



ANEXO 1

FORMATO PARA LA PRESENTACIÓN DE PROYECTOS DE INVESTIGACIÓN CON EL FINANCIAMIENTO DEL FEDU

1. Título del proyecto

**DETECCIÓN DEL USO DE MASCARILLAS FACIALES FRENTE AL COVID-19
MEDIANTE MODELOS DE APRENDIZAJE DE TRANSFERENCIA PREENTRENADOS
BASADOS EN TÉCNICAS DE APRENDIZAJE PROFUNDO**

2. Área de Investigación

Área de investigación	Línea de Investigación	Disciplina OCDE
Computación Gráfica y Visión Computacional	Sistemas, Computación e Informática	Ciencias de la Computación

3. Duración del proyecto (meses)

12

4. Tipo de proyecto

Individual	<input checked="" type="radio"/>
Multidisciplinario	<input type="radio"/>
Director de tesis pregrado	<input type="radio"/>

4. Datos de los integrantes del proyecto

Apellidos y Nombres	HUAYTA FLORES LENIN
Escuela Profesional	INGENIERÍA DE SISTEMAS
Celular	951462575
Correo Electrónico	lhuayta@unap.edu.pe

I. Título

**DETECCIÓN DEL USO DE MASCARILLAS FACIALES FRENTE AL COVID-19
MEDIANTE MODELOS DE APRENDIZAJE DE TRANSFERENCIA PREENTRENADOS
BASADOS EN TÉCNICAS DE APRENDIZAJE PROFUNDO**

II. Resumen del Proyecto de Tesis

La propagación del COVID-19 a nivel mundial alcanzó un nivel extremadamente alto, utilizar mascarillas es uno de los métodos de bioseguridad sugerido por la Organización Mundial de la Salud; el objetivo de la presente investigación es evaluar técnicas de aprendizaje profundo en la detección del uso de mascarillas frente al Covid-19 mediante modelos de aprendizaje de transferencia preentrenados basados en técnicas de aprendizaje profundo; la población del estudio serán imágenes de 3 clases (mascarilla incorrecta, con mascarilla y sin mascarilla), el 80% de las imágenes serán para el entrenamiento y el 20% para



las pruebas; las técnicas utilizadas serán las Redes Neuronales Convolucionales; respecto a la metodología, se utilizará un dataset de imágenes de personas con mascarilla incorrecta, con mascarilla y sin mascarilla de elaboración propia y se implementarán los algoritmos AlexNet, VGG11-BN, SqueezeNet, DenseNet e Inceptionv3, y se evaluará en Google Collaborate con GPU; bajo las mismas condiciones y métricas; el tipo de investigación es aplicada, con un nivel de investigación explicativa, siendo el diseño de la investigación de tipo experimental; se pretende llegar a la conclusión de que la arquitectura entrenada con mejor resultado en la detección de personas con mascarilla incorrecta, con mascarilla y sin mascarilla será un algoritmo con una *accuracy* (exactitud) bastante alta y una *loss* (pérdida) bastante baja, y se esperará a que nuestro estudio ayude a reducir la propagación del SARS-CoV-2 y sus variantes.

III. Palabras claves (Keywords)

COVID-19, dataset mask, detección del uso de mascarillas, SARS-CoV-2, técnicas de aprendizaje profundo, transfer learning.

IV. Justificación del proyecto

El CoronaVirus Disease 19, es una enfermedad infecciosa causada por el virus SARS-CoV-2, perteneciente a la familia de los coronavirus, los ciudadanos de Wuhan, Hubei, China, a fines de 2019, fueron los primeros en enfrentar el nuevo virus, que resultó en una pandemia en curso. Al 12 de enero de 2022, se habían reportado más de 320 millones de casos y más de 5.52 millones de muertes en todo el mundo.

Estudios recientes sobre coronavirus demuestran que el uso de mascarilla por parte de una población sana e infectada reduce considerablemente la transmisión del COVID-19 y sus distintas variantes.

