



ESCUELA UNIVERSITARIA DE POSGRADO

OPTIMIZACIÓN DEL PROCESO DE APERFILAMIENTO Y TRATAMIENTO DE
IMÁGENES UTILIZANDO REDES NEURONALES CONVOLUCIONALES PARA
UNA EMPRESA DE LA INDUSTRIA CINEMATOGRAFICA Y PUBLICITARIA
LIMA – PERÚ 2024

Línea de investigación:
Sistemas inteligentes, robótica, domótica

Tesis para optar el grado académico de Maestro en Ingeniería de Sistemas
con Mención en Gestión de Tecnologías de la Información

Autor

Cuadra Rivera, Carlos Joaquín

Asesor

Soto Soto, Luis

ORCID: 0000-0002-3799-645X

Jurado

Cachay Boza, Orestes

Paredes Paredes, Pervis

Enciso Lopez, Jossy Carlot

Lima - Perú

2025

OPTIMIZACIÓN DEL PROCESO DE APERFILAMIENTO Y
TRATAMIENTO DE IMÁGENES UTILIZANDO REDES
NEURONALES CONVOLUCIONALES PARA UNA EMPRESA DE LA
INDUSTRIA CINEMATOGRAFICA Y PUBLICITARIA LIMA – PERÚ
2024

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	Submitted to Universidad Nacional Federico Villarreal	8%
	Trabajo del estudiante	
2	repositorio.unfv.edu.pe	2%
	Fuente de Internet	
3	Submitted to Corporación Universitaria Minuto de Dios,UNIMINUTO	1%
	Trabajo del estudiante	
4	Submitted to Universidad Cesar Vallejo	1%
	Trabajo del estudiante	
5	Submitted to Universidad Internacional de la Rioja	<1%
	Trabajo del estudiante	
6	www.coursehero.com	<1%
	Fuente de Internet	
7	www.aprendemachinelearning.com	<1%
	Fuente de Internet	
8	repositorio.ucv.edu.pe	<1%
	Fuente de Internet	
9	repositorio.unfv.edu.pe:8080	<1%
	Fuente de Internet	
10	repositorio.uladech.edu.pe	



ESCUELA UNIVERSITARIA DE POSGRADO

OPTIMIZACIÓN DEL PROCESO DE APERFILAMIENTO Y TRATAMIENTO DE
IMÁGENES UTILIZANDO REDES NEURONALES CONVOLUCIONALES PARA UNA
EMPRESA DE LA INDUSTRIA CINEMATOGRAFICA Y PUBLICITARIA LIMA –
PERÚ 2024.

Línea de investigación:

Sistemas inteligentes, robótica, domótica

Tesis para optar el grado académico de Maestro en Ingeniería de Sistemas

Con Mención en Gestión de Tecnologías de la Información

Autor

Cuadra Rivera, Carlos Joaquín

Asesor

Soto Soto, Luis

ORCID: 0000-0002-3799-645X

Jurado

Cachay Boza, Orestes

Paredes Paredes, Pervis

Enciso Lopez, Jossy Carlot

Lima – Perú

2025

ÍNDICE

RESUMEN	viii
ABSTRACT	ix
I INTRODUCCIÓN	1
1.1 Planteamiento del problema	2
1.2 Descripción del problema	5
1.3 Formulación del problema	7
1.3.1 Problema general	7
1.3.2 Problema específicos	8
1.4 Antecedentes	8
1.4.1 Antecedentes internacionales	8
1.4.2. Antecedentes nacionales	10
1.5 Justificación de la investigación	12
1.5.1 Justificación practica	12
1.5.2 Justificación metodológica	12
1.5.3 Justificación teórica	13
1.5.4 Justificación social	15
1.5.5 Importancia de la investigación	15
1.6 Limitaciones de la investigación	16
1.7 Objetivos de la investigación	17
1.7.1 Objetivo general	17
1.7.2 Objetivos específicos	18

