



UNIVERSIDAD CÉSAR VALLEJO

## FACULTAD INGENIERÍA Y ARQUITECTURA

### ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

Sistema Inteligente basado en Deep Learning para mejorar el correcto uso personal de mascarillas en el supermercado Wong

TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:  
Ingeniero de Sistemas

#### **AUTORES:**

Baca Gamboa, María Rosa (ORCID: [0000-0003-1222-0548](https://orcid.org/0000-0003-1222-0548))

Sihuacollo Liñan, Julio Anderson (ORCID: [0000-0003-2144-2716](https://orcid.org/0000-0003-2144-2716))

#### **ASESOR:**

Dr. Agreda Gamboa, David (ORCID: [0000-0003-1252-9692](https://orcid.org/0000-0003-1252-9692))

#### **LÍNEA DE INVESTIGACIÓN:**

Sistemas de Información y Comunicación

TRUJILLO - PERÚ

2022

## Dedicatoria

Dedico este trabajo principalmente a Dios, por permitirme el haber llegado hasta este momento tan importante en mi formación profesional. A mis padres, William Baca y Amparo Gamboa por ser los pilares más importantes de mi vida y por el apoyo incondicional que siempre me han brindado.

**Rosa**

El presente trabajo tiene como dedicatoria a mis padres, amigos y a la UCV por brindarme su apoyo en esta etapa de mi carrera, por impulsarme a ser mejores y seguir aspirando a grados de master.

**Julio**

## Agradecimiento

Agradecemos principalmente a Dios por darnos la vida y fuerzas para seguir adelante, a la Universidad Cesar Vallejo por habernos permitido cumplir un logro importante en lo profesional y a nuestro asesor quien nos orientó en cada momento de la tesis compartiendo sus conocimientos.

Los autores

## Índice de contenidos

	Pág.
Dedicatoria .....	ii
Agradecimiento .....	iii
Índice de contenidos .....	iv
Índice de tablas .....	v
Índice de gráficos y figuras.....	vi
Resumen.....	vii
ABSTRACT .....	viii
I. INTRODUCCIÓN .....	1
II. MARCO TEÓRICO .....	5
III. MÉTODOLÓGÍA.....	18
3.1. Tipo y diseño de investigación .....	18
3.2. Variables y operacionalización.....	19
3.3. Población, muestra y muestreo.....	19
3.4. Técnicas e instrumentación de recolección de datos.....	21
3.5. Procedimientos .....	22
3.6. Método de análisis de datos.....	23
3.7. Aspectos éticos .....	26
IV. RESULTADOS .....	27
4.1 . Pruebas de Normalidad.....	27
4.2. Pruebas de Hipótesis .....	35
V. DISCUSION.....	40
VI. CONCLUSIONES.....	42
VII. RECOMENDACIONES .....	43
REFERENCIAS.....	44
ANEXOS .....	49

## Índice de tablas

	Pág.
Tabla 1. Población.....	19
Tabla 2. Recolección de Datos.....	21
Tabla 3. Prueba de Hipótesis del Indicador 1.....	23
Tabla 4. Prueba de Hipótesis del Indicador 2.....	24
Tabla 5. Prueba de Hipótesis del Indicador 3.....	25
Tabla 6. Prueba de Hipótesis del Indicador 4.....	25
Tabla 7. Normalidad – Prueba de indicador 1.....	27
Tabla 8. Normalidad – Prueba de indicador 1.....	28
Tabla 9. Normalidad – Prueba de indicador 2.....	29
Tabla 10. Normalidad – Prueba de indicador 2.....	30
Tabla 11. Normalidad – Prueba de indicador 3.....	31
Tabla 12. Normalidad – Prueba de indicador 2.....	32
Tabla 13. Normalidad – Prueba de indicador 4.....	33
Tabla 14. Normalidad – Prueba de indicador 4.....	34
Tabla 15. Wilcoxon – Prueba de Seguridad.....	35
Tabla 16. Contraste Estadístico – Prueba de Seguridad.....	36
Tabla 17. Wilcoxon – Prueba de Confianza.....	36
Tabla 18. Contraste Estadístico – Prueba de Confianza.....	37
Tabla 19. Wilcoxon – Prueba de Detección Mascarilla.....	37
Tabla 20. Contraste Estadístico – Prueba de Detección Mascarilla.....	38
Tabla 21. Wilcoxon – Prueba de Rapidez Reacción.....	38
Tabla 22. Contraste Estadístico – Prueba de Rapidez Reacción.....	39
Tabla 23. Matriz de Consistencia.....	64
Tabla 24. Operacionalización de Variables.....	66
Tabla 25. Cuadro de Comparación de Lenguaje de Programación.....	67
Tabla 26. Cuadro de Comparación de Metodología.....	69

## Índice de gráficos y figuras

	Pág.
Figura 1. Diseño Pre-Experimental.....	18
Figura 2. Histograma de Nivel de Seguridad.....	28
Figura 3. Histograma de Nivel de Seguridad.....	29
Figura 4. Histograma de Nivel de Confianza.....	30
Figura 5. Histograma de Nivel de Confianza.....	31
Figura 6. Histograma de Nivel de Detección Mascarilla.....	32
Figura 7. Histograma de Nivel de Detección de Mascarilla.....	33
Figura 8. Histograma de Nivel de Rapidez Reacción.....	34
Figura 9. Histograma de Nivel de Rapidez Reacción.....	35
Figura 10. Separación de Dataset para el entrenamiento.....	50
Figura 11. (a) Dataset: without_mask. (b) Dataset: with_mask.....	50
Figura 12. Obtención final de la detección después del procesamiento de Imágenes.....	51
Figura 13. Extracción de características necesarias.....	52
Figura 14. Extracción de características necesarias.....	53
Figura 15. (a). Usando la Mascarilla. (b) No usando la Mascarilla.....	54
Figura 16. (a). Usando la Mascarilla. (b) No usando la Mascarilla.....	54
Figura 17. Evolución en la reducción de error en el tiempo.....	55
Figura 18. Evolución de la precisión en el tiempo.....	55
Figura 19.a), (b), (c) y (d). Son los resultados que se ejecutan en tiempo real usando el modelo con alarma incluida si usa o no mascarilla.....	56

## Resumen

El objetivo principal del presente trabajo de investigación será mejorar el correcto uso de mascarillas en el supermercado Wong durante el contexto covid-19 con la implementación de un sistema inteligente, ya que se encontró que este es uno de los centros más capacidad de aglomerar personas y donde además se han detallado algunos casos de contagio a nivel local. Por lo cual, representa una gran necesidad y urgencia de implementar un dispositivo autónomo para el control de mascarillas. En ese sentido, el presente estudio es de tipo aplicado con un diseño pre-experimental. Para eso, se utilizó la metodología de Deep Learning con un promedio de muestra de 60 personas provenientes de San Miguel que concurren seguidamente en Wong. Esto con la finalidad de que los indicadores principales de seguridad, confianza, detección de mascarillas y rapidez de reacción sean los más óptimos posibles. Luego de ello, los resultados fueron destacables pues se concluyeron que sí hay un gran incremento de los indicadores planteados.

Palabras Clave: Deep Learning, Mascarilla, Sistema Inteligente, Sistemas Embebidos, Computer Vision, Redes Neuronales.

## **ABSTRACT**

The main objective of this research work will be to improve the correct use of masks in the Wong supermarket during the covid-19 context with the implementation of an intelligent system, since it was found that this is one of the centers with the greatest capacity to agglomerate people and where some cases of contagion at the local level have also been detailed. Therefore, it represents a great need and urgency to implement an autonomous device for the control of masks. In this sense, the present study is of an applied type with a pre-experimental design. For this, the Deep Learning methodology was obtained with an average sample of 60 people from San Miguel who subsequently attend Wong. This with the aim that the main indicators of safety, trust, detection of masks and speed of reaction are the most optimal possible. After that, the results were remarkable because it was concluded that there is a large increase in the indicators proposed.

Keywords: Deep Learning, Mask, Intelligent System, Embedded Systems, Computer Vision, Neural Networks.



## **I. INTRODUCCIÓN**

En tanto a la realidad problemática del presente trabajo de investigación, se consideró: Los sistemas inteligentes son capaces de funcionar adecuadamente de entornos de información sumamente cambiantes desarrollando cálculos numéricos y matriciales complejos, por ello son motivos de impacto en las diversas ramas de la ciencia, debido a sus distintas aplicaciones (Pitalúa, 2009). Asimismo, se menciona el correcto uso personal de mascarillas, la cual es una medida preventiva y eficaz para evitar la propagación de la Covid-19. Al margen de que se usen las mascarillas, también es importante detectar y verificar en el menor tiempo posible el inapropiado uso de las mascarillas en la población, como el distanciamiento físico y la observancia de la higiene permanente, principalmente de las manos (OMS, 2020).

La salud, según OMS (2020) es el estado integro de bienestar físico, mental y social. En ese sentido, y situado en el contexto COVID-19, mantener el estado e integridad física y mental no solo implica protegerse de daños exteriores conocidos, sino también es indispensable el uso permanente de las mascarillas y protectores faciales complementarios al cuerpo para evitar y mitigar posibles contagios del virus en lugares cerrados como estadios, supermercados, conciertos, bares, entre otros. Por lo tanto, respecto al gran número de personas que acuden con frecuencia a estos tipos de lugares, hace que sea difícil un adecuado control sobre ellos. Por ese motivo, un método más eficiente de verificar el correcto uso de mascarillas en lugares cerrados es usando técnicas de Inteligencia Artificial, específicamente de Deep Learning y Computer Vision.

En el ámbito Internacional, el Diario Oficial de Sao Paulo, Brasil (2020) publicó el Decreto 59396, el cual menciona que es obligatorio que todas las personas usen mascarillas en lugares públicos, comerciales y transportes con una multa por incumplimiento. Esto debido a que las mascarillas se volvieron esenciales para los paulistas que necesitan moverse por la ciudad durante la emergencia sanitaria. Además, según el Sistema de Monitoreo Inteligente de Sao Paulo PEREIRA (2021) la tasa de aislamiento fue baja, ya que, entre abril y mayo, osciló del 46% al 59%, de donde se esperaba un 70%. De acuerdo a ello, este sistema monitorea eficazmente el nivel de aislamiento y aglomeración de personas, pero

no el comportamiento de la población durante su tránsito en lugares públicos en cuanto al uso de mascarillas. Es por ello que, en dicho estado de Brasil, fue necesario implementar un sistema capaz de identificar si un individuo usa los equipos de protección personal en lugares públicos donde circula la gente. Sin embargo, ante los rebrotes de los virus generados con el transcurrir del tiempo y, además del bajo control personal de estas, la Start-Up China SenseTime (2020) desarrolló sistemas con inteligencia artificial para detectar el nivel de temperatura de las personas y, adicionalmente, desarrolló un algoritmo de detección de correcto uso de mascarillas en lugares públicos. Esto con el fin de generar alertas emergentes a los usuarios para mantener la distancia ante algún posible infectado.

En el ámbito Nacional, el informe N°5 Gestión Pública en tiempos de crisis Covid-19 (2020), hace mención que el Perú es uno de los principales países a nivel mundial con gran número de casos de covid-19, el cual tiene como foco de contagio los mercados de abastos y supermercados, ya que estos espacios de provisión de alimentos y materiales de primera necesidad, no contaron con medidas de protección adecuadas. Es por ello que, se realizaron aislamiento obligatorio en con el fin de reducir el índice de contagios. Sin embargo, esto acarrió consigo miedos e inseguridades en las personas al intentar salir a las calles. En ese sentido, NIZAMA (2021), miembro del Instituto Nacional de Salud Mental, afirma que la ansiedad y depresión afectan a 1 de cada 3 personas debido al confinamiento obligatorio decretado para hacer frente al covid-19. Asimismo, Nizama hace mención de que el ser humano necesita una rutina que le genere seguridad y lo impulse a seguir. En caso de que esta rutina se rompa, el humano entra en alerta causando desgaste mental. Por otro lado, la gran mayoría de ciudades del Perú con zonas urbanas cuentan con un 90% de contagios de COVID-19, donde todos son casos comunicados. Es por eso que es necesario responder ante la pandemia y trabajar por la recuperación colaborativa desde un punto de vista social, cultural, tecnológico y ético.

En el supermercado Wong ubicado en la ciudad de Lima, Perú, específicamente en el distrito de San Miguel. En este lugar viven alrededor de 100mil habitantes quienes suelen concurrir diversos lugares. En una publicación realizada por el

diario RPP (2020), en el supermercado Wong se registraron aproximadamente 11mil casos positivos de contagio de Covid-19 de un total de 100mil personas procesadas por pruebas rápidas y moleculares. Donde además se señala que el MINSA informó que de estas personas contagiadas 254 llegaron a la muerte. Es evidente que la situación cada vez es más compleja ante las diversas variantes que ya se conocen publica y abiertamente. Por ello el MINSA y demás centros de Salud recomiendan usar doble mascarilla, protector fácil y alcohol a la mando.

A continuación, mencionamos los problemas que fueron planteados en la investigación, existía un control ineficiente en la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong, se debió a que los clientes asistían a realizar sus compras de forma masiva al establecimiento, aumentando la probabilidad en el nivel de contagios de la Covid-19.

Falta de seguridad en las personas en el interior del supermercado Wong, se debió a que los clientes no usaban de manera correcta la mascarilla en todo momento, ocasionando que los clientes siempre estuvieran alertas de su alrededor; Falta de consciencia de la población en el uso correcto de la mascarilla al ingresar al supermercado Wong, se debió a que los clientes demostraban frecuentemente un bajo nivel de cultura ante la Covid-19, aumentando el índice de mortalidad que se registra de este virus; El personal encargado en la detección y verificación del uso correcto de las mascarillas no se daba abasto por la gran cantidad de clientes que asistían diariamente, se debe a que solo se contaba con la supervisión visual del personal de seguridad, ocasionando muchas veces que no se logre detectar el uso inapropiado de la mascarilla en tiempo real; En el interior del supermercado existían clientes que llevaban las mascarillas de forma incorrecta por un tiempo prolongado, se debía a la reacción tardía de las personas al llamado del personal de seguridad de colocarse de manera correcta la mascarilla, ocasionando que las personas estén propensas a contagiarse.

A continuación, el problema general de la investigación ¿De qué manera el uso de un sistema inteligente basado en Deep Learning mejora el correcto uso personal de mascarillas en el supermercado Wong?. Asimismo, como problemas específicos afines al general, se planteó los siguientes: ¿De qué manera un

sistema inteligente basado en Deep Learning influye en el nivel de seguridad de las personas en el supermercado Wong?, la segunda fue ¿De qué manera el sistema inteligente basado en Deep Learning influye en la confianza a las personas para transitar libre y seguramente en el supermercado Wong?, la tercera fue ¿De qué manera el sistema inteligente basado en Deep Learning influye el tiempo en la detección de las personas que usaron inapropiadamente la mascarilla en el supermercado Wong?, y la cuarta fue ¿De qué manera el sistema inteligente basado en Deep Learning influye en la rapidez en la reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong?

A Continuación, este estudio muestra la justificación de la investigación: Conveniencia, este trabajo permitirá que el Supermercado Wong mejore su tecnología con la implementación de un sistema inteligente que sea capaz de detectar con precisión, menor error, agilizar y controlar el uso de mascarillas personales, para reducir los riesgos de contagio de COVID-19 según lo recomendado por el MINSA; Relevancia social, este trabajo incluye un beneficio para la sociedad debido a que con la implementación de un sistema inteligente se mejoró la detección y verificación en el correcto uso personal de la mascarilla, dando seguridad y confianza a los clientes que concurran al supermercado con respecto a las medidas preventivas de la covid-19; Utilidad metodológica, sirve como base para futuras investigaciones sobre Sistemas inteligentes basados en Deep Learning; Implicancias prácticas, con el sistema inteligente permite solucionar de manera eficiente la detección del correcto uso personal de la mascarilla entre los clientes; Valor teórico, permite comprender mejor las teorías basadas en Sistema inteligente para mejorar el correcto uso de la mascarilla personal.

Seguidamente, a partir de las problemáticas que se identificó se planteó el siguiente objetivo general: Mejorar el correcto uso personal de mascarillas en el supermercado Wong, mediante un sistema inteligente basado en Deep Learning. Por consiguiente, se identificó, a raíz del objetivo general, los siguientes objetivos específicos: Aumentar el nivel de seguridad de las personas en el supermercado Wong, Aumentar el nivel de confianza de las personas para transitar libre y seguramente en el supermercado Wong, Disminuir el tiempo en la detección y

verificación del correcto uso personal de mascarillas en el supermercado Wong, Aumentar la rapidez de reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong.

Finalmente, una vez que se evidenció la realidad problemática que generó la COVID-19 a nivel internacional, nacional y local, se planteó la siguiente hipótesis de acuerdo a los lineamientos descritos inicialmente: Si se usa el sistema inteligente basado en Deep Learning mejora el correcto uso personal de mascarillas en el supermercado Wong. Asimismo, las hipótesis específicas: Si se usa el sistema inteligente basado en Deep Learning aumenta el nivel de seguridad de las personas en el supermercado Wong, Si se usa el sistema inteligente basado en Deep Learning aumenta el nivel de confianza de las personas para transitar libre y seguramente en el supermercado Wong, Si se usa el sistema inteligente basado en Deep Learning disminuye el tiempo en la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong, Si se usa el sistema inteligente basado en Deep Learning aumenta la rapidez de reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong.

## **II. MARCO TEÓRICO**

En referencia a los trabajos previos realizados sobre la variable dependiente (Detección y verificación del correcto uso personal de mascarillas), se tiene Shilpa, Mamta y Trilok (2021), desarrollaron el artículo Face mask detection using deep learning: An approach to reduce risk of Coronavirus spread, quienes tienen como objetivo general desarrollar un mejor modelo en Inteligencia y Visión Artificial para verificar que las personas usen correctamente la mascarilla y además generen un sistema de alerta y alarma gestionándolos desde una base de datos. Utilizó como diseño de investigación experimental, además tiene una población de 1000 personas de la India que transitan día a día en las calles, se aplicó el instrumento de recolección de datos visión por computadora. La metodología de desarrollo fue visión artificial y como componentes se usaron los frameworks de YOLO y PyTorch, donde en ambos casos es necesario programarlos en Python. Obtuvo como resultados la visualización de incumplimientos cuando las personas se quitan las

mascarillas personales. Asimismo, concluye que se pudo verificar y mostrar como el modelo construido en Inteligencia Artificial cuenta con una eficiencia de 98.2% para distinguir si una persona utiliza o no las mascarillas correctamente. Finalmente, recomienda encarecidamente el uso de máscaras faciales al público en general para aminorar la propagación de la covid-19.