Es necesario el uso de algoritmos de visión por computadora que controlen el uso de mascarillas en la población esto debido a que las mascarillas evitan el contacto con el virus y es inevitable su uso, para lo cual en el estudio se propone entrenar modelos de aprendizaje de transferencia preentrenados basados en técnicas de aprendizaje profundo y así determinar el mejor modelo de detección del uso de mascarillas frente al covid-19 en la población.

El artículo científico utilizará un dataset obtenidos en la población de la ciudad Puno con 3 clases de imágenes sobre personas con mascarilla de uso incorrecto, con mascarilla y sin mascarilla; además, se implementaran en el marco de trabajo Pytorch algoritmos de técnicas de Redes Neuronales Convolucionales Profundas (DCNN), que posteriormente se evaluarán en Google Collaborate, usando el run-time system GPU, bajo las mismas condiciones y métricas, se tomará de los modelos entrenados la mejor *accuracy* (exactitud) y la menor *loss* (pérdida) en el entrenamiento.

Se espera que el estudio sea un aporte que coadyuve a la mitigación de la propagación del SARS-CoV-2 y sus distintas variantes en escuelas, hospitales, bancos, aeropuertos, etc. como una herramienta de escaneo digitalizado.

V. Antecedentes del proyecto

(Koklu *et al.*, 2022) Se plantean como objetivo determinar si las personas usan la máscara facial correctamente mediante el uso de métodos de aprendizaje profundo, con tal fin crean un dataset que consta de 2000 imágenes, en el dataset recopilan imágenes de una persona desde tres ángulos diferentes en cuatro clases, que son "enmascarada", "no enmascarada", "enmascarada pero con la nariz abierta" y "enmascarada pero debajo de la barbilla", utilizando estos



datos, se proponen nuevos modelos transfiriendo el aprendizaje a través de AlexNet y VGG16, que son las arquitecturas de redes neuronales convolucionales, eliminan las capas de clasificación de estos modelos y, en su lugar, agregan arquitecturas de memoria a largo y corto plazo y memoria bidireccional a largo y corto plazo, el modelo TrVGG16 + BiLSTM ha logrado la mayor precisión de clasificación con una accuracy de 95.67%.

(Carrera *et al.*, 2021) Desarrollan un modelo de CNN utilizando Tensorflow basado en MobileNetV2, que permiten la detección de mascarillas en tiempo real, Prueban el modelo utilizando OpenCV y una red neuronal preentrenada para la detección de rostros. Analizan las métricas del desempeño de la red neuronal como son: precisión, exactitud (accuracy), exhaustividad (recall) y el valor F1 en función del número de iteraciones para el entrenamiento del modelo, obteniendo como resultado un modelo que establece tres clasificaciones: rostros sin mascarilla, rostros con mascarilla mal colocada y rostros con mascarilla colocada correctamente. Sus resultados presentan valores de precisión, exhaustividad y F1 superiores al 85% y la exactitud que oscila entre el 93% para 5 iteraciones y 95% para 25 iteraciones.

(Dey *et al.*, 2021) En su artículo, proponen MobileNetMask, que es un modelo de detección de máscara facial multifase basado en aprendizaje profundo para prevenir la transmisión humana del SARS-CoV-2. Utilizan dos datasets de máscaras faciales diferentes junto con más de 5200 imágenes para entrenar y probar el modelo para detectar con y sin máscara facial de las imágenes y la transmisión de video. Los resultados del experimento muestran que, con 770 muestras de validación, MobileNet Mask logra una exactitud (accuracy) de ~93%, mientras que con 276 muestras de validación alcanza una exactitud (accuracy) de casi ~100%. Por último, también discutimos la posibilidad de implementar nuestro modelo MobileNetMask propuesto en dispositivos informáticos livianos, como dispositivos móviles o integrados.

(Loey *et al.*, 2021) Proponen un modelo que consta de dos componentes, el primer componente está diseñado para el proceso de extracción de características basado en el modelo de aprendizaje de transferencia profunda ResNet-50, mientras que el segundo componente está diseñado para la detección de mascarillas médicas basadas en YOLO v2. Combinan dos datasets de mascarillas médicas en un conjunto de datos para ser investigados a través de esta investigación. Para mejorar el proceso de detección de objetos, se ha utilizado IoU promedio para estimar el mejor número de cajas de anclaje, concluyen que el optimizador adam logró el porcentaje de precisión promedio más alto del 81% como detector.