1.8 Hipótesis.....	18
1.8.1 Hipótesis general	18
1.8.2 Hipótesis específicas.....	18
II MARCO TEÓRICO	19
2.1 Marco conceptual	19
2.1.1 Teorías generales del estudio.....	19
2.1.2 Redes Neuronales Convulsionales (CNN)	21
2.1.3 Optimización del proceso de a perfilamiento y tratamiento de imágenes.....	22
2.1.4. Dimensiones de la Redes Neuronales Convulsionales (CNN).....	23
2.1.5 Dimensiones de la Optimización del proceso de a perfilamiento y tratamiento de imágenes.	23
2.1.6 Procesos Cognitivos Asociados a la Inteligencia Humana.....	24
2.1.7 Redes Neuronales Convulsionales (CNN)	26
2.1.8 Bases Teóricas sobre la Optimización del proceso de a perfilamiento y tratamiento de imágenes.	30
2.1.9 Características en el proceso de detección de objetos en las imágenes.....	36
2.1.10 Modelos Disponibles para la detección de los objetos	37
2.1.11 Concepto de las dimensiones de la Redes Neuronales Convulsionales (CNN)	37
2.1.12 Concepto de las dimensiones de la Optimización del proceso de a perfilamiento y tratamiento de imágenes	38
2.2.13 Términos relacionados al tratamiento de imágenes usadas dentro de esta investigación.....	39

2.2.14 Términos relacionados al proceso de casting de una empresa audiovisual	42
III MÉTODO	44
3.1 Tipo de investigación	44
3.2 Población y muestra	45
3.2.1 Población	45
3.2.2 Muestra	45
3.3 Operacionalización de variables	45
3.4 Instrumentos	46
3.5 Procedimientos	49
3.6 Análisis de datos	50
3.7 Consideraciones éticas	52
IV. RESULTADOS	53
4.1 Análisis y Resultados de la Variable Independiente y sus Indicadores	53
4.2 Análisis y resultados de la variable dependiente y sus indicadores	55
4.3 Prueba de Hipótesis	59
4.3.1 Prueba de Hipótesis Principal	59
4.3.2 <i>Prueba de Hipótesis Específica 1</i>	60
4.3.3 Prueba de Hipótesis Específica 2	61
4.3.4 Prueba de Hipótesis Específica 3	62
V. DISCUSIÓN DE RESULTADOS	63
VI CONCLUSIONES	69
VII. RECOMENDACIONES	71

VIII. REFERENCIAS.....	72
IX ANEXOS	82
Anexo A. Matriz de consistencia	82
Anexo B. Validación de instrumentos	84
Anexo C. Confiabilidad de Instrumentos.....	95
Anexo D. Instrumento de medición	97
Anexo E. Determinación de la muestra de estudio	99
Anexo F. Procesamiento	100
Anexo G. Resultados – figuras.....	109
Anexo H. Prueba de normalidad	115

ÍNDICE DE TABLAS

Tabla 1 Operacionalización de las Variables de estudio	46
Tabla 2 Relación de juicio de experto	47
Tabla 3 Lista de entrevistados y su distribución	48
Tabla 4 Escala de valoración.....	49
Tabla 5 Resultados de la Pruebas de Normalidad	51
Tabla 6 Matriz de confusión para el caso.....	53
Tabla 7 Prueba de rangos con signo de Wilcoxon para el indicador	55
Tabla 8 Prueba de rangos con signo de Wilcoxon para el indicador	56
Tabla 9 Prueba de rangos con signo de Wilcoxon para el indicador	56
Tabla 10 Prueba de rangos con signo de Wilcoxon para el indicador	57
Tabla 11 Prueba de rangos con signo de Wilcoxon para el indicador	58
Tabla 12 Resultados para el indicador de satisfacción.....	58
Tabla 13 Prueba de rangos con signo de Wilcoxon para la Hipótesis General.....	59
Tabla 14 Prueba de rangos con signo de Wilcoxon para la hipótesis específica 1	60
Tabla 15 Prueba de rangos con signo de Wilcoxon para la hipótesis específica 2	61
Tabla 16 Prueba de rangos con signo de Wilcoxon para la hipótesis específica 3	62
Tabla 17 Resultado de Fiabilidad Pre- Test	96
Tabla 18 Resultado de Fiabilidad Post - Test.....	96
Tabla 19 Muestra de resultado del proceso de selección	107
Tabla 20 Prueba de normalidad Shapiro Wilk	115