Mira (2021) quien tiene como objetivo general crear patrones de los clientes enlazados a una base de datos para que el sistema que utiliza vision artificial pueda detectar la identidad de las misma y, además, verificar que esté usando adecuadamente la mascarilla personal. Utilizó como diseño de investigación experimental, además tiene una población de 500 personas de la Universidad Montclair que requieren una identificación biométrica preliminar para poder ingresar a sus labores diarias, se aplicó instrumento recolección de datos mediante el uso de la red neuronal convolucional, que se basa en un algoritmo de aprendizaje profundo, que se enfoca en procesar datos e imágenes. La metodología de desarrollo fue la arquitectura de capas completamente conectadas y como componentes Adam Optimizer y MSELoss. Obtuvo como resultados la identificación de las personas incluso usando la mascarilla personal, de esta manera reduciendo tiempo y cuidando a las personas ante posibles ambientes de covid-19. Asimismo, concluye que se pudo crear un sistema inteligente para el control biométrico de las personas con una precisión de 97.1% incluido los aciertos en el uso de mascarillas. Finalmente recomienda el potencial que tienen los sistemas con computer vision para usarlos en entornos de trabajo validando la identificación de cada operario, siendo una herramienta útil para combatir la propagación del virus. También, Riya y Rutva (2020), desarrollaron el artículo Detection of Face Mask using Convolutional Neural Network, quienes tienen como objetivo general crear una red neuronal convolucional más óptima y que pueda desarrollarse con un margen de error menor en la identificación del uso de mascarillas en entornos difíciles. Utilizó como diseño de investigación experimental, además tiene una población cerca de 1000 personas de la India que cuestionaron la manera de usar mascarillas y necesitaron un método más inteligencia y autónomo para tomar decisiones e indicar detecciones, se aplicó el instrumento de recolección de datos mediante cámaras. La metodología de desarrollo fue MobileNetV2 usando Transfer Learning. Obtuvo como resultado una mayor rapidez

y un menor margen de error al verificar e identificar si una persona usa o no una mascarilla, para esto se usaron alrededor de 1000 imágenes pertenecientes a un dataset local. Asimismo, concluye que se pudo crear una nueva arquitectura de red neuronal usando frameworks como OpenCV, TensorFlow y Keras, la cual es superior en precisión y menor margen de error dando como resultado un 95% de precisión. Finalmente, recomienda cómo crear y comparar nuevas arquitecturas basadas en redes neuronales tomando como líneas de base modelos pre-entrenados con una gran exactitud. Otro resultado, Mbunge et al. (2020) quienes tienen como objetivo general experimentar diferentes redes neuronales basadas en Deep Learning para validar cuál de todas es mejor y bajo qué contextos se obtienen mejores eficiencias y generación de alertas para velar por las personas en lugares con alto impacto de la covid-19. Utilizó como diseño de investigación experimental, además tiene una población aproximada de 500 personas de Eswatini que mostraron actitudes de necesidad por desarrollar un sistema de alarma en lugares cerrados ante posibles personas que no contemplen los protocolos de la covid-19, se aplicó instrumento de recolección de datos mediante cámaras. La metodología de desarrollo fue deep learning y machine learning. Obtuvo como resultados la muestra de diversos algoritmos inteligentes que favorecen en la comparación y visualización de resultados, los cuales servirán como base para trabajar sobre estos y poder mejorarlos. Asimismo, concluye que se obtuvieron resultados de 99.9% de precisión en la arquitectura InceptionV3, la cual es la mejora hasta ahora. Finalmente, recomienda en señalar diversos algoritmos y compararlos para poder tomar mejores decisiones y optimizarlos al nivel necesario de precisión, ya que en el caso de detección de la covid-19 se necesitó un modelo con un gran performance en diversos escenarios. Mientras, Adhikarla y Davison (2021) quienes tienen como objetivo general desarrollar un modelo en Deep Learning para que pueda ser desplegado en una Jetson Nano Xavi usando solamente una cámara básica. Utilizó como diseño de investigación experimental, además tiene una población de 800 personas de Estado Unidos (USA) que colaboraron para hacer frente a la covid-19, se aplicó instrumento de recolección de datos mediante cámara facial web. La metodología de desarrollo fue Deep Learning y computer vision. Obtuvo como resultados la implementación y visualización de un sistema inteligente que contempla una cámara básica, pero con un modelo computacionalmente costoso,

estos mismos son incorporados dentro del microprocesador Jetson Nano para que pueda ser lo más autónomo posible. Asimismo, concluye que se puede crear y desplegar el modelo dentro de un sistema embebido para que pueda ser autónomo y proporcione reportes de zonas de mayor riesgo sanitario en una ciudad o calle. Finalmente, recomienda validar la forma y pasos para desplegar un modelo de inteligencia artificial en la web y en un microprocesador con potencial uso para Deep Learning y computer vision de la empresa líder en tecnología e innovación NVIDIA. Finalmente, Mahdi y Mohsen (2020) quienes tienen como objetivo general apoyar en la reducción de la propagación del coronavirus y sus costos económicos al proporcionar una solución basada en inteligencia artificial para monitorear y detectar automáticamente incumplimiento del distanciamiento social entre las personas. Utilizó como diseño de investigación experimental mediante la realización de pruebas y evaluaciones minuciosas en una diversidad de conjuntos de datos en interiores y exteriores que superan el estado de las artes, además tiene una población de 150,000 personas para realizar la detección y la estimación del distanciamiento, se aplicó la técnica de seguimiento simple en línea y en tiempo real. La metodología de desarrollo fue DeepSOCIAL-DS basado en YOLOv3 y YOLOv4-X. Obtuvo como resultado un alto nivel de precisión, lidiar con una variedad de condiciones de iluminación y rendimiento en tiempo real. Asimismo, concluye que un sistema genérico de detección se puede utilizar en varias aplicaciones del mundo real, como la detección de peatones en vehículos, el reconocimiento de acciones humanas y la detección de anomalías. Finalmente, recomienda un modelo de detector humano basado en redes neuronales profundas llamado DeepSOCIAL para detectar y rastrear personas estáticas y dinámicas en lugares públicos con el fin de supervisar el distanciamiento social recomendado en el tiempo de la COVID-19.

En referencia a los trabajos previos realizados sobre la variable dependiente (el correcto uso personal de mascarillas), se tiene Elias et al. (2021) quienes tienen como objetivo general aplicar algoritmos de Deep Learning para el reconocimiento facial con la presencia de oclusiones, aun cuando el personaje en estudio usa las mascarilla y protector facial. Utilizó como diseño de investigación experimental, además tiene una población aproximada de 480 personas de Huancayo - Perú que mostraron y prestaron comportamientos naturales en lugares concurridos para



poder evidenciar las debilidades de un sistema que identifica rostros a pesar de usar mascarillas. La metodología de desarrollo fue usando redes neuronales profundas. Obtuvo como resultados un entrenamiento con un dataset propio de más de 8h lo cual lo hace bastante robusto ante ruidos exteriores, una mejor identificación de rostros con un margen de error bajo y con una rapidez gestionando adecuadamente la RAM de una computadora. Asimismo, concluye que se obtuvieron resultados de 71% de precisión entrenando su modelo bajo la arquitectura VGG16, la cual logró brindar buenos resultados al momento de probar en campo. Finalmente, recomienda que, si se desea entrenar con dataset propios, es necesario usar Google Collab, pues permite usar una TPU y GPU universal para manejar datos no estructurados. En ese sentido, también adiciona que los resultados son sobresalientes en un entorno altamente iluminado, permitiendo una mejor identificación del sistema. Asimismo, La Madrid y Barriga (2019) quienes tienen como objetivo general implementar un modelo tecnológico para identificar y notificar la atención de los pacientes en el sector salud. Utilizó como diseño de investigación experimental, además tiene una población aproximada de 1000 personas de Lima - Perú que mostraron no contar con DNI o algún documento de identificación al momento de solicitar atención en el hospital, se aplicó un instrumento de recopilación de datos mediante un cuestionario de 4 preguntas y valoración de satisfacción en una escala de Likert. La metodología de desarrollo fue empleando técnicas avanzadas de Deep Learning y Google Cloud Platform. Obtuvo como resultados un mejor acercamiento y autoatención en la entrada para identificarse en el hospital y así poder agilizar el proceso de atención en cuestiones de salud y chequeos médicos. Asimismo, concluye que se obtuvieron resultados de 93% de precisión entrenando su modelo bajo el algoritmo de XGBoost en Machine Learning, lo cual permitió un fácil ensamble con el aplicativo (app/web) para poder realizar un deploy en la nube. Finalmente, recomienda que, si se desea trabajar con más datos, es necesario una limpieza del dataset previo para poder obtener mejores resultados. Además, de que es necesario contar con una señal de internet bastante buena para ejercer la gran masa de datos en un entorno de desarrollo web con Machine Learning. También, Ramirez (2019) quien tiene como objetivo general desarrollar un algoritmo de procesamiento de imágenes e inteligencia artificial orientada a la detección de reconocimiento de rostros en entornos de iluminación

no controlada con grado de asertividad del 95%. Utilizó como diseño de investigación pre-experimental, además tiene una población aproximada de 800 personas de Lima, Perú que evidenciaron según el ministerio de transportes una conducta de inadecuada en accidentes de tránsito en carreteras, se aplicó instrumento de recolección de imágenes mediante una interfaz gráfica de usuario donde se registró la hora en la que se capturaron las imágenes y se le asigna un identificador único a cada conductor. La metodología de desarrollo fue usando técnicas de procesamiento de imágenes e inteligencia artificial para detectar ciertos patrones que permitan evaluar si habrá una posible consecuencia grave en un choque, de esta manera el algoritmo tratará de controlar, monitorear y anticipar ante un posible accidente vehicular. Obtuvo como resultados 2 componentes que permiten trabajar más ágilmente en Deep Learning; es decir, usando detección y validación del rostro de la persona para identificarlos anticipadamente. Asimismo, concluye que se obtuvieron resultados de 99.2% de precisión entrenando su modelo basado en Deep Learning, constanding de evoluciones del 71.98%, 97.65% donde el cambio mayor se vio al tunear mejor los hiperparámetros dentro de la programación. Finalmente, recomienda que, si se desea obtener un mejor performance, es necesario usar otros algoritmos para optimizar los resultados. Asimismo, Aguilar et al. (2020) quienes tienen como objetivo general crear un modelo para la predicción de covid-19 usando redes neuronales convolucionales temporales en regiones peruanas a partir del uso de las cámaras web que almacenan información de video en tiempo real. Utilizó como diseño de investigación experimental, además tiene una población aproximada de 2500 personas de Trujillo - Perú que mostraron síntomas de enfermedades de la covid-19 debido al uso incorrecto de la mascarilla en zonas de mayor aglomeración de personas, se utilizó la recolección de imágenes mediante las redes neuronales convolucionales. La metodología de desarrollo fue considerando técnicas de aprendizaje profundo donde se hizo uso de redes neuronales convolucionales temporales para la predicción de posibles rebrotes de la covid-19. Obtuvo resultados considerables, donde alcanzaron predicciones precisas para identificar y prevenir posibles contagios potenciales en áreas de difícil acceso a la información. Asimismo, concluye que se obtuvieron resultados de 97.3% de precisión para el testeo respectivo en diversas zonas y regiones del Perú. Finalmente, recomienda

que es necesario contar con la información en tiempo real para pronosticar aún bajo los modelos en Deep Learning, gestionando de esta manera y anticipándose ante cualquier perjuicio que pueda provocar las futuras olas de contagios del virus. Otro resultado, Barreto y Lizarraga (2019) quienes indican como objetivo general el proponer un modelo de sistema de reconocimiento fácil para el control de la trata de personas. Utilizó como diseño de investigación pre-experimental, además tiene población aproximada de 100 personas de Arequipa, Perú que evidenciaron sensibilidad y necesidad de desarrollo tecnológico que afronte la trata de personas, un tema bastante delicado en el ámbito local, se aplicó la internet como técnica para la recopilación de datos, siendo una de las esenciales herramientas para la obtención de la información. La metodología de desarrollo fue usando frameworks como OpenFace y redes neuronales convolucionales que facilita obtener aciertos en reconocimiento de patrones y landmarks propios de un rostro, ayudando en la identificación de las personas acorde a una base de datos local. Obtuvo como resultados identificaciones de rostros precisas a menor distancia de la cámara y viceversa, siendo esta relación directamente proporcional. Asimismo, concluye que se obtuvieron resultados de 79% de acierto en la detección del rostro en diversas ubicaciones y perfiles usando Deep Learning para intensificar el aprendizaje pre-entrenados. Finalmente, recomienda que, para un mejor resultado, es necesario jugar con los hiperparámetros destinados por OpenFace en su documentación oficial. Asimismo, recomienda que se pueda hacer una comparativa entre algoritmos como Dlib, usar cámaras de 720p y aplicarlos directamente en lugares fronteros donde se necesita un mayor control como, por ejemplo, aeropuertos, terrapuertos, comisarías y estaciones fronteras. Finalmente, Cadena (2021) quien tiene como objetivo general desarrollar una técnica de reconocimiento facial que tenga un porcentaje de eficiencia por encima del 97% utilizando algoritmos de wavelets de Gabor y Máquinas de Soporte Vectorial con sus diferentes kernels a través de imágenes 3D para contribuir con la seguridad ciudadana. Utilizó como diseño de investigación pre-experimental, además tiene una población aproximada de 2000 personas de Lima - Perú que mostraron preocupación por desarrollar un sistema de reconocimiento biométrico facial para aportar en la seguridad ciudadana general, se aplicó técnicas de recolección de datos la Data de figuras de rostros 2D y 3D. La metodología de desarrollo fue en base a algoritmos genéticos basados en

patrones faciales que van asociados a técnicas algorítmicas como Gabor, para el filtrado y separación de cualidades faciales, y SVM, para la clasificación directa de estos mismos. Obtuvo como resultados mayores aciertos con filtros Gaussianos con un 96% de precisión, lo cual es considerado cercano al objetivo planteado. Asimismo, concluye que generar un modelo en Inteligencia Artificial para reconocimiento facial 2D, es bueno, pero si se desarrolla usando cámaras 3D, la optimización aumentaría considerablemente. Es por eso que usando el dataset TEXAS3DFRD siendo imágenes en 3D, llegó a una precisión del 98.4%, siendo superior al objetivo trazado y siendo más eficaz para extraer patrones faciales acordes a una persona. Finalmente, recomienda que se puedan realizar comparaciones con otros algoritmos de clasificación clásicos en Machine Learning como los árboles de decisiones o K-Nearest Neighbors.

A continuación, se procederá a describir algunas bases teóricas vinculadas al desarrollo de la presente investigación. En principio, se contempla la variable independiente que hace referencia a un sistema inteligente, para ello se subdividió en conceptos arraigados al mismo, los cuales son: Sistemas, Lopez (2012) es un grupo de elementos que se conectan entre sí para lograr metas. Es por ello que están estrechamente relacionados formando una actividad para lograr objetivos, además, ejecutan sobre datos, energía, materia y proporcionan información, energía y materia. Por otra parte, con respecto a sistemas inteligentes, Ramirez (2019) lo explica como un sistema con conciencia, estructura funcional y organizacional de alta integración y sensibilidad que le faculta contestar de forma adecuada, oportuna y eficiente a los problemas procedentes de su interacción con el entorno. De esta manera, la inteligencia, desde un punto de vista informático, es brindada por el desarrollo y programación de sistemas con Inteligencia Artificial.

A continuación, para describir la variable dependiente que es El Correcto Uso Personal De Mascarillas se consideró los siguientes conceptos:

Mascarillas, según Torres y Sevilla (2009) son equipos que se han usado para reducir la exposición de los trabajadores al material infeccioso ocurrido a través de salpicaduras y gotas, principalmente. Además, según Quiroz (2020), las mascarillas quirúrgicas pueden ayudar a bloquear las gotitas más grandes de partículas,

derrames, aerosoles o salpicaduras, que podrían contener microbios, virus y bacterias, para que no alcance la nariz o la boca.

Uso correcto, según el Ministerio de Salud (2021), el uso correcto de mascarillas lo asocia a tomar las medidas adecuadas de prevención para reducir la transmisión comunitaria.

Uso personal, RAE (2020) el uso personal hace referencia a que un ejemplar es exclusivamente para el propio uso de un individuo.

El correcto uso personal de mascarillas, OMS (2020) es importante, por ello se debe de detectar y verificar a tiempo de forma visual u otros medios, procurando que cubra la boca y la nariz, que se ajuste al puente de la nariz y quede bien sujeta para disminuir cualquier posible hueco entre el rostro y la mascarilla; previniendo la transmisión de la Covid-19.

Asimismo, se procede a describir la variable interviniente, la cual es Deep Learning. En este caso el concepto está vinculado a la detección de mascarillas y rostros biométricos. En principio, según Voulodimos et al. (2018) Deep Learning permiten que modelos computacionales con múltiples procesamientos, aprendan y represente datos con muchos niveles de abstracción mostrando como la mente humana puede percibir y entender objetos en lugares con grandes datos no estructurados. Esta tecnología trabajando conjuntamente con Computer vision, tienen un alto potencial de entendimiento del entorno, pues no solo permite comprenderlo, sino se le da la capacidad para reconocer qué objetos son de interés según la necesidad del desarrollo. Es por eso que se define a Deep Learning como un tipo de aprendizaje automático, inspirado en la estructura de un cerebro humano; es decir, se le dota a un sistema la capacidad de sacar conclusiones similares como lo que harían los humanos, analizando continuamente datos con una estructura lógica determinada. Para lograr esto, Oppermann (2019) el aprendizaje profundo o también llamado Deep Learning utiliza una estructura de algoritmos de varias capas llamadas redes neuronales. También, para comprender un poco más se define a las redes neuronales como un subconjunto del Machine Learning y están en el corazón de los algoritmos de Deep Learning, los cuales sus desarrollos están inspirados en la forma en que las neuronas biológicas se transmiten entre sí. Estos mismos, IBM (2020) se basan en entrenamientos para aprender y mejorar su

precisión con el tiempo y una vez que estos algoritmos de aprendizaje están ajustados para su precisión, son herramientas poderosas en las ciencias de la computación e IA, lo que permite clasificar y agrupar datos a alta velocidad.

Existen diversos tipos de redes neuronales, en principio se tiene las redes neuronales artificiales (ANN), Aravindpai (2020) la cual es capaz de aprender cualquier función no lineal, son conocidas como aproximadores de funciones universales. Esto ayuda a reconocer cualquier relación compleja entre la entrada y salida de datos. Por otro lado, existe la red neuronal recurrente (RNN), la cual similar a las ANN, tienen conexiones entre neuronas, sin embargo, la diferencia yace en que la RNN tienen una conexión recurrente en el estado oculto, es una restricción de bucle que asegura que la información secuencia se capture en los datos de entrada. Finalmente, se tienen las redes neuronales convolucionales (CNN), los cuales son ampliamente usados en proyectos de procesamiento de imágenes y videos. Los componentes básicos de las CNN son los filtros o también llamados kernels. Estos extraen características relevantes de la entrada mediante la operación de convolución, dando de esta manera un mapa de características y modificaciones en la imagen como parte de una salida de datos. Luego de entender todos los aspectos conceptuales que se centran en los algoritmos de Deep Learning, existe una rama paralela que va asociada a las redes neuronales convoluciones (CNN); es decir, Computer Vision.

Venables (2019) Esta última tiene diversas definiciones, pero las más resaltante es que es un campo de la inteligencia artificial que entrena a las computadoras para interpretar y comprender el mundo visual. Las máquinas pueden identificar y localizar objetos con precisión y luego reaccionar a lo que “ven” utilizando imágenes digitales de cámaras, videos y modelos de aprendizaje profundo para mejorar aún el entendimiento e interpretación del entorno.

