., Gao, T., Zhu, Z., Zhao, Y.
Real-time face mask detection method based on yolov3 (2021).
- [16] Paper with code (2018, Abr 08). Darknet-53 [Online] Disponible: <https://paperswithcode.com/method/darknet-53>.
- [17] Jonathan Hui (2018, Mar 06) mAP (mean Average Precision) for Object Detection [Online] Disponible: <https://jonathan-hui.medium.com/map-mean-average-precision-for-object-detection-45c121a31173>

- [18] pjreddie (2018) YOLO: Real-Time Object Detection [Online] Disponible: <https://pjreddie.com/darknet/yolo/>.
- [19] Jiang, X., Xiang, F., Lv, M., Wang, W., Zhang, Z., Yu, Y. YOLOv3-Slim for Face Mask Recognition (2021) <https://iopscience.iop.org/article/10.1088/1742-6596/1771/1/012002>.
- [20] J. A. Calderón Velasco, G. A. Amarillo Cárdenas, L. A. Silva Bahamon, y C. G. Donoso Albarracín, "Biometría dactilar: una nueva alternativa de controlar efectivamente la asistencia a clases", *Investigación e Innovación en Ingenierías*, vol. 6, n.º 1, pp. 27 - 39, 2018. DOI: <https://doi.org/10.17081/invinno.6.1.2773>
- [21] D. Heredia Acevedo, Y. F. Ceballos, y G. Sanchez Torres, "Modelo de simulación de eventos discretos para el análisis y mejora del proceso de atención al cliente", *Investigación e Innovación en Ingenierías*, vol. 8, n.º 2, pp. 44-61, 2020. DOI: <https://doi.org/10.17081/invinno.8.2.3639>
- [22] Sarrazín, J. P. (2018). La categoría indígena definida desde la hegemonía y sus alcances en la institucionalidad colombiana. *Justicia*, 22(32), 140–160. <https://doi.org/10.17081/just.22.32.3037>
- [23] I. Chaverra Mendoza, "Utilidad de los métodos inmunológicos y moleculares para el diagnóstico del virus Chikungunya", *Ciencia e Innovación en Salud*, vol. 4, núm. 1 de diciembre de 2017.
- [24] MobileNetV2: The Next Generation of On-Device Computer Vision Networks. (2018, 3 abril). Google AI Blog. <https://ai.googleblog.com/2018/04/mobilenetv2-next-generation-ofon.html>.