ÍNDICE DE FIGURAS

Figura 1 Impacto (%) sobre el proceso de aperfilamiento	65
Figura 2 Impacto (%) sobre el tiempo de perfilamiento en la selección de perfiles	66
Figura 3 Impacto (%) sobre la reducción de errores en los procesos de perfilamiento	67
Figura 4 Impacto (%) en la efectividad en los procesos de perfilamiento	68
Figura 5 Formula del Alfa de Cronbach	95
Figura 6 Rangos del Alfa de Cronbach	95
Figura 7 Formula: de Muestra Población Finita	99
Figura 8 Código Python de carga de imágenes	100
Figura 9 Revisión del Dataset	101
Figura 10 Flujo de proceso de limpieza de las imágenes usando CNN	102
Figura 11 Proceso de entrenamiento y validación de modelo	104
Figura 12 Flujo de proceso de selección de imágenes según la referencia	105
Figura 13 Resultados del Indicador: Tiempo en clasificar los candidatos.....	109
Figura 14 Resultados del Indicador: Tiempo de a perfilamiento de imágenes digitalizadas	110
Figura 15 Resultados del Indicador: Tiempo de identificación de rasgos faciales	111
Figura 16 Resultados del Indicador: Tiempo de ordenar y a perfilar las imágenes digitalizadas.....	112
Figura 17 Resultados del Indicador: Tiempo de generación de pre-seleccionados	113
Figura 18 Distribución de frecuencias del indicador dimensión satisfacción del Usuario con el proceso de Pos – test	114

RESUMEN

Objetivo: establecer el nivel en la cual la implementación del uso de las Redes Neuronales Convolucionales influye en las mejoras del proceso de aperfilamiento en la selección de perfiles para el área de casting de la entidad audiovisual Spiral Producciones en Lima, Perú.

Método: diseño no experimental, tipo aplicado, enfoque cuantitativo, positivista, como población son los postulantes a las convocatorias de casting entre las edades de 20 a 35 años de ambos sexos, de la provincia de Lima – Perú. Para el grupo de las convocatorias de aperfilamiento entre el mes de enero del 2023 y mayo 2024 y la muestra fue de 168 imágenes.

Resultados: La prueba de Wilcoxon muestra un valor de significancia de 0.000, inferior a 0.05, lo que indica una mejora significativa tras la implementación de la variable independiente. Esto se refleja en la reducción de plazos en la clasificación de candidatos y el aperfilamiento de imágenes digitalizadas. Además, la prueba de hipótesis, con significancia de 0.000, lleva al rechazo de la hipótesis nula y a la aceptación de la alternativa, demostrando que el nuevo modelo de redes neuronales mejora los procedimientos de aperfilamiento en la selección de perfiles para casting. **Conclusiones:** La implementación de la utilización de Redes Neuronales Convolucionales ayudó a mejorar el procedimiento de a perfilamiento en la selección de perfiles para el área de casting respaldada por un valor de significancia fue 0,000, que evidencia ser significativamente menor al umbral teórico equivalente a 0,05.

Palabras clave: Redes Neuronales Convolucionales, proceso de aperfilamiento, casting.

ABSTRACT

Objective: to establish the level to which the implementation of the use of Convolutional Neural Networks influences the improvements of the profiling process in the selection of profiles for the casting area of the audiovisual entity Spiral Producciones in Lima, Peru.

Method: non-experimental design, applied type, quantitative, positivist approach, as population are the applicants to the casting calls between the ages of 20 to 35 years of both sexes, from the province of Lima - Peru. For the group of the profiling calls between the month of January 2023 and May 2024 and the sample was 168 images. **Results:** The Wilcoxon test shows a significance value of 0.000, less than 0.05, which indicates a significant improvement after the implementation of the independent variable. This is reflected in the reduction of deadlines in the classification of candidates and the profiling of digitized images. Furthermore, the hypothesis test, with significance of 0.000, leads to the rejection of the null hypothesis and the acceptance of the alternative, demonstrating that the new neural network model improves the profiling procedures in the selection of profiles for casting. **Conclusions:** The implementation of the use of Convolutional Neural Networks helped to improve the profiling procedure in the selection of profiles for the casting area supported by a significance value of 0.000, which is significantly lower than the theoretical threshold equivalent to 0.05.

Keywords: Convolutional Neural Networks, profiling process, casting.

I. INTRODUCCIÓN

El proceso de casting en la industria cinematográfica y publicitaria es un componente esencial para asegurar que los proyectos cuenten con los profesionales más adecuados para desempeñar roles clave en producciones audiovisuales, teatrales, publicitarias y otros proyectos que requieren actores, modelos, presentadores, entre otros. Tradicionalmente, este proceso ha dependido de métodos manuales y subjetivos, lo que ha generado ineficiencias, posibles errores humanos y prolongados tiempos de espera, afectando la calidad y efectividad en la selección de los candidatos. Por ello, es importante resaltar el requerimiento de optimizar el proceso de aperfilamiento y tratamiento de imágenes, con la finalidad de disminuir los plazos y mejorar los resultados de forma significativa. La motivación detrás de esta investigación radica en encontrar soluciones innovadoras que, mediante el uso de tecnologías avanzadas, mejoren los estándares de trabajo en el sector.