En esta sección, se presentarán los enfoques conceptuales que están asociados a la presente investigación para su mayor entendimiento y comprensión al momento de desarrollar el módulo pre-experimental. En ese sentido, a continuación, se definen conceptos involucrados en la presente investigación.

Inteligencia Artificial, según Martinez (2013), lo define como la rama de la informática jurídica que trata de llevar a cabo con máquinas, labores que puede

realizar el ser humano utilizando cualquier tipo de razonamiento. Es una automatización de las actividades que relacionamos con procesos del pensamiento humano, tales como la determinación de decisiones, soluciones de los problemas y del aprendizaje. Es por ello, que cualquier sistema al que se le pueda dotar de inteligencia artificial, sería llamado sistema inteligente. Pues no solo contempla resolver objetivos planteados o diseñados, sino que también se pretende que pueda razonar bajo un entendimiento estricto para el que fue diseñado y programado.

Open Source Computer Vision (Open CV), según la documentación oficial y lo planteado por Viera (2017), esta es una librería completamente libre y gratuita, pues se distribuye bajo licencia BSD (Berkeley Software Distribution), que facilita que sea empleada libremente en diferentes proyectos con propósitos comerciales y de investigación, siempre y cuando, cumpla con los requisitos de la licencia. OpenCV está perfeccionada para ser empleada bajo procesadores Intel, sin embargo, también puede ser utilizada bajo cualquier otro tipo de procesadores y puede tomar ventaja de procesadores multinúcleo. Las librerías OpenCV pueden instalarse tanto en Linux como también en Windows. De esta manera, esta librería es conocida a nivel mundial y ampliamente usada en investigaciones de desarrollo en visión computacional, ya que está optimizada para procesamiento digital de imágenes, control de procesos, detección de objetos, robótica, etc.

Procesamiento digital de imágenes, según Viera (2017) se dividen en dos amplias categorías que son dominio espacial y dominio frecuencia, pero también hay técnicas que se mejoran las imágenes mezclando ambas categorías. El primero, se basa en la manipulación de los píxeles directamente, transformándolos por intensidad (contraste y umbralización) y filtrado que trabaja con los píxeles vecinos directamente. El segundo, utiliza técnicas avanzadas de la Transformada de Fourier de una imagen, en lugar de la propia imagen.

El ruido, según Viera (2017), es la información no deseada en la imagen digital, que provoca una oscilación en el valor de sus píxeles alrededor de su valor real. Esto suele producirse en la adquisición fuente de cada imagen o video, rendimiento de sensores y condiciones ambientales e iluminación que establece natural o artificialmente. En estas condiciones de ruido, es necesario usar la técnica de filtros con el fin de disminuir estas señales ruidosas para que se pueda obtener la

información más real posible al momento de procesar la imagen. Además, una data bien limpia, ordenada, gestionada, filtrada y controlada permite que se obtengan mejores entendimientos y visualización real del mundo y de lo que se desea extraer de este.

El Filtro, Viera (2017), lo definen como conjunto de operaciones en donde el nuevo valor de un pixel depende de su anterior valor y el de los pixeles vecinos. Estas operaciones no afectan el tamaño de la imagen resultante, de tal forma que la relación entre la imagen resultante y la imagen original sigue siendo igual que en las operaciones de pixel 1 a 1. Esta se basa en una función de transferencia que implica tener una señal de entrada, para obtener otra señal de salida, mediante el proceso llamado convolución. De esta manera, en la salida se obtienen imágenes libres de ruido y con suavizado en imágenes, contraste, relieve y brillo.

Sistema embebido, según Úbeda (2009), lo define como un sistema electrónico que está diseñado precisamente para realizar unas específicas funciones, habitualmente formando parte de sistema de mayor entidad. La característica fundamental es que emplea para ello uno o múltiples procesadores digitales (CPU) en formato de microprocesador, microcontrolador o DSP lo que le permite aportar inteligencia al sistema anfitrión al que ayuda a gobernar y de que forma parte. Este mismo consta de Software, que viene a ser la programación o lógica de control interno para la determinación en las decisiones y, también, consta de Hardware que viene a ser la parte de periféricos por donde las señales son brindadas a los actuadores y obtenidas mediante sensores. Es por ello que estos tipos de sistemas son ampliamente usados y mostrados en lugares donde se necesita autonomía para un control de alguna situación bajo cierto contexto. Brindando de esta manera, información precisa, confiable e interpretable para un usuario con el propósito de informar y controlar el entorno al que se expone, así realizando otras actividades mientras el sistema embebido realiza su función.

TensorFlow, según Muñoz (2016), lo define como una librería de código abierto para realizar operaciones (numéricas, computación) usando el flujo de datos en grafos. En estos, los nodos representan las operaciones mientras que las aristas personifican las estructuras de los datos o comúnmente llamado tensores. Esta librería fue desarrollada por GoogleBrain Team y Google's Machine Intelligence



Research para proyectos que involucren Machine Learning y Deep Learning. Este framework es muy amplio y conocido a nivel mundial por la facilidad de codificación y entendimiento en el desarrollo, además hace que su gran versatilidad se aplicable a muchos tipos de proyectos.

PyTorch, según Merino (2020), lo define como la librería Open Source de Python, que está enfocada a la ejecución de cálculos numéricos por medio de la programación de tensores, la cual posibilita su aplicación en el desarrollo de aplicaciones con Deep Learning. Su sencillez de su interfaz, y su capacidad para ejecutarse en GPUs, lo que acelera el entrenamiento de los modelos, lo convierten en la opción más asequible para crear redes neuronales artificiales. Además, es la biblioteca de tensores perfeccionados para el aprendizaje profundo mediante GPU y CPU. Las aplicaciones de esta misma son amplias, pues incluso empresas como Tesla, Uber y Pyro usando PyTorch como pieza fundamental en el desarrollo de aplicaciones con inteligencia artificial.

Python, según Vásquez (2019), lo describe como lenguaje de programación ampliamente usado en diversos proyectos de desarrollo web, aplicativos, robótica e inteligencia artificial. Asimismo, se le conoce como un lenguaje interpretado de tipado dinámico cuya filosofía hace que la sintaxis sea de código legible. Pues se ejecuta sin necesidad de ser procesado por el compilador y se detecten errores en tiempo de ejecución, soporta programación funcional, programación imperativa, programación orientada a objetos. Además, las variables se comprueban en tiempo real de ejecución, es multiplataforma pues trabaja tanto en Windows, Linux y Mac. Además, es gratuito, pues no dispone de licencia para programar.

Raspberry Pi, según Escalante (2019), es un ordenador muy pequeño, similar a una tarjeta de crédito y consta de varios elementos. Tiene una base que es una placa y está montado sobre un procesador, tiene un RAM y un chip. Fue creado en el 2006 para la enseñanza de informática en escuelas, pero actualmente tienen un software de Open Source, que significa de código abierto, esto puede modificar por parte de un programador y puede trabajar en cualquier sistema operativo, incluso en las últimas versiones de Windows 10. Consta de múltiples puertos de entrada y salida y se suele usar ampliamente en robótica e inteligencia artificial.

### III. METODOLOGÍA

#### 3.1. Tipo y diseño de investigación

El tipo de la presente investigación fue aplicada. Se escogió esto ya que según Schwarz (2017) el tipo aplicativo está vinculada a resolver problemáticas en trabajos de investigación asociadas a la industria, mercado o servicios. En ese sentido, escoger este tipo de investigación es óptimo ya que va acorde con los objetivos planteados.

Finalmente, el diseño del trabajo de investigación fue experimental, de tipo pre-experimental, ya que abarcó un pre-test y un post-test, ver Figura N° 1. Esto implicó que en el estudio pre-test se validaron la situación del momento (un antes), mientras que para llegar a realizar un post-test (un después) se necesitaba implementar el sistema inteligente para que haga puente entre ambos tipos de test y se llegue a resultados esperados luego de poner en ejecución en campo al sistema inteligente. En ese sentido, Hernandez, Fernandez y Baptista (2014), con este tipo de diseño se obtienen resultados con mayor validez, pues se observan a individuos en situaciones comunes y reales.




Figura 1. Diseño Pre-Experimental

En este esquema se detalla lo siguiente:

- G: Grupo experimental
- Diagnóstico Inicial: Control y verificación del correcto uso de mascarillas personales antes de la implementación del sistema inteligente en el supermercado Wong
- Implementación: Sistema Inteligente.
- Diagnóstico Final: Control y verificación del correcto uso de mascarillas personales después de la implementación del sistema inteligente en el supermercado Wong.

### 3.2. Variables y operacionalización

Las variables que se consideraron en la presente investigación fueron: Variable Independiente: Sistema Inteligente, Variable Dependiente: El correcto uso personal de mascarillas en el supermercado Wong y Variable Interviniente: Deep Learning. La operacionalización a detalle de estas variables se ubica en el Anexo N°02.

### 3.3. Población, muestra y muestreo

En este apartado se procedió a explicar detalles de un grupo de datos que sirvieron para un análisis estadístico y de razón según lo planteado líneas arriba.

La población se deriva del público que comprende a todos los elementos cuyas características queríamos estudiar. Salazar y Del Castillo (2018) indica en otras palabras, que es el conjunto integro al que se pretende describir o del que se requiere establecer conclusiones.

En ese sentido, para que el proyecto fuese efectivo se tomaron como población alrededor de 100 clientes dentro del supermercado de Wong en Plaza San Miguel provenientes de la zona y alrededores que visitaban al día. El rango de personas que fueron evaluadas fue en promedio de 18 años hasta los 40 años quienes son los visitantes más frecuentes en estas zonas.

Tabla 1. Población

<b>INDICADOR</b>	<b>CANTIDAD</b>	<b>UNIDAD</b>
Porcentaje en el nivel de seguridad de las personas	70	clientes
Porcentaje nivel de confianza de las personas	70	clientes
Tiempo en la detección y verificación del correcto uso personal de mascarilla	70	clientes
Porcentaje de rapidez de reacción de las personas.	70	clientes

Salazar y Del Castillo (2018) La muestra es un grupo de elementos elegidos de una población de acuerdo a un plan de acción previamente establecido (muestreo) con

la finalidad de conseguir resultados que pueden ser extensivas hacia toda la población. A continuación, se utilizó la siguiente fórmula para el cálculo de la muestra:

$$n = \frac{N * (z^2) * p * q}{(d^2)(N - 1) + (z^2) * p * q}$$

Donde:

n= Tamaño de la muestra

N= Tamaño de población (100)

z= nivel de confianza (95%)

p= probabilidad de éxito, o proporción esperada (0,5)

q= probabilidad de fracaso (0,5)

d= niveles de errores dispuestas a cometer (5%)

(Salazar y Del Castillo 2018) El muestreo considera como finalidad estudiar las relaciones presentes en medio de la distribución de la variable “y” en la población “z” y las distribuciones de esta variable en la muestra a estudio.

$$n = \frac{70 * (1.96^2) * 0.5 * 0.5}{(0.05^2)(70 - 1) + (1.96^2) * 0.5 * 0.5}$$

$$n = \frac{70 * (3.8416) * 0.5 * 0.5}{(0.0025)(69 - 1) + (3.8416) * 0.5 * 0.5}$$

$$n = \frac{67.23}{1.13}$$

n = 60 Clientes

### 3.4. Técnicas e instrumentación de recolección de datos

En esta sección se explicarán las técnicas, como también los instrumentos de recolección de datos que se usaron a lo largo del desarrollo del presente trabajo de investigación. De la misma manera, se contempló los criterios de confiabilidad y la validez como instrumentos para que pudiera procesar la gran cantidad de datos necesarios para obtener resultados y conclusiones que han podido afianzar todo el estudio. En ese sentido, para identificar las distribuciones muestrales se usó el método de Smirnov-Kolmogorov. Además, se usa la prueba Wilcoxon para las pruebas de las hipótesis planteadas en el capítulo uno.

Casas, Repullo y Donado (2003), El desarrollo de una encuesta es considerablemente utilizado como método de investigación, debido a que facilita la obtención y elaboración de datos sea de manera más rápida y efectiva. Es en ese sentido que su fácil adopción hace que las personas puedan plasmar sus experiencias vivenciales acorde a un suceso o evento que acontece en su entorno, brindando de esta manera datos realistas que permitan un análisis certero de la información recibida.

Tabla 2. Recolección de Datos

<b>DIMENSIÓN</b>	<b>INDICADOR</b>	<b>TÉCNICA</b>	<b>INSTRUMENTO</b>
Nivel De Seguridad	Porcentaje en el nivel de seguridad de las personas.	Observación	Ficha de Observación
Nivel De Confianza	Porcentaje nivel de confianza de las personas.		
Tiempo	Tiempo en la detección y verificación del correcto uso personal de mascarilla.		
Rapidez	Porcentaje de rapidez de reacción de las personas.		

### **3.5. Procedimientos**

En la presente investigación se analizó una de las problemáticas frecuentes en el supermercado Wong que es la detección y verificación del correcto uso de las mascarillas, es por ello que se propuso como la variable dependiente del presente proyecto, una vez establecido nuestro enfoque se dio inicio a investigar situaciones semejantes en otros supermercados del país y del mundo para poder examinar las soluciones que ofrecieron en ese momento, asimismo se conoce a nivel internacional estudios e investigaciones similares como: identificación de rostros, distanciamiento, calor térmico donde es aplicada la inteligencia artificial; basándose en esos antecedentes, se tomó la decisión de plantear un sistema inteligente para mejorar la detección y verificación del correcto uso de las mascarillas, siendo esta la variable independiente de la investigación. Para este proyecto se propuso tener un estudio detallado de ambas variables por lo cual se consigue libros y artículos científicos de diversos investigadores, como también proyectos y tesis para así tener referencias de problemáticas similares y así considerar los resultados de las soluciones que recomendaron, también obtuvimos gracias a estos estudios una buena base teórica que respaldó esta investigación, de la cual se obtuvo dimensiones e indicadores sustentables. Con todas las informaciones obtenidas se propuso una investigación aplicada pre experimental, ya que este proyecto se implementó y se pudo hacer el contraste del pre y post de los indicadores, por otro lado al ser plenamente conscientes de nuestras variables y el ambiente donde se desarrollaron, nos permitieron poder determinar el universo de personas involucradas en este proyecto, sacando de esta manera la población y muestra representativa; también se determinó el tipo del muestreo a usar y la técnica para recolectar los datos de indicadores cuantitativos, determinar su validez a través de un juicio de especialistas y señalar como se midió la confiabilidad mediante el coeficiente de la correlacional de Pearson. También se decidió el método con el que se examinó los datos de toda la investigación los cuales fueron a través de programa SPSS 25 usando un análisis descriptivo por medio de frecuencias y un análisis inferencial para la prueba de normalidad. Finalmente se estableció los aspectos administrativos de la investigación en el cual se señala los recursos utilizados y el presupuesto que estos originaron, también se define el financiamiento del proyecto y por último se realizó el cronograma de ejecución de la investigación.

### 3.6. Método de análisis de datos

En la presente investigación se usaron las técnicas del programa Statistical Package for the Social Sciences (SPSS 25), para interpretar y realizar un análisis mucho mejor por medio de gráficos los resultados obtenidos. De esta manera, se garantizó una mejor interpretación visual de lo que estaba sucediendo.

Por otro lado, en lo que se refiere a pruebas estadística se empleó la prueba de Kolmogórov-Smirnov, con esta misma se pudo identificar el tipo de distribución de la muestra. Puesto que, esta es ampliamente utilizada en variables cuantitativas continuas y que tienen por lo general un tamaño mayor a 50. En ese sentido, también sirvió para determinar si los datos tienen o no una distribución normal. Siendo este aspecto importante para descifrar los resultados obtenidos.

Finalmente, se usó la prueba en la que se comparó dos mediciones de rangos conocida como Wilcoxon, ya que con esta se pudo hacer una comparación del antes y el después de un grupo que cuenta con desigualdades en la hipótesis (Flores, Miranda y Villasís, 2017). Por otra parte, esta misma prueba se utilizó para medir diferencias entre muestras relacionadas, ofreciendo un nivel de eficiencia entre el 90% a 95% en muestras pequeñas (Badii, Guillen, Araiza, Cerna, Valenzuela y Landeros, 2012). A continuación se describirá las hipótesis estadísticas que se plantearon.

Tabla 3. Prueba de Hipótesis del Indicador 1

INDICADOR 1	
Porcentaje en el nivel de seguridad de las personas	
NsAs, que significa el nivel de seguridad antes de usar el Sistema Inteligente	NsDs, que significa el nivel de seguridad después de usar el sistema Inteligente
HIPÓTESIS	
HE1: Si se usaba el sistema inteligente basado en Deep Learning aumenta el nivel de seguridad en las personas en el supermercado Wong.	
Hipótesis nula	Hipótesis alterna

Hipótesis nula H0: El sistema inteligente no aumenta el nivel de seguridad en las personas en el supermercado Wong.	Hipótesis alterna Ha: El sistema inteligente aumenta el nivel de seguridad en las personas en el supermercado Wong
H0: NsAs ≤ NsDs	Ha: NsAs > NsDs

Fuente: Elaboración propia de los autores

Tabla 4. Prueba de Hipótesis del Indicador 2

INDICADOR 2	
Porcentaje en el nivel de confianza de las personas	
NcAs, que significará el nivel de Confianza antes de usar el sistema Inteligente	NcDs, que significará el nivel Confianza después de usar el sistema Inteligente
HIPÓTESIS	
HE2: Si se usaba el sistema inteligente basado en Deep Learning aumenta el nivel de confianza de las personas para transitar libre y seguramente en el supermercado Wong.	
Hipótesis nula	Hipótesis alterna
Hipótesis nula H0: El sistema inteligente no aumenta el nivel de confianza de las personas para transitar libre y seguramente en el supermercado Wong.	Hipótesis alterna Ha: El sistema inteligente aumenta el nivel de confianza de las personas para transitar libre y seguramente en el supermercado Wong.
Ho : NcAs ≤ NcDs	Ha : NcAs > NcDs

Fuente: Elaboración propia de los autores



Tabla 5. Prueba de Hipótesis del Indicador 3

INDICADOR 3	
Tiempo en la detección y verificación del correcto uso personal de mascarilla.	
TdvAs, que significará Tiempo en la detección y verificación antes de usar el Sistema Inteligente.	TdvDs, que significara Tiempo en la detección y verificación después de usar el Sistema Inteligente.
HIPÓTESIS	
HE3: Si se usaba el sistema inteligente basado en Deep Learning disminuye el tiempo en la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong.	
Hipótesis nula	Hipótesis alterna
Hipótesis nula H0: El sistema inteligente no disminuye el tiempo en la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong.	Hipótesis alterna Ha: El sistema inteligente disminuye el tiempo en la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong.
Ho : TdvAs $\leq$ TdvDs	Ha : TdvAs $>$ TdvDs

Fuente: Elaboración propia de los autores

Tabla 6. Prueba de Hipótesis del Indicador 4

INDICADOR 4	
Porcentaje de rapidez de reacción de las personas	
RrAs, que significará rapidez de reacción antes de usar el sistema Inteligente	RrDs, que significara rapidez de reacción después de usar el sistema Inteligente
HIPÓTESIS	
HE4: Si se usaba el sistema inteligente basado en Deep Learning aumenta la rapidez en la reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong.	