(Nagrath *et al.*, 2021) Implementan una técnica y obtienen una exactitud (accuracy) de 92.64% y una F1 score de 0.93. El dataset lo recopilan de varias fuentes e indican que puede ser utilizado por otros investigadores para otros modelos avanzados, como los de reconocimiento facial, puntos de referencia faciales y proceso de detección de partes faciales.

(Razavi *et al.*, 2021) Entrenan y prueban varios modelos de detección de objetos, utilizando Tensorflow en el dataset de la máscara facial y eligen la red Faster R-CNN Inception ResNet V2 que obtiene una exactitud (accuracy) del 99.8 %.

(Basha *et al.*, 2021) Se proponen desarrollar un detector de mascarillas con OpenCV, PyTorch y Deep Learning que ayude a detectar si una persona lleva o no mascarilla, utilizan un modelo de red neuronal llamado ResNet se entrena en el dataset, y predicen si una persona está usando o no una máscara junto con el porcentaje de la cara cubierta o descubierta, e indican también que los resultados



de la validación tienen una precisión del 97% en comparación con la aplicación de diferentes algoritmos, además, concluyen que el sistema de detección de mascarillas resultó ser apto para detectar si las personas usan o no mascarillas en lugares públicos que contribuyen a su salud y también a la salud de sus contactos en esta pandemia de COVID-19.

(Soto-Paredes & Sulla-Torres, 2021) Recopilan un dataset de 660 personas de ambos sexos, con edades comprendidas entre los 18 y los 86 años, eligen el modelo clásico de transferencia de aprendizaje ResNet-18; las capas variacionales del modelo propuesto lo construyeron con la plantilla Basic Entangler Layers para cuatro qubits, y la optimización del entrenamiento lo realizan con el Stochastic Gradient Descent con Nesterov Momentum, llegan a obtener una accuracy de 99.05% en la clasificación de las Mascarillas Protectoras correctas utilizando el simulador cuántico Pennylane en las pruebas realizadas, y llegan a la conclusión de que el modelo híbrido propuesto es una excelente opción para detectar la posición correcta de la máscara protectora para el COVID-19.

(Ornek *et al.*, 2021) Seleccionan ResNet-18 como modelo de red neuronal profunda y es entrenado con un dataset de 18600 imágenes faciales equilibradas pertenecientes a dos clases y prueban con 4540 imágenes faciales diferentes de las imágenes de entrenamiento, obtienen una sensibilidad del 95.16%, una especificidad del 96.69% y una accuracy del 96.58%, además, mencionan que se ve claramente que el modelo aprende la estructura de la cara para las imágenes sin máscara y la estructura de la máscara para las imágenes con máscara.

(Bhargavi *et al.*, 2021) Proponen un enfoque novedoso que no solo clasifica a las personas con mascarilla y sin mascarilla, sino que también identifica si una mascarilla está debidamente cubierta o no. Por lo tanto, en este artículo se propone el uso de R-CNN cuyo resultado es lograr una accuracy de hasta 0.93.

(Sethi *et al.*, 2021) Realizan un experimento con tres modelos de referencia ResNet50, AlexNet y MobileNet, y observan que la técnica propuesta logra una accuracy de 98.2% cuando se implementa con ResNet50, e indican que, el modelo propuesto genera un 11.07% y un 6.44% más de accuracy y recuperación en la detección de máscaras en comparación con el modelo de referencia RetinaFaceMask, y también precisan que el excelente rendimiento del modelo propuesto es muy adecuado para dispositivos de videovigilancia.