El propósito principal de la investigación es optimizar el proceso de casting a través de la utilización de Redes Neuronales Convolucionales (CNN) y Deep Learning, tecnologías reconocidas por la capacidad de gestión de volúmenes grandes de información con alta precisión, adaptabilidad y rendimiento. Estas herramientas permitirán automatizar el tratamiento de imágenes de los candidatos, lo que facilitará la selección precisa y eficaz de los perfiles adecuados para proyectos cinematográficos y publicitarios. Las redes neuronales convolucionales son ideales para analizar y procesar las imágenes de los candidatos, evaluando parámetros como expresiones faciales, características físicas y otros elementos visuales de forma automática, reduciendo la intervención humana y mejorando la eficiencia del proceso de selección.

La optimización propuesta en este estudio busca no solo mejorar la precisión y efectividad en la selección de los candidatos, sino también transformar un proceso históricamente lento y costoso en uno ágil y eficiente, alineado con las demandas actuales del

mercado. La integración de redes neuronales convolucionales en el ámbito cinematográfico y publicitario tiene el potencial de establecer una solución innovadora que no solo beneficie a la empresa en cuestión, sino que también sirva de referente para la adopción de tecnologías emergentes en un sector tradicionalmente conservador respecto a la innovación tecnológica.

El desarrollo de la presente labor investigativa se llevará a cabo en varias fases. En primer lugar, se planteará el problema, el cual permitirá contextualizar las dificultades y limitaciones del proceso de casting en la empresa estudiada. Luego, se dará la presentación del marco teórico, donde se revisarán las teorías principales y tecnologías relacionadas con la optimización de procesos, el tratamiento de imágenes y el uso de redes neuronales. Posteriormente, se diseñará e implementará un sistema basado en CNN que optimice el proceso de aperfilamiento de imágenes. Finalmente, se presentarán los resultados obtenidos, que serán analizados y discutidos en función de su impacto en la eficiencia, la calidad y el tiempo de ejecución del proceso de casting.

Al concluir esta investigación, se espera proporcionar una solución práctica y efectiva a la problemática planteada, demostrando que la aplicación de redes neuronales convolucionales y otras tecnologías de Deep Learning puede transformar significativamente el proceso de selección en la industria cinematográfica y publicitaria del Perú. Esta tesis contribuirá al avance tecnológico en el sector, promoviendo la innovación, mejorando la agilidad de los procesos y proporcionando una mayor precisión en las decisiones de selección, lo que abriría oportunidades para el uso de estas tecnologías en otros ámbitos de la industria audiovisual.

1.1 Planteamiento del problema

Las empresas cinematográficas y publicitarias no son ajenas a la forma en la cual impacta la Tecnología de la Información y Comunicaciones (TIC) en los procesos de negocio,

y cómo estos deben adaptarse a una realidad cada vez más digitalizada. En este contexto, uno de los procesos más críticos es el de casting, ya que la correcta selección de talento es fundamental para el éxito de cualquier producción audiovisual o publicitaria. Los directores de casting y los equipos de producción deben trabajar de manera estrecha para identificar a las personas que mejor se ajusten a los roles establecidos, y que puedan dar vida a los personajes de manera efectiva y creíble. Sin embargo, se ha podido apreciar en los últimos años, el incremento de que la participación de personas en convocatorias de casting ha generado nuevos desafíos, especialmente debido al gran volumen de imágenes digitales (retratos fotográficos) que deben ser procesadas. Esto ha aumentado aún más debido a factores como el auge de las redes sociales y la multiplicación de proyectos artísticos y publicitarios.

El departamento de Casting de la empresa audiovisual Spiral Producciones se encarga de seleccionar talento para diversas producciones, tales como audiovisuales, teatrales, publicitarias y otros proyectos que requieren la participación de actores, modelos, presentadores, voces en off, entre otros profesionales. Sin embargo, este proceso enfrenta inconvenientes debido a la cantidad creciente de imágenes digitales de los participantes, lo cual dificulta el manejo y análisis de esta información, afectando tanto la eficiencia como la calidad en las selecciones.

Según Cabello (2004) uno de los grandes retos en lo que respecta a los procesos de imágenes es el uso de algoritmos de Deep Learning para el reconocimiento automático de caras humanas en imágenes digitalizadas. Este desafío se debe a la complejidad de la tarea de emular la capacidad humana para reconocer características faciales de forma automática, lo que hace que el proceso sea más susceptible a errores y dificultades.