Hipótesis nula	Hipótesis alterna
Hipótesis nula H0: El sistema inteligente no aumenta la rapidez en la reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong.	Hipótesis alterna Ha: El sistema inteligente aumenta la rapidez en la reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong.
Ho : RrAs ≤ RrDs	Ha : RrAs > RrDs

Fuente: Elaboración propia de los autores

### 3.7. Aspectos éticos

Los aspectos éticos pueden definirse como la representación del cumplimiento de valores y principios relacionados con la veracidad de información, procedimientos de recolección de datos y originalidad. Además, se debe tener en cuenta aspectos como la privacidad personal y el bienestar de los individuos que se han integrado a esta investigación (Oliveros y Martínez, 2012). De igual manera es necesario considerar los aspectos éticos de un estudio, ya que a través del cumplimiento de estos, se puede originar un aporte de conocimiento útil para la sociedad (Valderrama, 2012).

Es por ello que de acuerdo a lo establecido en el código ético de investigación de la resolución del consejo universitario n°0126-2017-UCV, se respetarán todos los estándares de responsabilidad y honestidad involucrados en la precisión del conocimiento adquirido. Por consiguiente, se deberá tener presente los derechos intelectuales y el bienestar de los que participantes en la investigación. Por otro lado, los datos obtenidos por los investigadores serán analizados detalladamente antes publicados como resultado del estudio.

Centrándose básicamente en los principios de esta investigación y que se cumpla con los principios éticos, como también respetando los valores propios, que se exigen para mostrar una información precisa y relevante. Asimismo, se van a emplear técnicas e instrumentos de recolección de datos para sistematizar la información ofrecida a los sujetos de estudio, siempre respetando la privacidad y opinión de los mismos.

#### IV. RESULTADOS

En este capítulo se describirá los resultados de todo lo que ha abarcado la investigación presente, utilizando los indicadores de “Nivel de Seguridad de las personas”, “Nivel de confianza de personas”, “Tiempo de detección y verificación de correcto uso de mascarillas” y “Rapidez de reacción de las personas”. Con dichos resultados se pudo determinar el gran efecto que tiene el sistema inteligente basado en Deep Learning para la detección temprana del correcto uso de mascarillas en el contexto covid-19 en el supermercado Wong. Para ello, en el camino del procesamiento de datos e imágenes para entrenar el modelo, se recolectaron datos de un pre-test y post-test usando SPSS que permitió la visualización estadística de cada indicador.

##### 4.1. Pruebas de Normalidad

El funcionamiento de las pruebas de normalidad, se empleó la metodología de Kolmogórov-Smirnov, para los 4 indicadores de estudio. En este caso se utilizó alrededor de 60 casos de ciudadanos residentes cercanamente al shopping center Wong de Plaza San Miguel. De esa manera se tiene lo siguientes indicadores Sig. Usados ampliamente en SPSS:

Sig < 0.05: significa que la prueba de normalidad será “distribución no normal”

Sig > 0.05: significa que la prueba de normalidad será “distribución normal”.

a) Nivel de Seguridad de las personas

- Indicador de nivel de seguridad de personas (PNSP/ Pre-Test):

Para este caso, se utilizaron más de 45 personas para el presente estudio de esta variable, por lo cual es apto para usarse el método de Kolmogórov-Smirnov.

Tabla 7. Normalidad – Prueba de indicador 1.

	Shapiro-Wilk			Kolmogórov-Smirnov		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
<b>Pre_NivelDeSeguridad</b>	0,193	0,60	0,000	0,916	0,60	0,001

Se observa que el Sig. Es muchísimo menor que 0.5, lo cual significa que no se tiene una distribución normal, por lo cual se muestra en el siguiente Figura 2. En dicho grafico se muestra que se tiene un Pre\_NivelDeSeguridad vs Frecuencia,

esta frecuencia significa la calificación que ponen los usuarios antes de conocer el sistema inteligente basado en Deep Learning para la detección temprana de mascarillas en el contexto covid-19. Donde además se muestran las variables estadísticas importantes de desv. Estándar y media

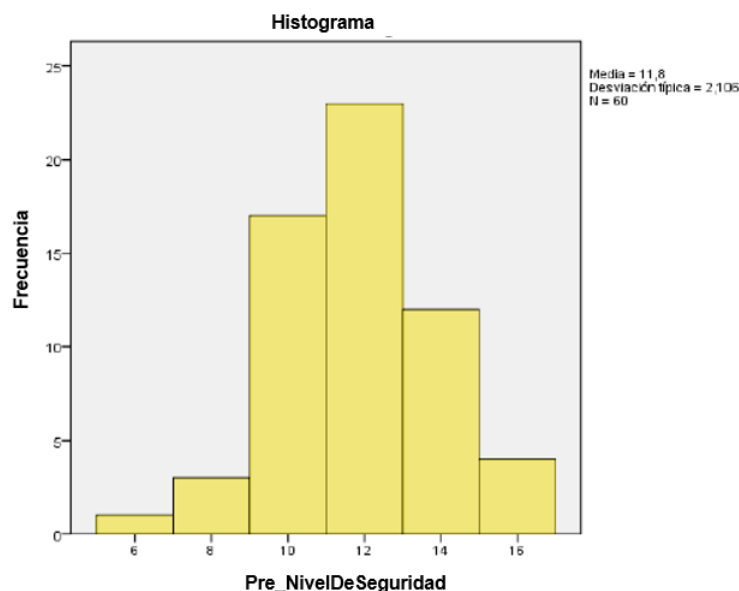


Figura 2. Histograma de Nivel de Seguridad

- Indicador de nivel de seguridad de las Personas (PNSP/Post-Test)

Al igual que el anterior caso, se utilizaron más de 45 personas para el presente estudio de esta variable, por lo cual es apto para usarse el método de Kolmogórov-Smirnov.

Tabla 8. Normalidad – Prueba de indicador 1.

	Shapiro-Wilk			Kolmogórov-Smirnov		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
<b>Post_NivelDeSeguridad</b>	0,21	0,60	0,000	0,905	0,60	0,000

Se observa que el Sig. Es muchísimo menor que 0.5, lo cual significa que no se tiene una distribución normal o no llega a ajustarse a una normalidad, por lo cual se muestra en el siguiente Figura 3. En dicho grafico se muestra que se tiene un Post\_NivelDeConfianza vs Frecuencia, esta frecuencia significa la calificación que ponen los usuarios después de conocer el sistema inteligente basado en Deep Learning para la detección temprana de mascarillas en el

contexto covid-19. Donde además se muestran las variables estadísticas importantes de desv. Estándar y media

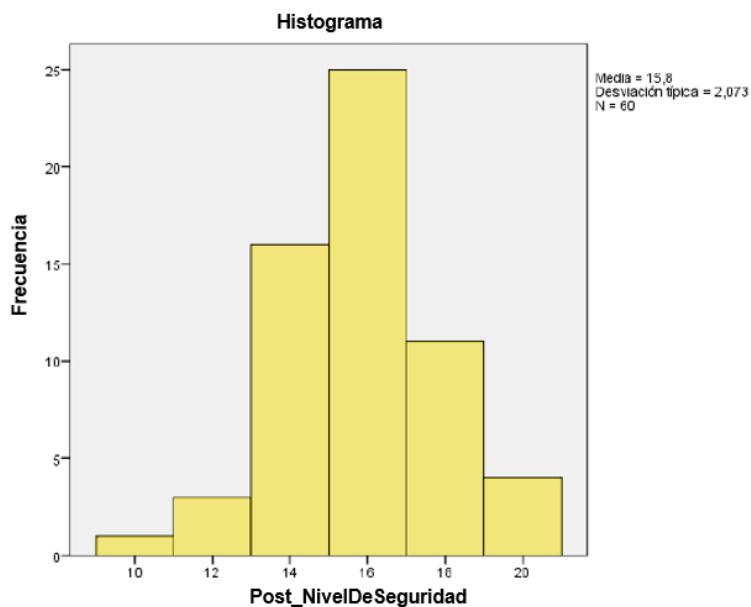


Figura 3. Histograma de Nivel de Seguridad

**b) Indicador de nivel de confianza de personas**

- Indicador de nivel de confianza de personas (PNCP/ Pre-Test):

Para este caso, se utilizaron más de 45 personas para el presente estudio de esta variable, por lo cual es apto para usarse el método de Kolmogórov-Smirnov.

Tabla 9. Normalidad – Prueba de indicador 2

	Shapiro-Wilk			Kolmogórov-Smirnov		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
<b>Pre_NivelDeConfianza</b>	0,224	0,60	0,000	0,875	0,60	0,000

Se observa que el Sig. Es muchísimo menor que 0.5, lo cual significa que no se tiene una distribución normal, por lo cual se muestra en el siguiente Figura 4. En dicho grafico se muestra que se tiene un Pre\_NivelDeConfianza vs Frecuencia, esta frecuencia significa la calificación que ponen los usuarios antes de conocer el sistema inteligente basado en Deep Learning para la detección temprana de

mascarillas en el contexto covid-19. Donde además se muestran las variables estadísticas importantes de desv. Estándar y media




Figura 4. Histograma de Nivel de Confianza

- Indicador de nivel de confianza de personas (PNCP/ Post-Test):

Al igual que el anterior caso, se utilizaron más de 45 personas para el presente estudio de esta variable, por lo cual es apto para usarse el método de Kolmogórov-Smirnov.

Tabla 10. Normalidad – Prueba de indicador 2.

	Shapiro-Wilk			Kolmogórov-Smirnov		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
<b>Post_NivelDeConfianza</b>	0,245	0,60	0,000	0,764	0,60	0,000

Se observa que el Sig. Es muchísimo menor que 0.5, lo cual significa que no se tiene una distribución normal o no llega a ajustarse a una normalidad, por lo cual se muestra en el siguiente Figura 5. En dicho grafico se muestra que se tiene un Post\_NivelDeConfianza vs Frecuencia, esta frecuencia significa la calificación que ponen los usuarios después de conocer el sistema inteligente basado en Deep Learning para la detección temprana de mascarillas en el contexto covid-19. Donde además se muestran las variables estadísticas importantes de desv. Estándar y media

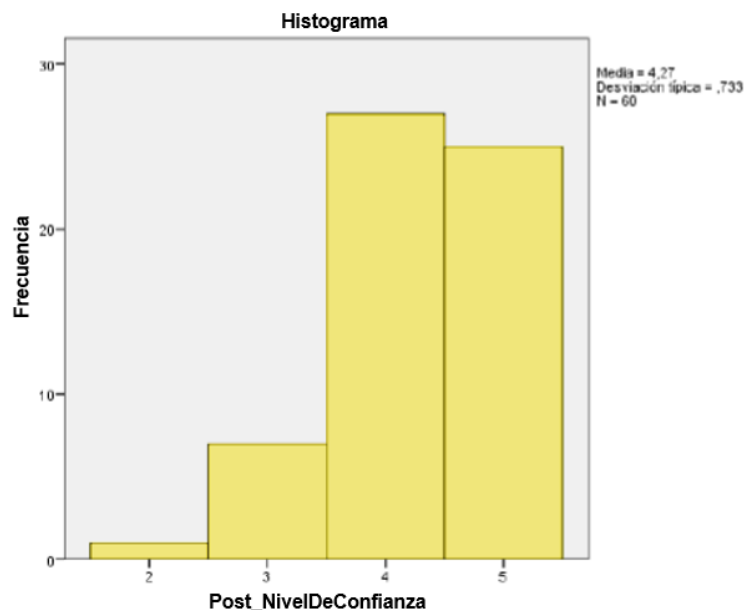


Figura 5. Histograma de Nivel de Confianza

**c) Indicador de tiempo de detección y verificación de correcto uso de mascarillas**

- Indicador de tiempo de detección y verificación de correcto uso de mascarillas (TDVM/ Pre-Test):

Para este caso, se utilizaron más de 45 personas para el presente estudio de esta variable, por lo cual es apto para usarse el método de Kolmogórov-Smirnov.

Tabla 11. Normalidad – Prueba de indicador 3.

	Shapiro-Wilk			Kolmogórov-Smirnov		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
<b>Pre_NivelDeDetecciónMascarilla</b>	0,267	0,60	0,000	0,84	0,60	0,001

Se observa que el Sig. Es muchísimo menor que 0.5, lo cual significa que no se tiene una distribución normal, por lo cual se muestra en el siguiente Figura 6. En dicho grafico se muestra que se tiene un Pre\_NivelDeDetecciónMascarilla vs Frecuencia, esta frecuencia significa la calificación que ponen los usuarios antes de conocer el sistema inteligente basado en Deep Learning para la detección temprana de mascarillas en el contexto covid-19. Donde además se muestran las variables estadísticas importantes de desv. Estándar y media

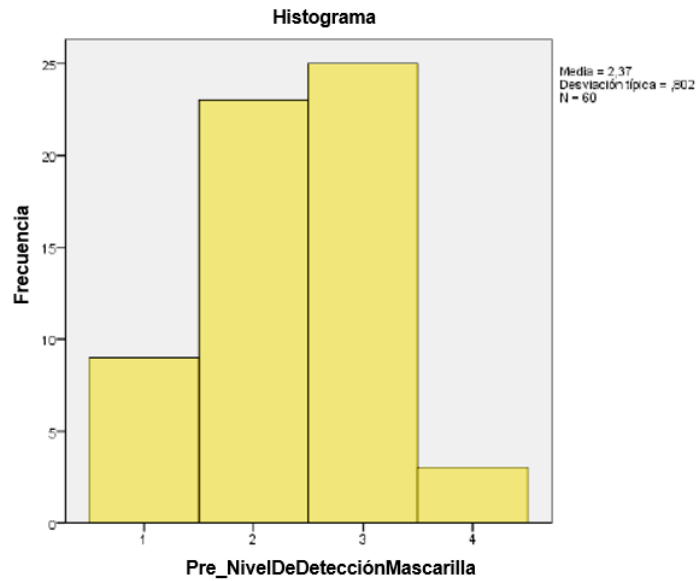


Figura 6. Histograma de Nivel de Detección Mascarilla.

- Indicador de tiempo de detección y verificación de correcto uso de mascarillas (TDVM/ Post-Test):

Al igual que el anterior caso, se utilizaron más de 45 personas para el presente estudio de esta variable, por lo cual es apto para usarse el método de Kolmogórov-Smirnov.

Tabla 12. Normalidad – Prueba de indicador 2.

	Shapiro-Wilk			Kolmogórov-Smirnov		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
<b>Post_NivelDeDetecciónMascarilla</b>	0,275	0,60	0,000	0,786	0,60	0,000

Se observa que el Sig. Es muchísimo menor que 0.5, lo cual significa que no se tiene una distribución normal o no llega a ajustarse a una normalidad, por lo cual se muestra en el siguiente Figura 7. En dicho grafico se muestra que se tiene un Post\_NivelDeDetecciónMascarilla vs Frecuencia, esta frecuencia significa la calificación que ponen los usuarios después de conocer el sistema inteligente basado en Deep Learning para la detección temprana de mascarillas en el contexto covid-19. Donde además se muestran las variables estadísticas importantes de desv. Estándar y media






Figura 7. Histograma de Nivel de Detección de Mascarilla

**d) Indicador de nivel de rapidez de reacción de las personas**

- Indicador de nivel de rapidez de reacción de las personas (PRRP/ Pre-Test):

Para este caso, se utilizaron más de 45 personas para el presente estudio de esta variable, por lo cual es apto para usarse el método de Kolmogórov-Smirnov.

Tabla 13. Normalidad – Prueba de indicador 4.

	Shapiro-Wilk			Kolmogórov-Smirnov		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
<b>Pre_NivelDeRapidezReaccion</b>	0,269	0,60	0,000	0,923	0,60	0,000

Se observa que el Sig. Es muchísimo menor que 0.5, lo cual significa que no se tiene una distribución normal, por lo cual se muestra en el siguiente Figura 8. En dicho grafico se muestra que se tiene un Pre\_NivelDeRapidezReacción vs Frecuencia, esta frecuencia significa la calificación que ponen los usuarios antes de conocer el sistema inteligente basado en Deep Learning para la detección temprana de mascarillas en el contexto covid-19. Donde además se muestran las variables estadísticas importantes de desv. Estándar y media

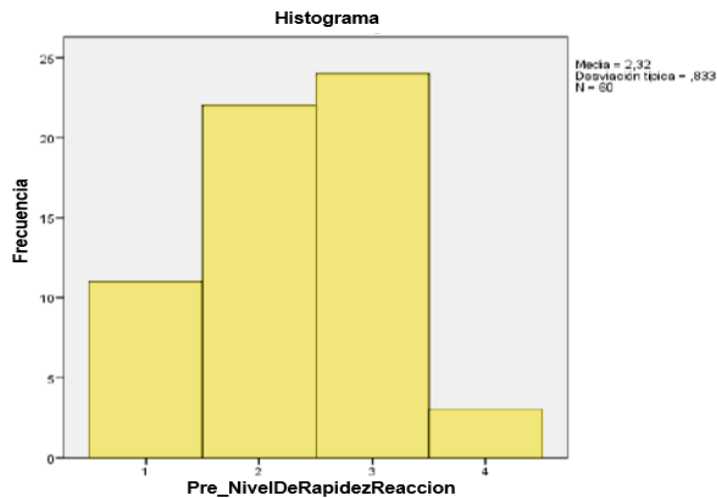


Figura 8. Histograma de Nivel de Rapidez Reacción.

- Indicador de nivel de rapidez de reacción de las personas (PRRP/ Pre-Test):

Al igual que el anterior caso, se utilizaron más de 45 personas para el presente estudio de esta variable, por lo cual es apto para usarse el método de Kolmogórov-Smirnov.

Tabla 14. Normalidad – Prueba de indicador 4.

	Shapiro-Wilk			Kolmogórov-Smirnov		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
<b>Post_NivelDeRapidezReaccion</b>	0,256	0,60	0,000	0,862	0,60	0,000

Se observa que el Sig. Es muchísimo menor que 0.5, lo cual significa que no se tiene una distribución normal o no llega a ajustarse a una normalidad, por lo cual se muestra en el siguiente Figura 9. En dicho grafico se muestra que se tiene un Post\_ NivelDeRapidezReacción vs Frecuencia, esta frecuencia significa la calificación que ponen los usuarios después de conocer el sistema inteligente basado en Deep Learning para la detección temprana de mascarillas en el contexto covid-19. Donde además se muestran las variables estadísticas importantes de desv. Estándar y media

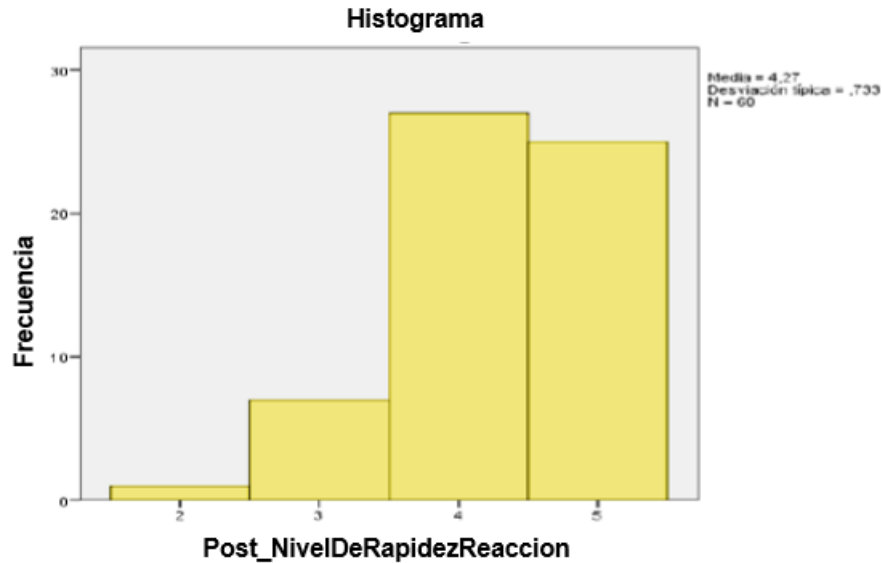


Figura 9. Histograma de Nivel de Rapidez Reacción

#### 4.2. Pruebas de Hipótesis

En este caso se validarán las pruebas de hipótesis planeadas inicialmente, es decir, el HE1, HE2, HE3 y HE4. Esto se realizará debido a que en todos los indicadores se encontraron Significancias mucho menores al estándar establecido de 0.05 en los indicadores de Seguridad, Confianza, Detección de Mascarilals y Rapidez de Reacción. En ese sentido, se usará las pruebas de Wilcoxon de la siguiente manera.