(Harahap *et al.*, 2021) En su estudio proponen la detección automática de máscaras con YOLOv4 con la etapa de recolección de datos registrando actividades comunitarias en lugares concurridos, etiquetando imágenes de máscaras y no máscaras. Los resultados del etiquetado se realizaron en un entrenamiento que dio como resultado una accuracy del 90.3%, el último de los cuales fue una prueba de video en tres lugares de multitud diferentes: impuestos, parques de la ciudad y carreteras, precisan también que sin embargo para la detección de personas con la posición incorrecta del uso de máscaras no ha resultado una buena detección.

(Yu & Zhang, 2021) Basado en el algoritmo de detección de objetos de aprendizaje profundo comparan una variedad de índices de evaluación para evaluar la efectividad del modelo, los resultados de las comparaciones muestran que el mAP del reconocimiento de máscaras faciales puede alcanzar el 98.3% y la velocidad de fotogramas es alta a 54.57 FPS.

(Rahman *et al.*, 2020) Proponen un sistema que restringe el crecimiento de COVID-19 al detectar personas que no usan máscara facial en una red de ciudad



inteligente donde todos los lugares públicos están monitoreados con cámaras de circuito cerrado de televisión (CCTV). La arquitectura entrenada logró una exactitud (accuracy) del 98.7% en la distinción de personas con y sin máscara facial, e indican que esperan que su estudio sea una herramienta útil para reducir la propagación de esta enfermedad transmisible en muchos países del mundo.

(Sandesara *et al.*, 2020) Proponen un modelo con una pila de capas convolucionales 2D con activaciones relu así como Max Pooling e implementan este modelo usando Gradient Descent para entrenamiento y entropía cruzada binaria como una función de pérdida. Entrenan dos datasets que son RMFD (conjunto de datos de rostros enmascarados del mundo real) y Kaggle. En general, logramos una exactitud (accuracy) de validación/prueba del 95% y una exactitud (accuracy) de entrenamiento del 97%.

(Das *et al.*, 2020) Utilizan paquetes básicos de aprendizaje automático como TensorFlow, Keras, OpenCV y Scikit-Learn. El método propuesto detecta la cara de la imagen correctamente y luego identifica si tiene una máscara o no. Como ejecutante de tareas de vigilancia, también puede detectar una cara junto con una máscara en movimiento. El método alcanza una exactitud (accuracy) de hasta el 95.77% y el 94.58%, respectivamente, en dos datasets diferentes. Exploran valores optimizados de parámetros utilizando el modelo de red neuronal convolucional secuencial para detectar la presencia de máscaras correctamente sin causar un ajuste excesivo.

(Draughon *et al.*, 2020) Precisan que, al asociar las máscaras faciales detectadas con las personas rastreadas, se puede estimar el uso general de máscaras faciales. El marco se implementa en varias cámaras de vigilancia a lo largo de Detroit RiverWalk, un parque peatonal de 5 kilómetros que conecta varias vías verdes, plazas, pabellones y espacios verdes abiertos a lo largo del río Detroit en Detroit, Michigan. Se muestra que la detección de los tipos de usuarios del parque tiene una precisión promedio del 89 % y superior para la mayoría de las clases de personas, y el detector de máscara tiene una precisión del 96 %. Una aplicación web interactiva visualiza los datos y los administradores del parque la utilizan para informar las decisiones de gestión y evaluar las estrategias utilizadas para aumentar las tasas de uso de mascarillas.

(Guillermo *et al.*, 2020) Analizan exhaustivamente un sistema basado en una red neuronal artificial capaz de detectar si las personas en la multitud usan máscaras faciales. La implementación del estudio resultó en un 99% en todos los parámetros clave de entrenamiento y prueba.

(Li *et al.*, 2020) Precisan que el método HGL propuesto combina el canal H del espacio de color HSV con el retrato facial y la imagen en escala de grises, y entrena a la CNN para extraer características para la clasificación. La evaluación del conjunto de datos MAFA muestra que, en comparación con los algoritmos basados en la detección de puntos de referencia faciales y la red neuronal convolucional, el método propuesto ha logrado un mejor rendimiento (exactitud o accuracy frontal: 93,64 %, exactitud o accuracy lateral: 87.17 %).