La importancia de este reto ha impulsado la investigación en áreas como la medicina legal y forense, donde los avances en el reconocimiento facial pueden tener implicaciones económicas significativas. En este sentido, Scarel (2010) resalta que el reconocimiento facial

en Deep Learning ha ganado relevancia en diversas disciplinas, como el proceso de imágenes y extraer ciertas particularidades o características. Parte de este avance se deberá al intento de replicar el proceso de reconocimiento realizado por el cerebro humano, lo que ha permitido desarrollar técnicas cada vez más cercanas al reconocimiento visual humano.

Sin embargo, a pesar de los avances, Kloster (2023) destaca algunas limitaciones inherentes a las técnicas de Deep Learning en la clasificación automática de imágenes. Aunque estas técnicas son muy efectivas y se acercan al nivel de precisión del reconocimiento humano, siguen siendo vulnerables a lo que se denomina ejemplos adversos. Estos ejemplos son imágenes generadas a partir de otras imágenes naturales que, aunque visualmente idénticas, pueden engañar a las redes neuronales y resultar en clasificaciones erróneas con alta confianza. Esta vulnerabilidad es una preocupación importante en el proceso de tratamiento de imágenes digitales en el área de casting, ya que puede llevar a seleccionar perfiles incorrectos a pesar de la aparente exactitud en las clasificaciones.

Por otro lado, Kokkiralala (2019) subraya que las redes neuronales pueden ser susceptibles a engaños o perturbaciones que pueden comprometer la seguridad y la fiabilidad del sistema. En este sentido, una posible solución es la eliminación de ruido o distorsiones de las imágenes antes de ser procesadas por las redes neuronales. Esto mejoraría la precisión de la red, permitiéndole clasificar las imágenes de manera más efectiva. En resumen, la necesidad de optimizar el proceso de casting, haciendo uso de tecnologías avanzadas, como las redes neuronales convolucionales, se ve cada vez más urgente, ya que los métodos tradicionales no resultan ser suficiente para afrontar los desafíos que derivan del aumento de participantes en los castings y la complejidad del procesamiento de imágenes.

Es por ello que resulta fundamental proponer soluciones desde el ámbito concerniente a la Ingeniería de Sistemas y su especialización en Gestión de I.T. El desarrollo de un sistema de Deep Learning eficiente al clasificar de manera automática de imágenes en el proceso de

casting permitiría resolver varias de las dificultades actuales, mejorando la precisión en la selección de perfiles, reduciendo el tiempo de procesamiento y ofreciendo una herramienta robusta que facilite el trabajo del equipo de producción al tomar decisiones. Al aplicarse dichas tecnologías no solo beneficiaría a la empresa Spiral Producciones, sino que también podría convertirse en un referente de innovación tecnológica dentro de la industria cinematográfica y publicitaria en Perú.

1.2 Descripción del problema

La empresa de servicios audiovisuales Spiral Producciones tiene como misión buscar y descubrir la mayor cantidad de talentos y conectarlos al mercado cinematográfico y artístico peruano o extranjero.

El departamento de Casting en Spiral Producciones, tiene la responsabilidad de elegir perfiles de rostros digitalizados mediante procesos de convocatoria. Utilizando técnicas semi manuales de identificación de patrones y reconocimiento facial (aperfilamiento), busca seleccionar aquellos que mejor se adecuen a los requisitos de un papel artístico-actoral en diversos proyectos artísticos, tanto a nivel nacional como internacional. Estos proyectos pueden abarcar películas, series, videoclips, teatro o campañas publicitarias.

El esfuerzo y el tiempo de desarrollo de esta actividad se incrementó en 60% en los últimos años (antes un proceso de selección, para una convocatoria, se tardaba aproximadamente 5 días hoy, con el incremento de la demanda está tardando 8 días), esto como efecto de pandemia y el incremento en el uso de nuevos canales de contactos el aumento de la utilización de redes sociales.

Esta nueva realidad está dificultando los trabajos de clasificación, aperfilamiento y ordenamiento de los rostros digitalizados de los candidatos debido a la variedad y cantidad de imágenes a procesar (antes se procesaban aproximadamente 400 retratos de candidatos, hoy se están procesando 1500 retratos digitalizados por convocatoria). Esto ha ocasionado

inconvenientes al momento de cumplir con las fechas establecida y perder nuevos contratos con empresas artísticas.