##### A) Uso de Pruebas de Wilcoxon

##### a) Nivel de seguridad de las personas (PNSP)

Tabla 15. Wilcoxon – Prueba de Seguridad.

		N	Suma de Rangos	Rango Promedio
Post_NivelDeSeguridad	Rango Neg.	0 <sup>a</sup>	0,00	0,00
	Rango Pos.	57 <sup>b</sup>	29,00	1653,00
Pre_NivelDeSeguridad	Empates	3 <sup>c</sup>		
Totales		60		

a. Post\_NivelDeSeguridad < Pre\_NivelDeSeguridad

b. Post\_NivelDeSeguridad > Pre\_NivelDeSeguridad

c. Post\_NivelDeSeguridad = Pre\_NivelDeSeguridad

Tabla 16. Contraste Estadístico – Prueba de Seguridad.

	Post_NivelDeSeguridad
	-
	Pre_NivelDeSeguridad
Z	- 6,713 <sup>b</sup>
Sig. Asintót. (bilateral)	0

a. Prueba de rangos con signo de Wilcoxon

b. Basado en rangos negativos

De estos casos se tiene las siguientes situaciones:

**HE1o:** Si se usa el sistema inteligente basado en Deep Learning no aumenta el nivel de seguridad de las personas en el supermercado Wong.

**HE1a:** Si se usa el sistema inteligente basado en Deep Learning aumenta el nivel de seguridad de las personas en el supermercado Wong.

Obtenido estos resultados provenientes de Wilcoxon, existe una gran diferencia entre las pruebas pre\_test y post\_test. Por lo cual, se concluye que se rechaza con un nivel de certeza del 95% la hipótesis nula, y por ende, se acepta la hipótesis alterna.

**b) Nivel de confianza de las personas (PNCP)**

Tabla 17. Wilcoxon – Prueba de Confianza.

		N	Suma de Rangos	Rango Promedio
Post_NivelDeConfianza	Rango Neg.	0 <sup>a</sup>	0,00	0,00
	Rango Pos.	58 <sup>b</sup>	29,45	1708,10
Pre_NivelDeConfianza	Empates	2 <sup>c</sup>		
	Totales	60		

a. Post\_NivelDeConfianza < Pre\_NivelDeConfianza

b. Post\_NivelDeConfianza > Pre\_NivelDeConfianza

c. Post\_NivelDeConfianza = Pre\_NivelDeConfianza

Tabla 22.

Tabla 18. Contraste Estadístico – Prueba de Confianza.

	Post_NivelDeConfianza
	Pre_NivelDeConfianza
Z	- 6,753 <sup>b</sup>
Sig. Asintót. (bilateral)	0

a. Prueba de rangos con signo de Wilcoxon

b. Basado en rangos negativos

De estos casos se tiene las siguientes situaciones:

**HE2o:** Si se usa el sistema inteligente basado en Deep Learning no aumenta el nivel de confianza de las personas para transitar libre y seguramente en el supermercado Wong.

**HE2a:** Si se usa el sistema inteligente basado en Deep Learning aumenta el nivel de confianza de las personas para transitar libre y seguramente en el supermercado Wong.

Obtenido estos resultados provenientes de Wilcoxon, existe una gran diferencia entre las pruebas pre\_test y post\_test. Por lo cual, se concluye que se rechaza con un nivel de certeza del 95% la hipótesis nula, y, por ende, se acepta la hipótesis alterna.

### c) Detección y verificación de uso de mascarillas (TDVM)

Tabla 19. Wilcoxon – Prueba de Detección Mascarilla.

		N	Suma de Rangos	Rango Promedio
Post_NivelDeDeteccionMascarilla	Rango Neg.	0 <sup>a</sup>	0,00	0,00
	Rango Pos.	59 <sup>b</sup>	30,00	1770,00
Pre_NivelDeDeteccionMascarilla	Empates	1 <sup>c</sup>		
	Totales	60		

a. Post\_NivelDeDeteccionMascarilla < Pre\_NivelDeDeteccionMascarilla

b. Post\_NivelDeDeteccionMascarilla > Pre\_NivelDeDeteccionMascarilla

c. Post\_NivelDeDeteccionMascarilla = Pre\_NivelDeDeteccionMascarilla

Tabla 20. Contraste Estadístico – Prueba de Detección Mascarilla.

	<b>Post_NivelDeDeteccion Mascarilla</b> -
	<b>Pre_NivelDeDeteccion Mascarilla</b>
<b>Z</b>	- 6,813 <sup>b</sup>
<b>Sig. Asintót. (bilateral)</b>	0

a. Prueba de rangos con signo de Wilcoxon

b. Basado en rangos negativos

De estos casos se tiene las siguientes situaciones:

**HE3o:** Si se usa el sistema inteligente basado en Deep Learning no disminuye el tiempo en la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong.

**HE3a:** Si se usa el sistema inteligente basado en Deep Learning disminuye el tiempo en la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong.

Obtenido estos resultados provenientes de Wilcoxon, existe una gran diferencia entre las pruebas pre\_test y post\_test. Por lo cual, se concluye que se rechaza con un nivel de certeza del 95% la hipótesis nula, y por ende, se acepta la hipótesis alterna.

#### d) Rapidez de reacción de personas (PRRP)

Tabla 21. Wilcoxon – Prueba de Rapidez Reacción.

		<b>N</b>	<b>Suma de Rangos</b>	<b>Rango Promedio</b>
Post_NivelDeRapidezReaccion	Rango Neg.	0 <sup>a</sup>	0,00	0,00
	Rango Pos.	60 <sup>b</sup>	30,55	1833,00
Pre_NivelDeRapidezReaccion	Empates	0 <sup>c</sup>		
	Totales	60		

a. Post\_NivelDeRapidezReaccion < Pre\_NivelDeRapidezReaccion

b. Post\_NivelDeRapidezReaccion > Pre\_NivelDeRapidezReaccion

c. Post\_NivelDeRapidezReaccion = Pre\_NivelDeRapidezReaccion

Tabla 22. Contraste Estadístico – Prueba de Rapidez Reacción.

	<b>Post_NivelDeRapidezReaccion</b>
	-
	<b>Pre_NivelDeRapidezReaccion</b>
<b>Z</b>	- 6,910 <sup>b</sup>
<b>Sig. Asintót. (bilateral)</b>	0

a. Prueba de rangos con signo de Wilcoxon

b. Basado en rangos negativos

De estos casos se tiene las siguientes situaciones:

**HE4o:** Si se usa el sistema inteligente basado en Deep Learning no aumenta la rapidez de reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong.

**HE4a:** Si se usa el sistema inteligente basado en Deep Learning aumenta la rapidez de reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong

Obtenido estos resultados provenientes de Wilcoxon, existe una gran diferencia entre las pruebas pre\_test y post\_test. Por lo cual, se concluye que se rechaza con un nivel de certeza del 95% la hipótesis nula, y, por ende, se acepta la hipótesis alterna.

## V. DISCUSION

En este capítulo, se procedieron a realizar comparaciones de un contexto previo al desarrollo de un sistema inteligente y otro cuando se implementó el sistema inteligente. En dichos casos, se encontraron muchas diferencias y semejanzas de los 4 indicadores fundamentales descritos inicialmente. Así mismo, se explican las implicancias estadísticas, normalidades con respecto al marco teórico y pruebas de hipótesis. Estas podrán determinar el uso del sistema inteligente y validar su efecto sobre el correcto uso de la mascarilla en el contexto del covid-19.

En un contexto general, el sistema inteligente basado en Deep Learning y computer vision superó con creces todos los indicadores estipulados. Es decir, los índices de seguridad, confianza, detección de mascarilla y rapidez de reacción, obtuvieron buenos puntajes que van en el orden 10.8, 2.23, 2.46 y 3.11 respectivamente. Mientras que los promedios generales oscilaron entre 14.7, 4.16, 4.17 y 4.32 respectivamente. Por lo tanto, con estos índices y lo detallado en la sección de resultados, se puede demostrar que el sistema inteligente incrementa tanto la seguridad, confianza, tiempo de detección de mascarilla y rapidez de reacción respectivamente, por lo cual hace que el sistema sea apto para una buena detección del correcto uso de mascarillas.

De esta manera, y de acuerdo a los resultados presentes, se halló similitudes con autores como Henderi (2020), quien muestra el gran desempeño de su sistema inteligente que usa Deep Learning para detectar mascarillas en el contexto covid-19. El cual muestra el nivel de confianza y seguridad de las personas al momento de circular en entornos cerrados, ya que les permite una sofisticada forma de control para personas con culturas distintas en cuanto al cumplimiento de las normas de distancia y uso obligatorio de mascarillas. Asimismo, Rujula et al. (2021), Evidencia que la rapidez de detección de sus sistemas inteligentes son ampliamente entrenados en diversos contextos para la preservación de la seguridad en todo momento de las personas. De esta manera, se hace en un menor tiempo y con un gran nivel de autonomía, que los sistemas inteligentes tomen decisiones con respecto a las mascarillas. Es así que, ambos autores dan en evidencia el gran nivel y potencial que presentan los sistemas creados con Deep Learning y computer vision para aplicaciones de diversas áreas en el sector



comercial, industrial, minero, etc. Estos resultados son semejantes a lo esperado inicialmente, ya que se esperaba que haya una gran similitud con estudios realizados por dichos autores en cuanto a los indicadores más importantes para salvaguardar la salud de las personas en el contexto covid-19.

De la misma manera, Shilpa, Mamta y Trilok (2021), pone en evidencia que los sistemas inteligentes son ampliamente usados en donde la labor humana carece de precisión y certeza al momento de detectar mascarillas. Esto hace referencia a la capacidad visual de detectar a grandes distancias o cortas distancias a muchas personas a la vez si usan o no mascarillas. Pero el autor plantea que no solo se puede llegar a desarrollar esto, sino que también se puede realizar un tracking de cada persona en un entorno cerrado para validar si continúa usando o no la mascarilla luego de haberlo detectado en una situación inadecuada. En ese sentido, lograr que un sistema inteligente gestione una gran cantidad de personas y valide si usan o no mascarillas, ya es un reto bien difícil y realizarlo hace que las personas confíen más en la capacidad autónoma que tiene que en la capacidad humana limitada. Así mismo, el autor indica que el nivel de seguridad y confianza de ambas partes; es decir, tanto del usuario final como del que compra el dispositivo inteligente, hace que se sientan más seguros porque el margen de error es cero y la precisión es muy alta comparado a la capacidad humana.

Finalmente, el estudio presente demostró la viabilidad de la detección del correcto uso de mascarillas en el contexto del covid-19 aplicado en lugares cerrados como en Wong. Donde de los datos recolectados, se logró validar que en las personas el índice de confianza y seguridad son altísimos tanto, así como la rapidez de reacción y el tiempo de detección. Dichos indicadores hacen que el sistema sea válido en cualquier contexto planteado por el uso de mascarillas en lugares con una gran concurrencia de personas.

## **VI. CONCLUSIONES**

En este capítulo se plantean las conclusiones con respecto a las hipótesis planteadas inicialmente. De esta manera, se tiene lo siguiente:

1. Con respecto a lo obtenido en la sección de resultados, la implementación de un sistema inteligente basado en Deep Learning y computer vision para la detección del correcto uso de mascarillas en Wong tuvo un incremento y validez sustancial, ya que se mejoró en cuando al promedio esperado de seguridad.
2. Con respecto a la confianza, se demuestra que el sistema inteligente tiene un gran impacto en la aceptación de los usuarios para concurrir a lugares cerrados y que no se contagien de covid-19. Este incremento se valida en los resultados.
3. El nivel de rapidez de detección del uso de mascarillas personales, ha incrementado con respecto a un pre\_test. Esto ya que un sistema inteligente con capacidades de Deep Learning hace que pueda detectar muchas mascarillas a la vez, brindando de esta manera la capacidad de detectar muchas mascarillas en menor tiempo.
4. La rapidez de reacción de las personas, incrementaron cuando se implementó una alarma sonora para que puedan mantener la distancia unos con otros. Esto con el fin de que las personas sepan que pueden estar expuestas al peligro, por lo cual, ha tenido una gran aceptación de los usuarios y los resultados lo validan.

## VII. RECOMENDACIONES

En esta sección se realizarán algunas recomendaciones generales de la investigación planteada inicialmente. En ese sentido, se recomienda lo siguiente:

1. Se recomienda principalmente aumentar el tamaño de la muestra que se adjuntó inicialmente, esto con el fin de que exista una mayor exactitud en los resultados y por consecuencia sean más aceptados en la validación experimental. De la misma manera, un diseño completamente experimental sería lo ideal, ya que, para el caso presente, se tuvo que pedir permiso a muchas entidades para acceder con las grabaciones, pero hubo rechazos y otros temas legales conforme a ley. En ese sentido, se prefiere ampliar el tamaño de muestra con personas a quienes se les pueda recompensar por la colaboración si se acepta un diseño experimental.
2. En cuanto al sistema inteligente, si bien detecta a muchas personas en el entorno, también es necesario que se pueda adquirir una buena cámara con una gran resolución para que evidencie y observe el entorno a gran precisión. Esto ya que no es lo mismo usar una cámara de 720píxeles a una de 4K de resolución, con la segunda opción todo sería más preciso, pero el costo sería mucho mayor.
3. Si se pretende realizar un modelo basado en Deep Learning y Computer Vision, es necesario que la CPU o entorno de desarrollo cuente con una tarjeta gráfica potente, ya que, con una normal, el entrenamiento del modelo puede llevar muchas horas o incluso muchos días de entrenamiento, por lo cual, es necesario que se tome dichas precauciones. En ese caso, se recomienda utilizar computadoras gamer.
4. Se recomienda que este sistema inteligente no solo sea útil en el contexto de supermercados, sino que también se puede llevar a lugares bastante concurridos como, por ejemplo, conciertos, estadios, iglesias, buses de transporte público, etc. Con el fin de tener un control total sobre el uso de mascarillas en un contexto de covid-19.

## REFERENCIAS

- ADHIKARLA, E. y DAVISON, B., 2021. Detección de máscara facial en imágenes de cámara web del mundo real. [en línea], ISSN 978-1-4503-8478-0. Disponible en: <https://dl.acm.org/doi/pdf/10.1145/3462203.3475903>.
- AGUILAR, L., IBAÑEZ, M., AGUILAR, J., ZAVALA, E. y AGUILAR, A., 2020. Forecasting SARS-CoV-2 in the peruvian regions: a deep learning approach using temporal convolutional neural networks. , vol. 8, pp. 12. ISSN 2411-1783.
- ARAVINDPAI, P., 2020. CNN vs. RNN vs. ANN – Analyzing 3 Types of Neural Networks in Deep Learning. [en línea], Disponible en: <https://www.analyticsvidhya.com/blog/2020/02/cnn-vs-rnn-vs-mlp-analyzing-3-types-of-neural-networks-in-deep-learning/>.
- BARRETO, R. y LIZARRAGA, D., 2019. *Modelo de Sistema de Reconocimiento Facial para el Control de la Trata de Personas* [en línea]. Arequipa - Perú: UNIVERSIDAD TECNOLÓGICA DEL PERU. Disponible en: [https://repositorio.utp.edu.pe/bitstream/handle/20.500.12867/2063/Robert%20Barreto\\_David%20Lizarraga\\_Tesis\\_Titulo%20Profesional\\_2019.pdf?sequence=1&isAllowed=y](https://repositorio.utp.edu.pe/bitstream/handle/20.500.12867/2063/Robert%20Barreto_David%20Lizarraga_Tesis_Titulo%20Profesional_2019.pdf?sequence=1&isAllowed=y).
- BESOFTWARE, 2019. ¿QUÉ ES C# Y PARA QUÉ SIRVE? [en línea], Disponible en: <https://bsw.es/que-es-c/>.
- CADENA, J.A., 2021. *Técnica eficiente para reconocimiento facial global utilizando wavelets y máquinas de vectores de soporte en imágenes 3D* [en línea]. Lima-Perú: Universidad Nacional Mayor de San Marcos. Disponible en: [https://cybertesis.unmsm.edu.pe/bitstream/handle/20.500.12672/16552/Cadena\\_mj.pdf?sequence=1&isAllowed=y](https://cybertesis.unmsm.edu.pe/bitstream/handle/20.500.12672/16552/Cadena_mj.pdf?sequence=1&isAllowed=y).
- CASAS, J., REPULLO, J.R. y DONADO, J., 2003. La encuesta como técnica de investigación. Elaboración de cuestionarios y tratamiento estadístico de los datos (I). , pp. 12.