(Lubis, 2020) Menciona que las redes neuronales convolucionales (CNN) se han establecido como una poderosa clase de modelos para problemas de reconocimiento de imágenes. Nuestro intento ha alcanzado un nivel de confianza del 99.4 % en el aprendizaje automático sobre alrededor de 90000 objetos de imagen de un conjunto de datos. Y el rendimiento del hardware es considerablemente rápido con el uso de una máquina de 8 GPU para lograr 78 clips por segundo y poder completar una época en 30 segundos por época y lograr el nivel de confianza usando un escenario de diez y veinte épocas.



(Nagoriya & Parekh, 2020) Crean un dataset que consta de 18236 imágenes de personas con máscara y sin máscara, establecen 101 capas de profundidad, y entrenan la red neuronal convolucional ResNet-101, la detección de máscaras logra una tasa de exactitud (accuracy) del 96.02 %.

(Harani *et al.*, 2019) Utilizan para la detección de objetos el Single Shot Detector (SSD) debido a su buen desempeño, accuracy y alta velocidad. Utilizan transferencia de aprendizaje en redes neuronales para finalmente generar la presencia o ausencia de una máscara facial en una imagen o transmisión de video. Los resultados experimentales muestran que nuestro modelo funciona bien en los datos de prueba con un 100 % y un 99 % de precisión y recuperación, respectivamente.

VI. Hipótesis del trabajo

El modelo de aprendizaje de transferencia preentrenado basado en la técnica de aprendizaje profundo *IncepciónV3* obtiene mejores resultados que *AlexNet*, *VGG11-BN*, *SqueezeNet* y *DenseNet* en la detección del uso de mascarillas faciales en personas frente al COVID-19.

VII. Objetivo general

- Determinar qué modelo de aprendizaje de transferencia preentrenado basado en técnicas de aprendizaje profundo obtiene mejores resultados en la detección del uso de mascarillas faciales en personas frente al COVID-19.

VIII. Objetivos específicos

- Construir un dataset significativo de imágenes de personas con mascarilla incorrecta, con mascarilla y sin mascarilla que permitan la construcción de modelos de clasificación del uso de mascarillas faciales en personas frente al COVID-19.
- Obtener el mejor modelo de aprendizaje de transferencia preentrenado basado en técnicas de aprendizaje profundo bajo las mismas condiciones y métricas de evaluación en la tarea de detección del uso de mascarillas faciales en personas frente al COVID-19.

IX. Metodología de investigación

9.1. Lugar de Estudio.

La recopilación del dataset se realizará en la región Puno, respecto a la construcción, entrenamiento y evaluación de los modelos bajo las mismas condiciones y métricas será trabajo de laboratorio.

9.2. Población y tamaño de muestra.

La población estará constituida por 3 clases a saber mascarilla incorrecta, con mascarilla y sin mascarilla, con 2079 imágenes, de los cuales el 80% se utilizará para el entrenamiento, y el 20% para la validación.

7.3. Descripción detallada de los métodos, uso de materiales, equipos o insumos.



Metodología del Objetivo Específico 1: Construir un dataset significativo de imágenes de personas con mascarilla incorrecta, con mascarilla y sin mascarilla que permitan la construcción de modelos de clasificación del uso de mascarillas faciales en personas frente al COVID-19.

a) Diseño de muestreo

No corresponde.

b) Descripción detallada del uso de materiales, equipos, insumos, entre otros

Laptop, SmartPhone, cámara digital, OpenCV, Python, Microsoft Windows Anaconda, Google Collaborate.

c) Descripción de variables a ser analizados en el objetivo específico

VI: Construir un dataset significativo de imágenes de rostros de personas con mascarilla incorrecta, con mascarilla y sin mascarilla

VD: Permitan la construcción de modelos de clasificación del uso de mascarillas faciales en personas frente al COVID-19.

d) Aplicación de prueba estadística inferencial

Se utilizarán el dataset a crear que constará de 3 clases (2079 imágenes) mascarilla incorrecta, con mascarilla y sin mascarilla; se redimensionaran las imágenes, y se guardaran en una estructura de árbol de carpetas, tanto para el entrenamiento (80% de las imágenes) y la validación (20% de las imágenes).