Se puede observar que estas actividades vinculadas al proceso de aperfilamiento de retratos de candidatos están relacionados entre sí y observamos:

- La problemática en el proceso selección de retratos digitalizados se da al momento que el director de Casting requiere contar con los candidatos que cumplan con las características físicas faciales de una determinada campaña y esta no se da con prontitud, ocasionando dificultades con el cumplimiento de los compromisos y fechas establecidas con el cliente. También ocasiona molestias en los usuarios del área de casting por la gran cantidad de fotos a procesar originado por falta de una tecnología de Información que ayude con este proceso.
- Otro problema es que debido al incremento de retratos digitalizados a clasificar y los pocos recursos humanos involucrados en los procesos de aperfilamiento el índice de efectividad de selección de pre-candidatos se ha visto reducido en un 40% ocasionando una baja en la calidad del servicio.
- Las consultas a sus bases de datos de retratos digitalizados históricos, que necesariamente se tiene desarrollar antes de crear una nueva convocatoria, con el objetivo de saber si se cuenta ya con candidatos pre-seleccionados en campañas pasadas. Este proceso se hace de manera semi-manual, debido que se tiene una Excel que ayuda a clasificado los atributos faciales de cada candidato y la información no está actualizada en la mayoría de los casos, debido a que tiene no se dan abasto en procesar toda la cantidad de imágenes que se tienes y el proceso de clasificación no siempre es el más adecuado.
- Otro problema que se observa es el excesivo de tiempo requerido para la clasificación y aperfilamiento de los retratos digitalizados de los candidatos y los reportes de los

candidatos pre-seleccionados, ocasionando problemas en cumplir los tiempos establecidos con los clientes.

- Del mismo modo se identifican problemas en la actividad del guardado de la información, dado que esta actividad se hace en una PC local, el cual no cuenta las medidas de seguridad, escalamiento de arquitectura tecnológica, monitoreo de servicios, ni redundancias adecuadas para salvaguarda la información.

Por lo antes expuesto, de llegar a una solución de estos problemas identificados, se plantea el uso de la tecnología:

- ¿Una vez implementada la tecnología de Información, mejorara los tiempos del proceso de aperfilamiento?
- ¿Una vez implementada la tecnología de información, mejorarán la calidad de las consultas de los perfiles y se reducirán los errores según los requisitos del área de casting?
- ¿Una vez implementada la tecnología de información, mejorará el índice de efectividad de los perfiles en comparación con los actuales?

El cumplimiento de estos retos posee el potencial para la generación de un significativo impacto en la empresa y en el bienestar de su cartera de cliente, especialmente en un campo tan competitivo como la industria cinematográfica y publicidad.

1.3 Formulación del problema

1.3.1 Problema general

¿En qué medida el uso de las Redes Neuronales Convolucionales contribuirá a mejorar el proceso de a perfilamiento en la selección de perfiles para el área de casting de la empresa audiovisual Spiral Producciones en Lima, Perú, durante el año 2024?

1.3.2 Problema Específicos

- ¿En qué medida el uso de las Redes Neuronales Convolucionales contribuirá a mejorar los tiempos del proceso de a perfilamiento en la selección de perfiles para el área de casting?
- ¿En qué medida el uso de las Redes Neuronales Convolucionales contribuirá a reducir el índice de errores del proceso de a perfilamiento en la selección de perfiles para el área de casting?
- ¿En qué medida el uso de las Redes Neuronales Convolucionales contribuirá a aumentar el índice de efectividad del proceso de a perfilamiento en la selección de perfiles para el área de casting?

1.4 Antecedentes

1.4.1 Antecedentes internacionales

Benedikt et al. (2024) evaluó la capacidad de técnicas de aprendizaje profundo para medir la calidad de imagen tomografía en conjuntos de datos, utilizó una red neuronal convolucional 3D (3D-CNN) para esta evaluación, logrando una precisión del 92% al 96%.

Tennakoon et al. (2024) obtuvo en su publicación “Emotion-Based Movie Recommendation System”, una precisión del 78% a en el uso un sistema de recomendación de películas que utiliza las emociones del usuario para sugerir películas usando Algoritmos de tipo CNN.

Para Senousy (2023) proporciona nuevas técnicas con un sistema de clasificación de imágenes que tengan características de diseño de aprendizaje consciente del contexto(Context awareness), el cual agrega inteligencia y enriquece los datos para aplicaciones, servicios y sistemas al tiempo que permite que los algoritmos subyacentes detecten cambios dinámicos en los flujos de datos entrantes, con el objetivo de adicionar características de confiabilidad mediante la cuantificación de la incertidumbre, generalización y robustez mediante una

novedosa estrategia de conjunto dinámico, y acción automatizada mediante la optimización de la cuantificación de la incertidumbre. Las metas de dicha labor investigativa se establecieron para que pueda cumplirse con el objetivo mencionado anteriormente.