- DÍAZ, S. y GONZÁLES, S., 2010. REFLEXIONES SOBRE LOS CONCEPTOS VELOCIDAD Y RAPIDEZ DE UNA PARTÍCULA EN FÍSICA. , pp. 9.
- ELIAS, J., ROJAS, A., ROJAS, L.M., ALFARO, M., USCAMAYTA, R. y GAMARRA, A., 2021. Aplicación del deep learning para el reconocimiento facial con la presencia de oclusiones en el contexto de la pandemia covid 2021. , vol. 18, pp. 8.
- ESCALANTE, D., 2019. Raspberry pi: la tecnología reducida en placa. , pp. 13.
- FERNÁNDEZ, J.P., 2005. *SEGURIDAD HUMANA* [en línea]. BARCELONA: UNIVERSIDAD AUTONOMA DE BARCELONA. Disponible en: [https://www.iidh.ed.cr/multic/UserFiles/Biblioteca/IIDHSeguridad/12\\_2010/d540f1cb-719b-4b49-95b1-f61a7faa7ab2.pdf](https://www.iidh.ed.cr/multic/UserFiles/Biblioteca/IIDHSeguridad/12_2010/d540f1cb-719b-4b49-95b1-f61a7faa7ab2.pdf).
- HENDERI, 2020. An Application of Mask Detector For Prevent Covid-19 in Public Services Area. [en línea], Disponible en: <https://iopscience.iop.org/article/10.1088/1742-6596/1641/1/012063/pdf>.
- HERNANDEZ SAMPIERI, R., FERNANDEZ COLLADO, C. y BAPTISTA LUCIO, P., 2014. *METODOLOGIA DE LA INVESTIGACION* [en línea]. SEXTA. MEXICO: s.n. ISBN 978-1-4562-2396-0. Disponible en: <https://www.uca.ac.cr/wp-content/uploads/2017/10/Investigacion.pdf>.
- IBM, 2020. Neural Networks. [en línea], Disponible en: <https://www.ibm.com/cloud/learn/neural-networks>.
- LA MADRID, D. y BARRIGA, M., 2019. *Modelo Tecnológico de Reconocimiento Facial para la Identificación de Pacientes en el Sector Salud* [en línea]. Lima-Perú: UNIVERSIDAD PERUANA DE CIENCIAS APLICADAS. Disponible en: [https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/648832/La%20Madrid\\_ad.pdf?sequence=3&isAllowed=y](https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/648832/La%20Madrid_ad.pdf?sequence=3&isAllowed=y).
- LOPEZ, A., 2012. Teoría de la Información. [en línea]. Mexico. Disponible en: [https://www.uv.mx/personal/artulopez/files/2012/08/02\\_TS-y-TI.pdf](https://www.uv.mx/personal/artulopez/files/2012/08/02_TS-y-TI.pdf).

- MAHDI, R. y MOHSEN, A., 2020. DeepSOCIAL: Monitoreo del distanciamiento social y evaluación del riesgo de infección en la pandemia COVID-19. [en línea], Disponible en: <https://arxiv.org/pdf/2008.11672.pdf>.
- MARTINEZ, G., 2013. La inteligencia artificial y su aplicación al campo de derecho. [en línea], Disponible en: <https://www.corteidh.or.cr/tablas/r30570.pdf>.
- MBUNGE, E., SIMELANE, S., FASHOTO, S. y AKINNUWESI, B., 2020. Aplicación de modelos de aprendizaje profundo y aprendizaje automático para detectar máscaras faciales COVID-19. , pp. 245. ISSN 2666-4127.
- MERINO, M., 2020. Así puedes aprender a usar PyTorch, la herramienta más accesible para crear redes neuronales. [en línea], Disponible en: <https://www.genbeta.com/desarrollo/asi-puedes-aprender-a-usar-pytorch-herramienta-accesible-para-crear-redes-neuronales>.
- MINISTERIO DE SALUD, 2021. Uso correcto de las mascarillas contribuirá a desacelerar la propagación de la COVID-19. [en línea]. S.l.: Disponible en: <https://www.gob.pe/institucion/minsa/noticias/326528-uso-correcto-de-las-mascarillas-contribuira-a-desacelerar-la-propagacion-de-la-covid-19>.
- MIRA, B., 2021. *Facial Recognition and Face Mask Detection Using Machine Learning Techniques* [en línea]. Montclair, New Jersey: MONTCLAIR STATE UNIVERSITY. Disponible en: <https://digitalcommons.montclair.edu/cgi/viewcontent.cgi?article=1729&context=etd>.
- MUÑOZ, G., 2016. Deep learning con TensorFlow. [en línea]. S.l. Disponible en: [http://www.cs.us.es/~fsancho/ficheros/IAML/2016/Sesion07/seminario\\_tensorflowGabi.pdf](http://www.cs.us.es/~fsancho/ficheros/IAML/2016/Sesion07/seminario_tensorflowGabi.pdf).
- NIZAMA, A., 2021. Covid-19 en el Perú: aumentan casos de ansiedad y depresión. [en línea], Disponible en: <https://www.usil.edu.pe/noticias/covid-19-en-el-peru-aumentan-casos-de-ansiedad-y-depresion>.

- NUÑEZ, R., 2018. *LA NOCIÓN DE TIEMPO EN LA CIENCIA ACTUAL Y SU RELACIÓN CON LA CAUSACIÓN*. [en línea]. Argentina: UNIVERSIDAD NACIONAL DE LA PLATA. Disponible en: <https://memoria.fahce.unlp.edu.ar/tesis/te.1565/te.1565.pdf>.
- OMS, 2020. *RECOMENDACIONES SOBRE EL USO DE MASCARILLAS EN EL CONTEXTO DE LA COVID-19* [en línea]. 5 junio 2020. S.l.: s.n. Disponible en: [https://apps.who.int/iris/bitstream/handle/10665/332657/WHO-2019-nCov-IPC\\_Masks-2020.4-spa.pdf](https://apps.who.int/iris/bitstream/handle/10665/332657/WHO-2019-nCov-IPC_Masks-2020.4-spa.pdf).
- OPPERMANN, A., 2019. What is Deep Learning and How does it work? [en línea], Disponible en: <https://towardsdatascience.com/what-is-deep-learning-and-how-does-it-work-2ce44bb692ac>.
- PEREIRA, A., 2021. *Aplicación de inteligencia artificial para monitorear el uso de mascarillas de protección* [en línea]. BRASIL: s.n. ISBN 1900-6586. Disponible en: <http://www.scielo.org.co/pdf/recig/v19n33/2500-7645-recig-19-33-205.pdf>.
- PITALÚA, N., 2009. *Introducción a los sistemas inteligentes* [en línea]. Bolfeta y Asociados S.C. Mexico: Editorial Universitaria de la Secretaría de Rectoría e Imagen Institucional de la Universidad Autónoma de Baja California. ISBN 978-607-7753-47-6. Disponible en: [file:///C:/Users/USUARIO/Downloads/SISTEMAS\\_INTELIGENTESconISBN.pdf](file:///C:/Users/USUARIO/Downloads/SISTEMAS_INTELIGENTESconISBN.pdf).
- QUIROZ, F., 2020. Mascarillas quirúrgicas a propósito del COVID-19: Algunos aspectos técnicos. [en línea], Disponible en: <http://www.scielo.org.co/pdf/rcci/v35n2/2619-6107-rcci-35-02-00200.pdf>.
- RAE, 2020. Uso Personal. [en línea]. Disponible en: <https://dle.rae.es/personal?m=form>.
- RAMIREZ, A., 2019. *UN ALGORITMO DE DETECCIÓN Y VALIDACIÓN DE ROSTROS EN ENTORNOS NO CONTROLADOS ORIENTADO AL MONITOREO BIOMÉTRICO DE CONDUCTORES VEHICULARES* [en

- línea]. Lima-Perú: Universidad Nacional de Ingeniería. Disponible en: [http://cybertesis.uni.edu.pe/bitstream/uni/19928/1/ramirez\\_pa.pdf](http://cybertesis.uni.edu.pe/bitstream/uni/19928/1/ramirez_pa.pdf).
- RIYA, C. y RUTVA, J., 2020. Detection of Face Mask using Convolutional Neural Network. [en línea], ISSN 1532-0464. Disponible en: <https://arxiv.org/ftp/arxiv/papers/2106/2106.05728.pdf>.
- ROBLEADO, Á., 2019. QUÉ ES C++: CARACTERÍSTICAS Y APLICACIONES. [en línea], Disponible en: <https://openwebinars.net/blog/que-es-cpp/>.
- RPP, 2020. Tres trabajadores de Wong dieron positivo a prueba de la COVID-19. [en línea]. 15 abril 2020. Disponible en: <https://rpp.pe/lima/actualidad/coronavirus-en-peru-tres-trabajadores-de-wong-dieron-positivo-a-prueba-de-la-covid-19-noticia-1258723?ref=rpp>.
- RUJULA, S., NIKHIL, N., SAHANA, S. y RUCHITA, R.B., 2021. COVID-19 Monitoring System using Social Distancing and Face Mask Detection on Surveillance video datasets. [en línea], Disponible en: <https://arxiv.org/ftp/arxiv/papers/2110/2110.03905.pdf>.
- SALAZAR, C. y DEL CASTILLO, S., 2018. *FUNDAMENTOS BÁSICOS DE ESTADÍSTICA* [en línea]. Primera. S.l.: s.n. ISBN 978-9942-30-616-6. Disponible en: <http://www.dspace.uce.edu.ec/bitstream/25000/13720/3/Fundamentos%20B%C3%A1sicos%20de%20Estad%C3%ADstica-Libro.pdf>.
- SCHWARZ, M., 2017. Guía de referencia para la elaboración de una investigación aplicada. , pp. 30.
- SHILPA, S., MAMTA, K. y TRILOK, K., 2021. Face mask detection using deep learning: An approach to reduce risk of Coronavirus spread. [en línea], Disponible en: <https://reader.elsevier.com/reader/sd/pii/S1532046421001775?token=573EB97DB6755FF1AD2C95A0A84445201F673BA00C5A5362410C1FE2B4EBD427739A0E634244EA268554513EC1D03C32&originRegion=us-east-1&originCreation=20211115235430>.



TORRES, K. y SEVILLA, E., 2009. Conceptos para la selección y uso de mascarillas y respiradores, como medidas de protección durante los brotes de influenza. [en línea], vol. 22. Disponible en: <https://www.medigraphic.com/pdfs/iner/in-2009/in093j.pdf>.

ÚBEDA, B., 2009. Sistemas embebidos. , pp. 30.

VÁSQUEZ, G., 2019. Introducción a Python. [en línea], Disponible en: [http://cdr.ing.unlp.edu.ar/files/presentaciones/012\\_Introduccion%20a%20Python.pdf](http://cdr.ing.unlp.edu.ar/files/presentaciones/012_Introduccion%20a%20Python.pdf).

VENABLES, M., 2019. An Overview of Computer Vision. [en línea], Disponible en: <https://towardsdatascience.com/an-overview-of-computer-vision-1f75c2ab1b66>.

VIERA, G., 2017. *Procesamiento de Imágenes usando OpenCV aplicado en Raspberry Pi para la Clasificación del cacao* [en línea]. Piura: Universidad de Piura. Disponible en: [https://pirhua.udep.edu.pe/bitstream/handle/11042/2916/IME\\_218.pdf](https://pirhua.udep.edu.pe/bitstream/handle/11042/2916/IME_218.pdf).

VOULODIMOS, A., DOULAMIS, N., DOULAMIS, A. y PROTOPAPADAKIS, E., 2018. Deep Learning for Computer Vision: A Brief Review. En: D. ANDINA (ed.), *Computational Intelligence and Neuroscience*, vol. 2018, pp. 7068349. ISSN 1687-5265. DOI 10.1155/2018/7068349.

YAÑEZ, R., AHUMADA, L. y COVA, F., 2006. CONFIANZA Y DESCONFIANZA: DOS FACTORES NECESARIOS PARA EL DESARROLLO DE LA CONFIANZA SOCIAL. , pp. 13. ISSN 1657-9267.

## **ANEXOS**

## Anexo N°01 Desarrollo de Metodología Deep Learning

Tal como se detalló en la sección 3.8 que abarca la metodología seleccionada que es la de Deep Learning debido a que es altamente compatible con proyectos grandes vinculados a Computer Vision. En ese sentido, se procederá a seguir las etapas de la metodología en mención:

### 1. Adquisición de Imágenes:

En esta sección es muy importante a tomar en cuenta que se necesita una gran cantidad de imágenes referidas a la necesidad del proyecto; es decir, se necesitará tener imágenes donde haya personajes usando mascarillas y en otras donde no hagan uso de estas. En ese sentido, se ejemplifica en la siguiente Figura 5.

Compartir Vista

> Este equipo > Escritorio > PRUEBAS FUNCIONALES > face-mask-detection-keras-master > dataset

Nombre	Fecha de modificación	Tipo	Tamaño
with_mask	24/10/2021 15:57	Carpeta de archivos	
without_mask	24/10/2021 15:57	Carpeta de archivos	

Figura 10. Separación de Dataset para el entrenamiento

Dentro de cada carpeta se almacenará imágenes de acuerdo al nombre de la carpeta. En la primera y en la segunda hay 690 imágenes para el entrenamiento, tal como se muestra en la siguiente Figura 6.



Figura 11. (a) Dataset: without\_mask. (b) Dataset: with\_mask.

## 2. Procesamiento de Imágenes y extracción de características customizadas:

En esta sección se abarcará la extracción de características necesarias dentro de las imágenes mediante la implementación de programación en Python y OpenCV. Este paso se debe realizar siempre y cuando ya se cuente con todo el arsenal de imágenes necesarias. En ese sentido, es necesario contar con el dataset de imágenes balanceadas, entendiéndose éstas como adquirir cantidades iguales de imágenes con mascarillas y sin mascarilla. Esto con el fin de que, durante el entrenamiento con las redes neuronales convolucionales, no exista un favoritismo uno de otro, es decir, que el sistema aprenda a diferenciar o discernir en el contexto real del uso de mascarillas.

De esa manera, el procesamiento implica extraer las características necesarias en la forma binaria de una imagen, es decir, deberá ser una imagen en blanco o negro tal como se muestra en la Figura 7. Donde en esta, la mascarilla ha sido detectada en forma binaria, lo facilita los trabajos posteriores en entrenamiento con redes neuronales.



*Figura 12. Obtención final de la detección después del procesamiento de imágenes*

### 3. Segmentación semántica de Imágenes:

En esta sección, luego de haber identificado la zona de la mascarilla en el procesamiento de imágenes, ahora se realizará la segmentación semántica, la cual consiste en pintar las zonas de interés en la imagen para determinar y etiquetar las características necesarias. De este modo, permitiendo la sensibilidad en la detección de lo necesario en un video o en tiempo real funcionando a través de las cámaras de seguridad con conexión USB. Por otro lado, en el sentido de realizar cada extracción de los equipamientos necesarios dentro de la zona de la cara, es necesario para que, durante el entrenamiento, las redes neuronales aprendan qué zona es más importante detectar y, a partir de estas, tomar decisiones de si usan o no correctamente las mascarillas como medio de seguridad de salud regida por la OMS.

Es de esa manera que lo mencionado líneas arriba, quedarían representadas bajo la siguiente imagen mostrada de la Figura 8.




Figura 13. Extracción de características necesarias

#### 4. Modelamiento en IA:

En esta sección, luego de haber realizado el procesamiento, extracción de características y segmentación semántica, se procede a realizar el entrenamiento con las 64 redes neuronales descritas líneas abajo. Esto con el fin de que se pueda extraer las zonas de interés y el sistema aprenda a detectar dichas zonas para que luego pueda tomar decisiones autónomas.

De esta manera, en la siguiente Figura 9 se muestra la arquitectura usada para el desarrollo de la red neuronal.

```
Model: "sequential_2"
```

Layer (type)	Output Shape	Param #
conv2d_3 (Conv2D)	(None, 98, 98, 200)	2000
activation_3 (Activation)	(None, 98, 98, 200)	0
max_pooling2d_3 (MaxPooling2D)	(None, 49, 49, 200)	0
conv2d_4 (Conv2D)	(None, 47, 47, 100)	180100
activation_4 (Activation)	(None, 47, 47, 100)	0
max_pooling2d_4 (MaxPooling2D)	(None, 23, 23, 100)	0
flatten_2 (Flatten)	(None, 52900)	0
dropout_2 (Dropout)	(None, 52900)	0
dense_3 (Dense)	(None, 50)	2645050
dense_4 (Dense)	(None, 2)	102

```
Total params: 2,827,252  
Trainable params: 2,827,252  
Non-trainable params: 0
```

Figura 14. Extracción de características necesarias

## 5. Creación de Boundingbox para la mascarilla:

En esta sección se presentará, las señales de detección basada en cuadros con mensajes de lo que está sucediendo. En este caso, se presenta lo siguiente. En la Figura 10, se visualiza el boundingbox que muestra con un mensaje y color si el presente tesista usa o no la mascarilla correctamente, de esta manera se evidencia el suceso acontecido en tiempo real.



Figura 15. (a). Usando la Mascarilla. (b) No usando la Mascarilla.

Del mismo modo, para validar los resultados, se presenta el mismo suceso con la segunda tesista. En este caso, también usando la mascarilla correcta e incorrectamente, tal como se muestra en la Figura 11.




Figura 16. (a). Usando la Mascarilla. (b) No usando la Mascarilla.

## 6. Análisis de Errores Durante el Entrenamiento:

En esta sección se presentarán los resultados y performance obtenidos durante el entrenamiento de las redes neuronales convolucionales. En ese sentido, lo que se busca es un menor error y una mayor precisión. En la Figura 12 se puede observar la evolución del error durante el entrenamiento del modelo, logrando obtener un error dentro del 0.0% y 0.1% lo cual es bastante bueno para el desarrollo.

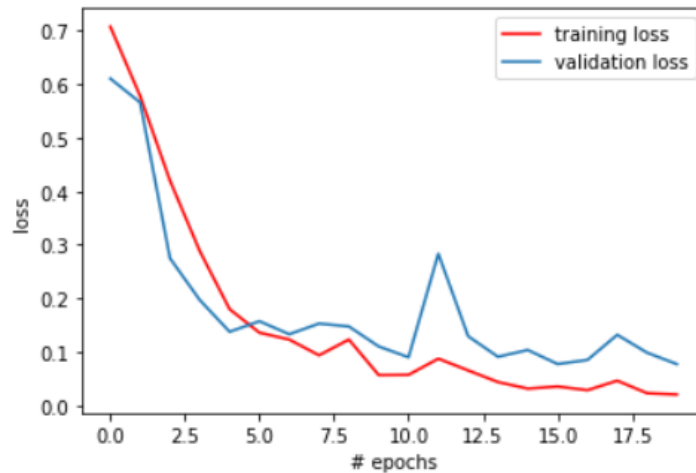


Figura 17. Evolución en la reducción de error en el tiempo

Así mismo, es necesario evaluar que tan preciso es el modelo al momento de realizar el entrenamiento, esto se puede evidenciar en la Figura 13 donde se visualiza el incremento de precisión en el tiempo. Esto se puede apreciar que llega al 0.95 o 1 de precisión, donde 1 es el máximo. Por lo cual, se concluye que el modelo en Deep Learning es bastante bueno.




Figura 18. Evolución de la precisión en el tiempo



## 7. Análisis y simulación en rea-time:

En esa sección, luego de entrenada el modelo tal como se muestra en el Anexo 04, se optimiza y ensambla con el nuevo modelo mostrado en el Anexo 05. En este se tiene los siguientes resultados evidenciados con la simulación en campo mostrada a continuación.




Figura 19.a), (b), (c) y (d). Son los resultados que se ejecutan en tiempo real usando el modelo con alarma incluida si usa o no mascarilla.

Estos resultados evidencian que el modelo es más robusto y, además, ¡se incluye la alarma visual como lo es un foco de color verde y rojo con un texto que señala “PASE!”, el cual hace referencia a que, en la entrada de Wong, el cliente pueda acceder a las instalaciones. Caso contrario se mostrará el mensaje “ALERTA” que hace referencia que no se está usando correctamente la mascarilla al entrar a Wong. Por lo cual, en este último mensaje, se tiene que tomar acciones correctivas a fin de que se pueda llevar un mejor control del uso de mascarillas y por ende evitar contagios de covid-19.