Metodología del Objetivo Específico 2: Obtener el mejor modelo de aprendizaje de transferencia preentrenado basado en técnicas de aprendizaje profundo bajo las mismas condiciones y métricas de evaluación en la tarea de detección del uso de mascarillas faciales en personas frente al COVID-19.

a) Diseño de muestreo

No corresponde.

b) Descripción detallada del uso de materiales, equipos, insumos, entre otros

Dataset de mascarilla incorrecta, con mascarilla y sin mascarilla.

c) Descripción de variables a ser analizados en el objetivo específico

VI: Modelo de aprendizaje de transferencia preentrenado basado en técnicas de aprendizaje profundo

VD: Detección del uso de mascarillas faciales en personas frente al COVID-19.

d) Aplicación de prueba estadística inferencial

Para evaluar la eficiencia relativa de los diferentes modelos de segmentación y clasificación, utilizaremos *Machine Learning* y la métrica a utilizar será accuracy.

$$\text{Accuracy (Exactitud)} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN})$$

TP: Verdaderos Positivos

TN: Verdaderos Negativos

FP: Falsos Positivos

FN: Falsos Negativos

Se determinará mediante la métrica accuracy la arquitectura entrenada con mejor resultado en la detección de personas con mascarilla incorrecta, con mascarilla y sin mascarilla será un modelo con una accuracy (exactitud) bastante alta y una loss (pérdida) bastante baja.

X. Referencias



- Basha, C., Pravallika, B. N., & Shankar, E. B. (2021). An Efficient Face Mask Detector with PyTorch and Deep Learning. *EAI Endorsed Transactions on Pervasive Health and Technology*, 7(25), e4.
- Bhargavi, C. V, Mani, G., Cherukuri, N., Prasad, C., Krishna, A., & Basha, C. Z. (2021). A Novel Framework for Facemask Detection Using R-Convolution Neural Network. *2021 Third International Conference on Inventive Research in Computing Applications (ICIRCA)*, 958–962.
- Carrera, H. A., Maita, S. S., & Lascano, P. H. (2021). Modelo para detectar el uso correcto de mascarillas en tiempo real utilizando redes neuronales convolucionales. *Revista de Investigación En Tecnologías de La Información: RITI*, 9(17), 111–120.
- Das, A., Ansari, M. W., & Basak, R. (2020). Covid-19 Face Mask Detection Using TensorFlow, Keras and OpenCV. *2020 IEEE 17th India Council International Conference (INDICON)*, 1–5.
- Dey, S. K., Howlader, A., & Deb, C. (2021). MobileNet Mask: A Multi-phase Face Mask Detection Model to Prevent Person-To-Person Transmission of SARS-CoV-2. *Proceedings of International Conference on Trends in Computational and Cognitive Engineering*, 603–613.
- Draughon, G. T. S., Sun, P., & Lynch, J. P. (2020). Implementation of a Computer Vision Framework for Tracking and Visualizing Face Mask Usage in Urban Environments. *2020 IEEE International Smart Cities Conference (ISC2)*, 1–8.
- Guillermo, M., Pascua, A. R. A., Billones, R. K., Sybingco, E., Fillone, A., & Dadios, E. (2020). *COVID-19 Risk Assessment through Multiple Face Mask Detection using MobileNetV2 DNN*.
- Harahap, M., Kusuma, L., Suryani, M., Situmeang, C. E., & Purba, J. F. (2021). Identification of Face Mask With YOLOv4 Based on Outdoor Video. *Sinkron: Jurnal Dan Penelitian Teknik Informatika*, 6(1), 127–134.
- Harani, N. H., Prianto, C., & Hasanah, M. (2019). Deteksi Objek Dan Pengenalan Karakter Plat Nomor Kendaraan Indonesia Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Python. *Jurnal Teknik Informatika*, 11(3), 47–53. https://doi.org/10.1007/978-3-030-49336-3_11
- Koklu, M., Cinar, I., & Taspinar, Y. S. (2022). CNN-based bi-directional and directional long-short term memory network for determination of face mask. *Biomedical Signal Processing and Control*, 71, 103216.
- Li, S., Ning, X., Yu, L., Zhang, L., Dong, X., Shi, Y., & He, W. (2020). Multi-angle Head Pose Classification when Wearing the Mask for Face Recognition under the COVID-19 Coronavirus Epidemic. *2020 International Conference on High Performance Big Data and Intelligent Systems (HPBD&IS)*, 1–5. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9130585>
- Loey, M., Manogaran, G., Taha, M. H. N., & Khalifa, N. E. M. (2021). Fighting against COVID-19: A novel deep learning model based on YOLO-v2 with ResNet-50 for medical face mask detection. *Sustainable Cities and Society*, 65, 102600.
- Lubis, R. (2020). *Machine Learning (Convolutional Neural Networks) for Face Mask Detection in Image and Video*.
- Nagoriya, H., & Parekh, M. (2020). *Live Facemask Detection System*. https://www.researchgate.net/profile/Harsh_Nagoriya/publication/347945595_Live_Facemask_Detection_System/links/5fe97578299bf14088505224/Live-Facemask-Detection-System.pdf
- Nagrath, P., Jain, R., Madan, A., Arora, R., Kataria, P., & Hemanth, J. (2021). SSDMNV2: A real time DNN-based face mask detection system using single shot multibox detector and MobileNetV2. *Sustainable Cities and Society*, 66, 102692.
- Ornek, A. H., Celik, M., Center, H. T. R., & Ceylan, M. (2021). *Explainable Artificial Intelligence: How Face Masks are Detected via Deep Neural Networks*.
- Rahman, M. M., Manik, M. M. H., Islam, M. M., Mahmud, S., & Kim, J.-H. (2020). An Automated System to Limit COVID-19 Using Facial Mask Detection in Smart City