Thunuguntla et al. (2023) generó modelos de tipo CNN para el sector publicitario para mejorar la experiencia del cliente en manejo de anuncios. Los modelos propuestos alcanzan una alta precisión del 99.93%, mostrando buenos resultados en diversas categorías de anuncios.

Roy et al. (2022) para la identificación de enfermedades de plantas usando el procesamiento de imágenes. Observo un impacto positivo usando la CNN y el algoritmo You Only Look Once (YOLOv4), obtuvo un valor de precisión del 90.33%, una puntuación F1 del 93.64% y un valor promedio de precisión (mAP) del 96.29%.

Según Waldie (2021) presenta la importancia de las CNN (Convolutional Neural Network, que se traduce como "Red Neuronal Convolutacional" en español) y su drástica mejora en la precisión y confiabilidad en el procesamiento automático de imágenes automáticas y procesamiento de vídeo, pero su usabilidad está limitada debido a los requisitos de hardware.

Para Xu (2021) indica que uno de los desafíos del aprendizaje profundo es poder aprovechar las Redes Neuronales Convolucionales (CNNs) para aprender automáticamente en representaciones de múltiples niveles a partir de datos brutos mediante el uso de múltiples capas lineales y no lineales. También indica que las CNN profundas son capaces de descubrir estructuras de datos complejas sin necesidad de diseñar manualmente características, por lo que son aplicables a muchos dominios.

Para Kokkiralala (2019) presenta una arquitectura de eliminación de ruido que extrae el ruido de una imagen, lo que permite que la red neuronal convolucionales profundas (CNN), cuyo uso principal es clasificar imágenes, etiquete con precisión una imagen. Las redes neuronales convolucionales profundas (ConvNets) actualmente se encargan de los problemas de reconstrucción de imágenes inversas de vanguardia, es decir, eliminación de ruido.

Rami et al. (2019) logró en su estudio “Facial Emotion Recognition Using NLPCA and SVM”, una mejor precisión en el reconocimiento y clasificación de emociones faciales con muestras de entrenamiento limitadas y bajo iluminación variable. Usando algoritmos de tipo CNN, lograron tasas de reconocimiento promedio del 97.3% y 98%.

Wang et al. (2019) propuso un método de aprendizaje automático para identificar las intenciones en grandes volúmenes de contenidos (datos e imágenes) en el contenido de datos redes sociales. Usando Modelos de tipo CNN reflejo las características semánticas, y la poda del árbol de decisiones reduciendo la complejidad computacional. Obteniendo una eficiencia en la identificación de intenciones de marketing en un 5% y una reducción en tiempo de clasificación y ejecución en un 20%, demostrando su eficacia y eficiencia.

Para Belver (2016) precisa que El estimador de edad puede utilizar un enfoque de aprendizaje automático para entrenar un modelo con las características extraídas y hacer predicciones de edad para rostros consultados utilizando el modelo entrenado. En términos generales, la estimación de edad se puede considerar como un problema de clasificación multiclase, un problema de regresión o una combinación de ambos. El enfoque basado en antropometría depende principalmente de las medidas y distancias de diferentes puntos de referencia faciales. Los enfoques basados en antropometría pueden ser útiles para bebés, niños y adultos jóvenes, pero son poco prácticos para adultos, ya que la apariencia de su piel facial es la principal fuente de información sobre etnia, género y edad.

1.4.2. Antecedentes nacionales

Según Fernández (2024) estudio para diagnosticar y detectar la COVID - 19 usando parámetros de tipo DL y CNN para el análisis de tomografías usando modelos de tipos Google Net, obtuvo una precisión superior al 90%.

Acuña et al. (2024) en su publicación “A Machine Learning Approach for Predicting Caco-2 Cell Permeability in Natural Products from the Biodiversity in Perú”, uso modelos CNN (SVM–RF–GBM) mostró un rendimiento 76%.

Palomino et al. (2023) desarrolló un estudio se enfocó en determinar el área de acero de refuerzo en vigas rectangulares de concreto armado, crucial debido al incumplimiento significativo de regulaciones técnicas en estructuras residenciales en Perú. Usando modelos estudio se enfocó en determinar el área de acero de refuerzo en vigas rectangulares de concreto armado, crucial debido al incumplimiento significativo de regulaciones técnicas en estructuras residenciales en Perú.