## Anexo N°02 - Códigos en Python del Desarrollo de la Metodología

### a. Procesamiento Inicial de Todas las Imágenes del Dataset

```
import cv2,os

data_path='dataset'
categories=os.listdir(data_path)
labels=[i for i in range(len(categories))]

label_dict=dict(zip(categories,labels)) #creamos un Diccionario limpio

print(label_dict)
print(categories)
print(labels)

img_size=100
data=[]
target=[]

#####

for category in categories:
    folder_path=os.path.join(data_path,category)
    img_names=os.listdir(folder_path)

    for img_name in img_names:
        img_path=os.path.join(folder_path,img_name)
        img=cv2.imread(img_path)

        try:
            gray=cv2.cvtColor(img,cv2.COLOR_BGR2GRAY)
            #Convertiremos las imagenes RGB a escala de grises para mayor facilidad de procesamiento
            resized=cv2.resize(gray,(img_size,img_size))
            #Reescalamos las imagenes a 50x50 a todas las imagenes
            data.append(resized)
            target.append(label_dict[category])
            #agregamos las imagenes en su categoria en la lista de imagenes

        except Exception as e:
            print('Exception:',e)
            #si existe alguna excepcion o problema, se enlista aqui y se pasa a la siguiente imagen

#####

import numpy as np

#Convertiremos las imagenes de 0 a 1, es decir, las estandarizamos
data=np.array(data)/255.0
data=np.reshape(data,(data.shape[0],img_size,img_size,1))
target=np.array(target)

from keras.utils import np_utils

new_target=np_utils.to_categorical(target)

#####

np.save('data',data)
np.save('target',new_target)
```

## b. Entrenamiento de la Red Neuronal y Evaluación de Performance

```
#Cargamos los arreglos numpy guardados anteriormente
import numpy as np

data=np.load('data.npy')
target=np.load('target.npy')

#####

from keras.models import Sequential
from keras.layers import Dense,Activation,Flatten,Dropout
from keras.layers import Conv2D,MaxPooling2D
from keras.callbacks import ModelCheckpoint

model=Sequential()

model.add(Conv2D(200,(3,3),input_shape=data.shape[1:]))
model.add(Activation('relu'))
model.add(MaxPooling2D(pool_size=(2,2)))
#La primera capa CNN seguido de capas ReLu y Maxpooling

model.add(Conv2D(100,(3,3)))
model.add(Activation('relu'))
model.add(MaxPooling2D(pool_size=(2,2)))
# Segunda capa CNN seguido de capas ReLu y Maxpooling

model.add(Flatten())
model.add(Dropout(0.5))
# Aplanar la capa para apilar las convoluciones de
# salida de la segunda capa de convolución

model.add(Dense(50,activation='relu'))
#Capa Densidad con 64 Neuronas

model.add(Dense(2,activation='softmax'))
#Las 2 salidas para las 2 categorias:
# NO usa Mascarilla, SÍ usa Mascarilla

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

#####

# Separamos la data de entrenamiento y testeo
from sklearn.model_selection import train_test_split

train_data,test_data,train_target,test_target=train_test_split(data,target,test_size=0.1)

#####

#Entrenamiento con las Redes Neuronales Convolucionales
checkpoint = ModelCheckpoint('model-{epoch:03d}.model',monitor='val_loss',verbose=0,save_best_only=True,mode='auto')
history=model.fit(train_data,train_target,epochs=20,callbacks=[checkpoint],validation_split=0.2)

#####

#Visualizacion de Error
from matplotlib import pyplot as plt

plt.plot(history.history['loss'],'r',label='training loss')
plt.plot(history.history['val_loss'],label='validation loss')
plt.xlabel('# epochs')
plt.ylabel('loss')
plt.legend()
plt.show()

#####

#Visualizacion de Precision
plt.plot(history.history['accuracy'],'r',label='training accuracy')
plt.plot(history.history['val_accuracy'],label='validation accuracy')
plt.xlabel('# epochs')
plt.ylabel('accuracy')
plt.legend()
plt.show()

#####

#Evaluacion de modelo
print(model.evaluate(test_data,test_target))
```

### c. Despliegue y Detección de Mascarilla en tiempo real

```
# Cargamos las librerias
from keras.models import load_model
import cv2
import numpy as np

#####

#Se carga uno de los modelos generados durante el entrenamiento de CNN
model = load_model('model-003.model')

face_clsfr=cv2.CascadeClassifier('haarcascade_frontalface_default.xml')

source=cv2.VideoCapture(0)

labels_dict={0:'NOT USING MASK',1:'USING MASK'}
color_dict={0:(0,0,255),1:(0,255,0)}

#####

#Despliegue en Real-Time de la detección de Mascarillas
while(True):

    ret,img=source.read()
    gray=cv2.cvtColor(img,cv2.COLOR_BGR2GRAY)
    faces=face_clsfr.detectMultiScale(gray,1.3,5)

    for (x,y,w,h) in faces:

        face_img=gray[y:y+w,x:x+w]
        resized=cv2.resize(face_img,(100,100))
        normalized=resized/255.0
        reshaped=np.reshape(normalized,(1,100,100,1))
        result=model.predict(reshaped)

        label=np.argmax(result,axis=1)[0]

        #Se crean los BoundingBoxes para detectar la zona de mascarilla en la cara
        cv2.rectangle(img,(x,y),(x+w,y+h),color_dict[label],2)
        cv2.rectangle(img,(x,y-40),(x+w,y),color_dict[label],-1)
        cv2.putText(img, labels_dict[label], (x, y-10),cv2.FONT_HERSHEY_SIMPLEX,0.8,(
255,255,255),2)

    cv2.imshow('LIVE',img)
    key=cv2.waitKey(1)

    if(key==27):
        break

cv2.destroyAllWindows()
source.release()
```

## Anexo N°05 - Códigos en Python para la optimización de los resultados

### a. Se realiza los pasos del 1 al 3 de la metodología en Deep Learning

```
#IMPORTACION DE TODAS LA LIBRERIAS EN DEEP LEARNINGN A USA
from keras.preprocessing.image import ImageDataGenerato
from keras.applications import MobileNetV2
from keras.layers import AveragePooling2
from keras.layers import Dropout
from keras.layers import Flatten
from keras.layers import Dense
from keras.layers import Input
from keras.models import Model
from keras.optimizers import Adam
from keras.applications.mobilenet_v2 import preprocess_inpu
from keras.preprocessing.image import img_toarray
from keras.preprocessing.image import load_img
from keras.utils import to_categorical
from sklearn.preprocessing import LabelBinarizer
from sklearn.model_selection import train_test_spli
from sklearn.metrics import classification_repor
import matplotlib.pyplot as plt
import numpy as np
import os

#SE INICIALIZA EL RATIO DE APRENDIZAJ
INIT_LR = 1e-4
#SE INICIALIZA LAS EPOCAS O ITERACIONES NECESARIA
EPOCHS = 20
BS = 32

#SE ADJUNTA LA RUTA DONDE SE ALMACENA LA BASE DE DATOS DE IMAGENES PARA EL ENTRENAMIENTO
DIRECTORY = r"C:\Users\EDSON\Desktop\PRUEBAS FUNCIONALE \face-mask-detection-keras-maste \Master\dataset"
#SE DIFERENCIA LAS CARPETAS DE LA BASESDE DATOS EN "CON MASCARILLA" Y "SIN MASCARILL
CATEGORIES = ["with_mask", "without_mask"]

print("[[INFO] Cargando Imagenes del Datase      )
      t]...")
#SE INICIALIZA LA DATA Y LABEL EN VACI
data = []
labels = []

#SE EXTRAERA TODA LA INFORMACION DE LAS IMAGENES, ES DECIR, LAS CATEGORIAS, RUTA E IMAGENE
for category in CATEGORIES:
    path = os.path.join(DIRECTORY, category)
    for img in os.listdir(path):
        img_path = os.path.join(path, img)
        image = load_img(img_path, target_size=(224, 224))
        image = img_to_array(image)
        image = preprocess_inpu (image)
        t
        data.append(image)
        labels.append(category)

#SE BINARIZA LAS IMAGENES PARA TRANSFORMARLAS EN TIPO DE DATO OBJETO (IAMGEN)
lb = LabelBinarizer()
labels = lb.fit_transform(labels)
labels = to_categorical(labels)
#LA IMAGEN, SE CONVIERTE EN TIPO DE DATO ARRAY, OSEA MATRICES CON PÍXELES EN DECIMALE
data = np.array(data, dtype="float32")
#SE CONVIERTE EN ARRAY LAS ETIQUETA
labels = np.array(labels)

#SE SEPARA EN TRAIN Y TEST CON EL 20% DEL DATASET PARA TES
(trainX, testX, trainY, testY) = train_test_spli (data, labels,
        test_size=0.20, stratify=labels, random_state=42)

#SE AUMENTAN IMAGENES A PARTIR LA IMAGEN ORIGINAL (ROTACION, SIMETRIA, TRASLACION, ET
aug = ImageDataGenerato (
    rotation_range=20,
    zoom_range=0.15,
    width_shift_range=0.2,
    height_shift_rang =0.2,
    ehear_range=0.15,
    horizontal_flip=True,
    fill_mode="nearest")
```

## b. Se realiza los pasos del 3 al 5 de la metodología en Deep Learning

```
#SE UTILIZA EL MODELO PREENTRENADO MOBILENE
baseModel = MobileNetV2(weights="imagenet", include_top=False,
    input_tensor=Input(shape=(224, 224, 3)))
#SE CREA EL MODELO A PARTIR DE LAS ENTRADAS DEL MODELO ANTERIO
headModel = baseModel.output
headModel = AveragePooling2(pool_size=(7, 7))(headModel)
headModel = Flatten(name="flatten")(headModel)
headModel = Dense(128, activation="relu")(headModel)
headModel = Dropout(0.5)(headModel)
headModel = Dense(2, activation="softmax")(headModel) #SALIDA=2, YA QUE SERÁ "USA MASCARILLA" O "NO USA MASCARILLA"

#SE CREA EL MODELO
model = Model(inputs=baseModel.input, outputs=headModel)
#SE REENOMBRA LOS LAYERS PARA QUE SEAN EJECUTABLE
for layer in baseModel.layers:
    layer.trainable = False

print("[INFO] Compilando el modelo MobileNetV2")
#SE OPTIMIZA EL MODELO CON EL OPTIMIZADOR "ADAM", EL CUAL BUSCA EL ERROR MINIMO EN UN TIEMPO CORTO
opt = Adam(lr=INIT_LR, decay=INIT_LR / EPOCHS)
model.compile(loss="binary_crossentropy", optimizer=opt,
    metrics=["accuracy"])

#SE ENTRENA EL MODELO
print("[INFO] Entrenando el modelo")
H = model.fit(
    aug.flow(trainX, trainY, batch_size=BS),
    steps_per_epoch=len(trainX) // BS,
    validation_data=(testX, testY),
    validation_steps=len(testX) // BS,
    epochs=EPOCHS)

#SE REALIZA PREDICCIONES DE LAS REDES NEURONALES (DEEP LEARNING)
print("[INFO] Evaluando las predicciones de las redes neuronales")
predIdxs = model.predict(testX, batch_size=BS)
predIdxs = np.argmax(predIdxs, axis=1)

#SE REALIZA UNA MATRIZ DE CONFUSION PARA EVALUAR LOS ACIERTOS Y ERRORES
print(classification_report(testY.argmax(axis=1), predIdxs,
    target_names=lb.classes_))

#SE GUARDA EL MODELO
print("[INFO] Guardando el modelo de Vision Artificial para el Deploy")
model.save("mask_detector.h5", save_format="h5")

#SE REALIZA UNA IMPRESION EN IMAGEN DEL ENTRENAMIENTO
N = EPOCHS
plt.style.use("ggplot")
plt.figure()
plt.plot(np.arange(0, N), H.history["loss"], label="train_loss")
plt.plot(np.arange(0, N), H.history["val_loss"], label="val_loss")
plt.plot(np.arange(0, N), H.history["accuracy"], label="train_acc")
plt.plot(np.arange(0, N), H.history["val_accuracy"], label="val_acc")
plt.title("Training Loss and Accuracy")
plt.xlabel("Epoch #")
plt.ylabel("Loss/Accuracy")
plt.legend(loc="lower left")
```

### c. Se realiza los pasos del 5 al 6 de la metodología en Deep Learning

```
#SE REALIZA LA IMPORTACION DE LIBRERIAS EN DEEP LEARNIN
from keras.applications.mobilenet_v2 import preprocess_inpu
from keras.preprocessing.image import img_toarray
from keras.models import load_model
import numpy as np
from tensorflow import keras
import time
import cv2
import os

#SE CREA UNA FUNCION QUE DETECTARA Y PREDECIRA EL USO CORRECTO DE MASCARILLA
def detect_and_predict_mas (frame, faceNet, maskNet):
    k
    (h, w) = frame.shape[:2]
    blob = cv2.dnn.blobFromImage(frame, 1.0, (224, 224),
        (104.0, 177.0, 123.0))

    faceNet.setInput(blob)
    detections = faceNet.forward()
    print(detections.shape)

    faces = []
    locs = []
    preds = []

    for i in range(0, detections.shape[2]):
        confidence = detections[0, 0, i, 2]

        if confidence > 0.5:

            box = detections[0, 0, i, 3:7] * np.array([w, h, w, h])
            startX, startY, endX, endY = box.astype("int")

            (
                startX, startY) = (max(0, startX), max(0, startY))
            (
                endX, endY) = (min(w - 1, endX), min(h - 1, endY))

            face = frame[startY:endY, startX:endX]
            face = cv2.cvtColor(face, cv2.COLOR_BGR2RGB)
            face = cv2.resize(face, (224, 224))
            face = img_to_array(face)
            face = preprocess_inpu (face)
            t
            faces.append(face)
            locs.append((startX, startY, endX, endY))

    if len(faces) > 0:

        faces = np.array(faces, dtype="float32")
        preds = maskNet.predict(faces, batch_size=32)

    return (locs, preds)

#SE USARA LA RUTA DONDE SE TIENE LOS MODELOS PREENTRENADO
prototxtPath = r"C:\Users\EDSON\Desktop\PRUEBAS-FUNCIONALE \face-mask-detection-keras-maste \Master\face_detector\deploy.prototx
weightsPath = r"C:\Users\EDSON\Desktop\PRUEBAS-FUNCIONALE \face-mask-detection-keras-maste \Master\face_detector\res10_300x300_ssd_iter_140000.caffemode
1"
```

#### d. Se realiza los pasos del 6 al 8 de la metodología en Deep Learning

```
#SE REALIZARA UN ENSAMBLE DE MODELO
faceNet = cv2.dnn.readNet(prototxtPath, weightsPath)

#SE CARGA EL MODELO RESULTANTE ANTERIOR ENTRENAD
maskNet = keras.models.load_model("mask_detector.model")

#SE ENCIENDE LA CAMARA
print("[INFO] Empezando uso de web camera")
#vs = cv2.VideoCapture(wong5)
vs = cv2.VideoCapture('prueba2.mp4') #wong5,
                                     wong7

#SE CREA LOS BOUNDINGBOX PARA RESALTAR LA ZONA DONDE VA LAS MASCARILLAS
#ASI MISMO SE CREA LA ALARMA EN FORMA DE FOCO PARA QUE SIMULE UN AMBIENTE REAL
while True:
    #SE EXTRAE LA IMAGEN DEL VIDEO
    ret, frame = vs.read()
    #frame = cv2.rotate(frame, cv2.ROTATE_90_COUNTERCLOCKWISE)
    #frame = cv2.rotate(frame, cv2.ROTATE_90_CLOCKWISE)
    #SE REALIZA UN REDIMENSIONAMIENTO DE DICHA IMAGEN, PASANDO A 700x700 PÍXELES
    frame=cv2.resize(src=frame, dsize=(700,700))
    #SE EXTRAEN LOS VALORES DETECTADOS Y PREDICHOS DE LA IMAGEN
    (locs, preds) = detect_and_predict_masks(frame, faceNet, maskNet)

    #SE UTILIZARA LOS PÍXELES NECESARIOS PARA LA CREACION DEL RECTANGULO QUE DETECTE LA MASCARILLA O NO MASCARILLAS
    for (box, pred) in zip(locs, preds):
        (startX, startY, endX, endY) = box
        (mask, withoutMask) = pred

        #SE CONDICIONA SI USA O NO MASCARILLA, PARA PINTAR DE COLORES VERDE O ROJO
        label = "SI USA" if mask > withoutMask else "NO USA"
        color = (0,255, 0) if label == "SI USA" else (0, 0, 255) #BGR
                MASK"
        #SE CREA LA ALARMA DEPENDIENDO SI USA O NO MASCARILLAS
        if label == "NO USA":
            cv2.rectangle(frame, (34+15, 60), (64+15, 100), (0,0,255), -1)
            cv2.circle(frame, (50+15, 50),33,(0,0,255),-1)
            cv2.putText(frame, "ALERTA!", (10, 128), cv2.FONT_HERSHEY_SIMPLE , 1, (0,0,255), 2)
        elif label == "SI USA":
            cv2.rectangle(frame, (34+15+580, 60), (64+15+580, 100), (0,255,0), -1)
            cv2.circle(frame, (50+15+580, 50),33,(0,255,0),-1)
            cv2.putText(frame, "PASE!", (23+580, 128), cv2.FONT_HERSHEY_SIMPLE , 1, (0,255,0), 2)

        #SE PONE EN PROBABILIDAD EL NIVEL DE ACIERTO EN SI USA O NO MASCARILLAS
        label = "{}: {:.2f}%".format(label, max(mask, withoutMask) * 100)

        #SE ESCRIBE EN LA IMAGEN
        cv2.putText(frame, label, (startX, startY - 10), cv2.FONT_HERSHEY_SIMPLE , 0.45, color, 2)
        cv2.rectangle(frame, (startX, startY), (endX, endY), color, 2)

    #SE MUESTRA LA IMAGEN QUE VISUALIZA LA CAMARA WEB
    cv2.imshow("Frame", frame)
    key = cv2.waitKey(1) & 0xFF

    #SE CIERRA LA WEBCAM CON LA LETRA
    if key == ord("q"):
        break

#SE DESTRUYE TODA VENTANA ABIERTA A PARTIR DEL CODIGO EJECUTADO
cv2.destroyAllWindows()
vs.stop()
```

### ANEXO N°03 Matriz de Consistencia

Tabla 23. Matriz de Consistencia

PROBLEMA GENERAL	OBJETIVO GENERAL	HIPOTESIS GENERAL	VARIABLE INDEPENDIENTE	DIMENSIONES	INDICADORES	METODOLOGIA
¿En qué medida el uso de un sistema inteligente basado en Deep Learning mejora el correcto uso personal de mascarillas en el supermercado Wong?	Mejorar el correcto uso personal de mascarillas en el supermercado Wong, mediante un sistema inteligente basado en Deep Learning.	Si se usa el sistema inteligente basado en Deep Learning mejora el correcto uso personal de mascarillas en el supermercado Wong	Sistema Inteligente			
PROBLEMAS ESPECIFICOS	OBJETIVOS ESPECIFICOS	HIPOTESIS ESPECIFICAS	VIARIABLE DEPENDIENTE			
¿De qué manera el uso de un sistema inteligente basado en Deep Learning aumenta el nivel de seguridad de las personas en el supermercado Wong?	Aumentar el nivel de seguridad de las personas en el supermercado Wong	Si se usa el sistema inteligente basado en Deep Learning aumenta el nivel de seguridad de las personas en el supermercado Wong		Nivel De Seguridad (Fernández 2005)	Porcentaje En El Nivel De Seguridad De Las personas (Fernández 2005)	
¿De qué manera el uso del sistema inteligente basado en Deep Learning aumenta la confianza a las personas para transitar libre y seguramente en el supermercado Wong?	Aumentar el nivel de confianza de las personas para transitar libre y seguramente en el supermercado Wong.	Si se usa el sistema inteligente basado en Deep Learning aumenta el nivel de confianza de las personas para transitar libre y seguramente en el supermercado Wong	Detección Y Verificación del correcto	Nivel De Confianza (Yañez, Ahumada y Cova 2006)	Porcentaje en el Nivel De Confianza De Las Personas (Yañez, Ahumada y Cova 2006)	RAZON