- Network. *2020 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)*, 1–5.
- Razavi, M., Alikhani, H., Janfaza, V., Sadeghi, B., & Alikhani, E. (2021). An Automatic System to Monitor the Physical Distance and Face Mask Wearing of Construction Workers in COVID-19 Pandemic. *ArXiv Preprint ArXiv:2101.01373*.
- Sandesara, A. G., Joshi, D. D., & Joshi, S. D. (2020). *Facial Mask Detection Using Stacked CNN Model*.
- Sethi, S., Kathuria, M., & Kaushik, T. (2021). Face mask detection using deep learning: An approach to reduce risk of Coronavirus spread. *Journal of Biomedical Informatics*, 120, 103848.
- Soto-Paredes, C., & Sulla-Torres, J. (2021). *Hybrid Model of Quantum Transfer Learning to Classify Face Images with a COVID-19 Mask*.
- Yu, J., & Zhang, W. (2021). Face mask wearing detection algorithm based on improved YOLO-v4. *Sensors*, 21(9), 3263.

XI. Uso de los resultados y contribuciones del proyecto

El modelo con accuracy más alto puede ser utilizado en la detección de personas con mascarilla incorrecta, con mascarilla y sin mascarilla, mediante las cámaras de video vigilancia, y se esperará a que nuestro estudio ayude a reducir la propagación del SARS-CoV-2 y sus variantes, además, servirá como base para estudios a futuro en el área.

XII. Impactos esperados

i. Impactos en Ciencia y Tecnología

Los nuevos avances tecnológicos sustentarán la innovación, es debido a eso que se utilizará creará un dataset de imágenes de personas con mascarilla incorrecta, con mascarilla y sin mascarilla y se implementarán los algoritmos AlexNet, VGG11-BN, SqueezeNet, DenseNet e Inceptionv3 adaptados al proyecto y se evaluará en Google Collaborate con tecnología GPU, así automatizar la detección del uso de mascarillas faciales frente al COVID-19, dando un aporte en la prevención de la propagación de la misma y sus variantes.

ii. Impactos económicos

Se presenta un impacto económico favorable a la población en general, promoviendo la prevención de contagios del COVID-19, se reduce considerablemente los gastos en salud por parte del estado y de la población.

iii. Impactos sociales

El desarrollo de este proyecto se pretende concientizar a la población respecto al uso de mascarillas frente a la COVID-19 y sus variantes.

iv. Impactos ambientales

Se presenta un impacto ambiental favorable pues con el futuro control de la propagación del COVID-19 y sus variantes, se reduce considerablemente daños ambientales en el uso de medicinas y fármacos.

XIII. Recursos necesarios



Infraestructura

- Laboratorio de Cómputo del Instituto de Informática de la UNA Puno

Software

- MS Windows 11
- Microsoft Office 2019
- Python
- Google Collaborate
- OpenCV
- Pytorch

Hardware

- Computadoras (Core i7)
- Laptop (Core i7)
- Impresora

XIV. Localización del proyecto

La creación del dataset con imágenes de la población de Puno y el trabajo de gabinete será en el Jr. Acora N° 235, 2do. piso, barrio Laykakota – Puno, Instituto de Informática de la UNA Puno.

XV. Cronograma de actividades

Actividad	Meses 2022											
	E	F	M	A	M	J	J	A	S	O	N	D
Proyecto de Investigación												
Antecedentes y Marco Teórico												
Recolección de datos (imágenes)												
Preprocesamiento de imágenes												
Programación de técnicas de Deep Learning												
Transfer Learning, Entrenamiento, Validación y Creación de Modelos.												
Resultados y Discusión.												
Presentación												

XVI. Presupuesto

Descripción	Unidad de medida	Precio Unitario (S/.)	Cantidad	Precio Sub Total
1. PERSONAL				
RECURSOS HUMANOS				
Recolección de Datos	Unid.	S/ 0.50	2097	S/ 1,048.50
Programador	Unid.	S/ 1,000.00	1	S/ 1,000.00
				S/ 2,048.50
2. MATERIALES Y EQUIPOS				
MATERIALES DE ESCRITORIO				
Papel Bond A4 de 80 gr.	Millar	S/ 34.00	2	S/ 68.00
Lapicero	Unid.	S/ 1.50	15	S/ 22.50
1 Tera	Unid.	S/ 250.00	1	S/ 250.00
PostIt	Unid.	S/ 1.50	1	S/ 1.50
Tinta para Impresora	Unid.	S/ 50.00	4	S/ 200.00
Router/Modem	Unid.	S/ 120.00	1	S/ 120.00



Cable de Red	Metro	S/ 7.00	10	S/ 70.00
MATERIAL BIBLIOGRÁFICO				
Textos Especializados	Unid.	S/ 230.00	2	S/ 460.00
RECURSOS HARDWARE				
Ordenador Portátil HP Core i7	Unid.	S/ 4,000.00	1	S/ 4,000.00
Impresora a chorro de tinta	Unid.	S/ 750.00	1	S/ 750.00
Computadoras Laboratorio de Computo del Instituto de Informática	Unid.	S/ -	5	S/ -
RECURSOS SOFTWARE (Licencia)				
MS Windows 11 (Incl. Laptop)	Unid.	S/ -	1	S/ -
Python, Google Collaborate	Unid.	S/ -	1	S/ -
OpenCV, Pytorch	Unid.	S/ -	1	S/ -
				S/ 5,942.00
3. SERVICIOS				
ESTUDIO - DOCUMENTACIÓN				
Elaboración del proyecto	Unid.	S/ 150.00	1	S/ 150.00
Elaboración del artículo	Unid.	S/ 150.00	1	S/ 150.00
MANTENIMIENTO				
Sistema Operativo	Unid.	S/ 50.00	1	S/ 50.00
Software de desarrollo	Unid.	S/ 50.00	1	S/ 50.00
OTROS				
Acceso a internet	Mes	S/ 75.00	9	S/ 675.00
				S/ 1,075.00
4. IMPREVISTOS				
Imprevistos (10%)				S/ 906.50
TOTAL PRESUPUESTO				S/ 9,972.00