<p>¿De qué manera el uso del sistema inteligente basado en Deep Learning disminuye el tiempo en la detección y verificación de las personas que usen inapropiadamente la mascarilla en el supermercado Wong?</p>	<p>Disminuir el tiempo en la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong</p>	<p>Si se usa el sistema inteligente basado en Deep Learning disminuye el tiempo en la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong</p>	<p>uso personal de mascarillas en el supermercado Wong</p>	<p>Tiempo (Nuñez 2018)</p>	<p>Tiempo En La Detección Y Verificación Del Correcto Uso Personal De Mascarilla (Nuñez 2018)</p>
<p>¿De qué manera el uso del sistema inteligente basado en Deep Learning aumenta la rapidez en la reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong?</p>	<p>Aumentar la rapidez de reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong.</p>	<p>Si se usa el sistema inteligente basado en Deep Learning aumenta la rapidez de reacción de las personas en el uso correcto de la mascarilla en el supermercado Wong.</p>		<p>Rapidez (Díaz y Gonzáles 2010)</p>	<p>Porcentaje De Rapidez de Reacción de las Personas. (Díaz y Gonzáles 2010)</p>

## Anexo N°04 Operacionalización de Variables

Tabla 24. Operacionalización de Variables

VARIABLES DE ESTUDIO	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	DIMENSIÓN	INDICADORES	ESCALA DE MEDICIÓN
Independiente : Sistema Inteligente	Los sistemas inteligentes son diseñados electrónicamente para que realicen o cumplan cierta función destinada junto a sensores, actuadores y microcontroladores o microprocesadores (Arriarán 2021 p.87).	Se obtendrán diversos datos a partir de la muestra aleatoria escogida desde una población. Estas encuestas buscarán determinar el efecto del sistema inteligente que busca controlar y monitorear el correcto uso de las mascarillas personales. (Caballero, 2020 p.36)			
Dependiente: El correcto uso personal de mascarillas en el supermercado Wong	Uso correcto de mascarillas, el uso de este nuevo objeto personal es obligatorio en la nación peruana debido al alto índice de contagios del covid-19. (2020).	El correcto uso personal de mascarillas podrá proteger a personas sanas o evitar la transmisión del virus. Es por ello que a recomendación de la OMS es necesario usar estas mascarillas quirúrgicas para reducir el alto nivel de contagio y, además, usar los protectores faciales para evadirlos en mayor proporción (2020).	Nivel De seguridad (Fernández 2005) Nivel De Confianza (Yañez, Ahumada y Cova 2006) Tiempo (Nuñez 2018) Rapidez (Díaz y Gonzáles 2010)	Porcentaje en el nivel de seguridad de las personas. (Fernández 2005) Porcentaje nivel de confianza de las personas. (Yañez, Ahumada y Cova 2006) Tiempo en la detección y verificación del correcto uso personal de mascarilla. (Nuñez 2018) Porcentaje de rapidez de reacción de las personas. (Díaz y Gonzáles 2010)	Razón

Tabla 25. Cuadro de Comparación de Lenguaje de Programación

N°	LP	DEFINICIÓN	VENTAJAS	DESVENTAJAS	AÑO
1	PYTHON	Lenguaje de programación ampliamente usado en diversos proyectos de desarrollo web, aplicativos, robótica e inteligencia artificial. (Vásquez 2019)	<ul style="list-style-type: none"> <li>• Poseen una sintaxis sencilla y fácil de aprender.</li> <li>• Es un lenguaje extremadamente fructuoso.</li> <li>• Tiene licencia de código abierto y está disponible para los usuarios de forma gratuita</li> <li>• Existe una amplia gama de bibliotecas disponibles para extender sus funcionalidades.</li> <li>• Es un lenguaje muy portable y multiplataforma.</li> <li>• Presenta una fácil integración con otros lenguajes de programación</li> </ul>	<ul style="list-style-type: none"> <li>• Python posee una baja velocidad de procesamiento, por lo que puede volverse difícil de manejar para aplicaciones grandes y complejas</li> <li>• Sus funciones dinámicas pueden causar errores en tiempo de ejecución</li> <li>• La mayoría de Servidores con servicios Hosting no tiene soporte para Python</li> <li>• Posee un consumo ineficiente de memoria para realizar algunas tareas</li> <li>• Cuenta con una programación débil para dispositivos móviles</li> </ul>	1991
2	LENGUAJE R	Es un entorno de sw libre (licencia GNU GPL) y lenguaje de programación interpretado, de distribución libre. Corre en diferentes plataformas como Linux, MacOS, Windows. (Corvi y Fanjul 2016)	<ul style="list-style-type: none"> <li>• Acumula, en un único programa, todo lo necesario para analizar los datos con eficacia.</li> <li>• Incluye modelos lineales y no lineales usados en el sector de la estadística. Es idóneo para la clasificación y el agrupamiento de los datos, facilitando así su posterior interpretación.</li> <li>• Los diversos operadores permiten realizar cálculos con matrices más rápidamente.</li> <li>• El lenguaje de programación permite crear un código limpio que facilita la gestión de los datos.</li> <li>• Su uso es gratuito. Solo es necesario descargarse el programa en su web oficial.</li> </ul>	<ul style="list-style-type: none"> <li>• No soporta gráficos en tres dimensiones o dinámicos.</li> <li>• Los algoritmos no están unificados. Cada uno de ellos se almacena en un paquete distinto, por lo que hay que ir cambiando de opción para leer los datos obtenidos.</li> <li>• Su origen está en S, un lenguaje de programación bastante anticuado que no ha sabido adaptarse a los tiempos. Otras alternativas, como Python, son más competitivas.</li> <li>• Sus restricciones y su incompatibilidad con otros lenguajes de programación impiden que se pueda usar para crear aplicaciones web.</li> </ul>	1993

3	C#	Es un lenguaje de programación orientado a objetos desarrollado y estandarizado por Microsoft como parte de su plataforma .net. (BeSoftware 2019)	<ul style="list-style-type: none"> <li>• Declaraciones en el espacio de nombres: al empezar a programar algo, se puede definir una o más clases dentro de un mismo espacio de nombres.</li> <li>• Tipos de datos: Existe un rango más amplio y definido de tipos de datos que los que se encuentran en C, C++ o Java.</li> <li>• Atributos: cada miembro de una clase tiene un atributo de acceso del tipo público, protegido, interno, interno protegido y privado.</li> </ul>	<ul style="list-style-type: none"> <li>• Se tiene que conseguir una versión reciente de visual studio.net, por otra parte, se tiene que tener algunos requerimientos mínimos del sistema para poder trabajar adecuadamente tales como contar con Windows NT 4 o superior, tener alrededor de 4 gigas de espacio libre para la pura instalación entre otros.</li> <li>• Para quien no está familiarizado con ningún lenguaje de programación, le costará más trabajo iniciarse en su uso.</li> </ul>	1974
4	C++	Contiene los paradigmas de la programación estructurada y orientada a objetos, por lo que se le conoce como un lenguaje de programación multiparadigma. (Robleado 2019)	<ul style="list-style-type: none"> <li>• Es potente en cuanto a lo que se refiere a creación de sistemas complejos un lenguaje muy robusto.</li> <li>• Programación orientada a objetos.</li> <li>• Muy didáctico, con este lenguaje puedes aprender muchos otros lenguajes con gran facilidad, como C#, Java, Visual Basic, JavaScript, PHP, entre otros.</li> </ul>	<ul style="list-style-type: none"> <li>• No es atractivo visualmente.</li> <li>• No soporta para creación de páginas web.</li> <li>• Es mucho más difícil de usar q otros lenguajes de programación.</li> <li>• Es difícil programar bases de datos.</li> </ul>	1979

Tabla 26. Cuadro de Comparación de Metodología

	<b>MACHINE LEARNING</b>	<b>CRISP-DM</b>	<b>DEEP LEARNING</b>	<b>SCRUM</b>	<b>PROGRAMACIÓN EXTREMA</b>
<b>Breve Descripción</b>	Metodología que busca que un proyecto basado en un sistema aprenda de forma autónoma y tome decisiones	Metodología que busca brindar fases detalladas y brindar una orientación al proyecto de minería de datos	Metodología orientada para realizar proyectos haciendo uso de redes neuronales complejas	Metodología que busca que el trabajo se realice mediante interacciones de equipo definiendo el modelo de trabajo	Metodología que brinda la capacidad de que la gestión del proyecto sea más ágil y flexible
<b>Tipos de Proyectos de Software</b>	Pequeños y medianos Proyectos	Adaptación evolutiva en Feature Engineering	Pequeños, Medianos y Grandes Proyectos	Medianos Proyectos	Grandes Proyectos y Apps Móviles
<b>Desarrollador / Relación con el usuario</b>	Programadores con facilidad para Teamwork	Se relaciona con procedimientos Industriales Estandarizados para la minería de Datos e IA	Programadores Certificados en Desarrollo IA	Se relaciona a la necesidad del cliente	Programadores con vinculación al trabajo en equipo
<b>Etapas</b>	<ol style="list-style-type: none"> <li>1. Entender el Problema</li> <li>2. Criterio de Evaluación</li> <li>3. Evaluación de la solución actual</li> <li>4. Preparación de los Datos</li> <li>5. Construir el modelo</li> <li>6. Análisis de Errores</li> <li>7. Modelo Integrado de un sistema</li> </ol>	<ol style="list-style-type: none"> <li>1. Entendimiento del Negocio</li> <li>2. Entendimiento de la Data</li> <li>3. Preparación de la Data</li> <li>4. Modelamiento</li> <li>5. Evaluación</li> <li>6. Despliegue del Proyecto</li> </ol>	<ol style="list-style-type: none"> <li>1. Adquisición de Imágenes</li> <li>2. Procesamiento de Imágenes</li> <li>3. Extracción de características customizadas</li> <li>4. Segmentación de imágenes</li> <li>5. Modelamiento en IA</li> <li>6. Creación de Boundinboxes</li> <li>7. Análisis de Errores</li> <li>8. Despliegue en Real-time</li> </ol>	<ol style="list-style-type: none"> <li>1. Inicio</li> <li>2. Planificación y estimación</li> <li>3. Implementación</li> <li>4. Revisión y retrospectiva</li> <li>5. Lanzamiento</li> </ol>	<ol style="list-style-type: none"> <li>1. Planificación</li> <li>2. Diseño</li> <li>3. Codificación</li> <li>4. Pruebas</li> <li>5. Lanzamiento</li> </ol>
<b>Características del Modelo</b>	Modelo adaptivo-evolutivo vinculado a la data estructurada customizada	Modelo incremental centrado en el seguimiento de pasos y diagramas de bloques	Modelo adaptivo centrado en casos particulares el desarrollo vinculado a computer vision	Modelo focalizado en la comunicación y trabajo en equipo	Modelo centrado en la compartición, códigos y comunicación.

## Instrumento 1: Porcentaje en el Nivel De Seguridad ante el Contagio



**UNIVERSIDAD CÉSAR VALLEJO**

<b>Investigadores</b>	- Baca Gamboa, Maria Rosa - Sihuacollo Liñan, Julio Anderson	<b>Tipo de Prueba</b>	Pre Test		
<b>Empresa Investigada</b>	Supermercado Wong				
<b>Motivo de Investigación</b>	Porcentaje en el Nivel De Seguridad de las personas				
<b>Fecha de Inicio</b>		<b>Fecha Final</b>			
<b>Sistema Inteligente basado en Deep Learning para mejorar la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong</b>					
<b>OBJETIVO</b>	<b>INDICADOR</b>	<b>MEDIDA</b>	<b>FORMULA</b>		
Aumentar el nivel de seguridad de las personas en el supermercado Wong	Porcentaje en el nivel de seguridad de las personas. (PNSP)	Porcentaje	$PNSP = \frac{PS\ inicial - PS\ final}{100}$ PS: Porcentaje de Seguridad		
<b>INFORMACIÓN SOBRE LA SEGURIDAD DE LAS PERSONAS</b>					
N°	Datos de la persona	DNI	Contexto		
				PS inicial	PS final
1	Sotomayor Silvestre Eduardo	46385090	Al ingreso y salida del supermercado Wong.	100%	80%
2	Cabrera García Ulises	56478910	Al ingreso y salida del supermercado Wong.	90%	70%
3	Tapia Tito Roger	34678900	Al ingreso y salida del supermercado Wong.	80%	50%
4	Gonzales Balcázar José	34500230	Al ingreso y salida del supermercado Wong.	80%	60%
5	Ríos Almanza Roberto	46396032	Al ingreso y salida del supermercado Wong.	90%	70%
6	Cueva Lavado Elio	28906750	Al ingreso y salida del supermercado Wong.	100%	70%
7					
8					
9					
10					
11					
12					
13					

## Instrumento 2: Porcentaje Nivel De Confianza De Las Personas



**UNIVERSIDAD CÉSAR VALLEJO**

<b>Investigadores</b>	- Baca Gamboa, Maria Rosa - Sihuacollo Liñan, Julio Anderson	<b>Tipo de Prueba</b>	Pre Test		
<b>Empresa Investigada</b>	Supermercado Wong				
<b>Motivo de Investigación</b>	Porcentaje en el Nivel De Confianza De Las Personas				
<b>Fecha de Inicio</b>		<b>Fecha Final</b>			
<b>Sistema Inteligente basado en Deep Learning para mejorar la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong</b>					
<b>OBJETIVO</b>	<b>INDICADOR</b>	<b>MEDIDA</b>	<b>FORMULA</b>		
Aumentar el nivel de confianza de las personas para transitar libre y seguramente en el supermercado Wong.	Porcentaje Nivel De Confianza De Las Personas. (PNCP)	Porcentaje	$PNCP = \frac{PC\ inicial - PC\ final}{Total}$ PC: Porcentaje de Confianza		
<b>INFORMACIÓN SOBRE LA CONFIANZA DE LAS PERSONAS</b>					
N°	Datos de la Persona	DNI	Contexto		
				PC inicial	PC final
1	Sotomayor Silvestre Eduardo	46385090	Al transitar por el interior del supermercado	100%	80%
2	Cabrera García Ulises	56478910	Al transitar por el interior del supermercado	90%	70%
3	Tapia Tito Roger	34678900	Al ingreso y salida del supermercado Wong.	80%	50%
4	Gonzales Balcázar José	34500230	Al transitar por el interior del supermercado	80%	60%
5	Ríos Almanza Roberto	46396032	Al transitar por el interior del supermercado	90%	70%
6	Cueva Lavado Elio	28906750	Al transitar por el interior del supermercado	100%	70%
7					
8					
9					
10					
11					
12					
14					

### Instrumento 3: Tiempo En La Detección Y Verificación Del Correcto Uso Personal De Mascarilla



<b>Investigadores</b>	- Baca Gamboa, Maria Rosa - Sihuacollo Liñan, Julio Anderson	<b>Tipo de Prueba</b>	Pre Test
<b>Empresa Investigada</b>	Supermercado Wong		
<b>Motivo de Investigación</b>	Tiempo En La Detección Y Verificación Del Correcto Uso Personal De Mascarilla		
<b>Fecha de Inicio</b>		<b>Fecha Final</b>	

**Sistema Inteligente basado en Deep Learning para mejorar la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong**

OBJETIVO	INDICADOR	MEDIDA	FORMULA
Disminuir el tiempo en la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong	Tiempo en la detección y verificación del correcto uso personal de mascarilla. (TDVM)	Minuto	$TDVM = \frac{\text{Tiempo de deteccion}}{\text{Total de personas}}$

#### INFORMACIÓN SOBRE LA DETECCIÓN Y VERIFICACIÓN DEL CORRECTO USO PERSONAL DE MASCARILLA

N°	Día	N.º Personas	Tiempo	Contexto		
					Hora Inicial	Hora Final
1	Lunes	100	120 min	Tiempo que demora el personal encargado en la detección y verificación.	10:00	12:00
2	Martes	100	130 min	Tiempo que demora el personal encargado en la detección y verificación.	13:00	15:10
3	Miércoles	100	110 min	Tiempo que demora el personal encargado en la detección y verificación.	11:00	12:50
4	Jueves	100	140 min	Tiempo que demora el personal encargado en la detección y verificación.	14:00	16:20
5	Viernes	100	130 min	Tiempo que demora el personal encargado en la detección y verificación.	15:00	17:10
6	Sábado	100	100 min	Tiempo que demora el personal encargado en la detección y verificación.	12:00	13:40
7	Domingo	100	120 min	Tiempo que demora el personal encargado en la detección y verificación.	11:00	13:00
8						
9						
10						
11						



### Instrumento 4: Porcentaje De Rapidez de Reacción de las Personas



**UNIVERSIDAD CÉSAR VALLEJO**

<b>Investigadores</b>	- Baca Gamboa, Maria Rosa - Sihucollo Liñan, Julio Anderson	<b>Tipo de Prueba</b>	Pre Test
<b>Empresa Investigada</b>	Supermercado Wong		
<b>Motivo de Investigación</b>	Porcentaje De Rapidez de Reacción de las Personas		
<b>Fecha de Inicio</b>		<b>Fecha Final</b>	

**Sistema Inteligente basado en Deep Learning para mejorar la detección y verificación del correcto uso personal de mascarillas en el supermercado Wong**

OBJETIVO	INDICADOR	MEDIDA	FORMULA
Aumentar la rapidez de reacción de las personas en el supermercado Wong.	Porcentaje de rapidez de reacción de las personas. (PRRP)	Porcentaje	$PRRP = \frac{(TR * CP)}{100}$ PRRP: Porcentaje de Reacción

#### INFORMACIÓN SOBRE LA RAPIDEZ DE REACCIÓN DE LAS PERSONAS

N°	DIA	HORA INICIAL	HORA TERMINO	CANTIDAD DE PERSONAS (CP)	TIEMPO DE REACCION(TR)
1	Lunes	09:00	10:00	100	0.5 min
2	Lunes	10:00	11:00	65	0.6 min
3	Lunes	11:00	12:00	92	0.5 min
4	Lunes	13:00	14:00	94	0.7 min
5	Lunes	14:00	15:00	89	0.6 min
6	Lunes	16:00	17:00	95	0.8 min
7	Martes	09:00	10:00	85	0.9 min
8	Martes	10:00	11:00	87	0.5 min
9	Martes	11:00	12:00	70	0.7 min
10	Martes	13:00	14:00	75	0.6 min
11	Martes	14:00	15:00	79	0.8 min
12	Martes	16:00	17:00	60	0.4 min