Según Balbuena (2022) se desarrollan modelos para la creación, evaluación y elección de diferentes tipos de RNN y CNN que se utilizan para identificar emociones en expresiones faciales y textos. Estos modelos pueden integrarse como componentes adicionales en agentes conversacionales en un plazo real, sean robots sociales o chatbots. Esto permite que dichos agentes comprendan las emociones de todo individuo durante la interacción, lo que les habilita para ofrecer respuestas empáticas al conocer esos estados emocionales.

Para Cadena (2021) se crea un método de identificación facial que alcanza una efectividad superior al 97% mediante el uso de algoritmos de wavelets de Gabor y también de Máquinas de Vectores de Soporte con diversas configuraciones de kernels, aplicando inclusive imágenes en 3D. Este enfoque busca mejorar la seguridad pública al analizar imágenes faciales de individuos, empleando técnicas estadísticas y matemáticas para extraer particularidades y clasificar las imágenes, con el objetivo de determinar si una persona pertenece a una categoría específica y, en última instancia, identificar su persona.

Por su parte, J. García (2019) se propone parámetros algorítmicos que facilita el hecho de poder identificar automáticamente las imágenes en movimiento tomando como punto de partida las grabaciones de las distintas etapas que se producen durante la aplicación técnicas y

estrategias de recepción en voleibol. Esto se logra mediante el estudio minucioso del movimiento en video utilizando a través de profundas redes neuronales y el algoritmo You Only Look Once (YOLO), el cual se conoce comúnmente como el mecanismo de código abierto diseñado para detectar cosas que se encuentren en movimiento. Además, se emplean módulos de Pytorch para entrenar el modelo y se aplican mecanismos que permitan analizar tanto por fotogramas individuales como mediante la aplicación del Early Fusión.

1.5 Justificación de la investigación

1.5.1 Justificación practica

La justificación práctica de la tesis sobre la optimización del proceso de perfilamiento y tratamiento de imágenes utilizando redes neuronales convolucionales radica en los beneficios tangibles que esta solución aporta a las entidades relacionadas con la industria cinematográfica y publicitaria en Lima, Perú. La implementación de redes neuronales convolucionales permite automatizar y mejorar significativamente el procesamiento de imágenes, lo que resulta en una mayor rapidez en los plazos de entrega y mejorar los niveles de calidad visual, fundamentales en un entorno tan competitivo. Además, al reducir la intervención manual en los procesos de tratamiento, se disminuye la probabilidad de errores humanos, lo que contribuye a una mayor precisión y consistencia en los resultados. Esta optimización también implica una reducción de costos operativos, lo que favorece la rentabilidad de toda entidad. En el actual contexto, donde los avances tecnológicos son un factor clave para la competitividad, esta solución práctica no solo mejora los procesos internos, sino que también prepara a las empresas para estar a la vanguardia en la utilización de inteligencia artificial que se aplica a la industria audiovisual.

1.5.2 Justificación metodológica

La justificación metodológica se basa en el tipo aplicado y el diseño experimental seleccionado para abordar el problema planteado, que busca optimizar el proceso de perfilamiento y tratamiento de imágenes utilizando redes neuronales convolucionales en la

industria cinematográfica y publicitaria. El enfoque aplicado permite utilizar los conocimientos y técnicas de la inteligencia artificial, específicamente las redes neuronales, para resolver un problema real y concreto en una empresa del sector. El diseño experimental es adecuado porque permite realizar pruebas controladas y sistemáticas para evaluar cómo la implementación de redes neuronales impacta en la eficiencia y calidad de los procesos de tratamiento de imágenes. A través de la manipulación de la variable independiente, se podrá establecer una relación clara entre las modificaciones realizadas y los beneficios obtenidos. Este enfoque metodológico garantiza que los resultados sean válidos y replicables, permitiendo obtener conclusiones prácticas y aplicables directamente a las necesidades de la industria audiovisual.

1.5.3 Justificación teórica

La justificación teórica de la tesis se fundamenta en varias teorías generales que explican cómo los avances tecnológicos pueden optimizar los procesos en la industria cinematográfica y publicitaria.

En primer lugar, la Teoría de la Optimización de Procesos de George Dantzig (2002) introduce el concepto de programación lineal y el Método Simplex, establece las bases para mejorar la eficiencia en los procesos organizacionales. En este caso, la optimización del tratamiento de imágenes busca reducir los tiempos y costos asociados, mejorando la eficiencia operativa y reduciendo los esfuerzos manuales en la industria cinematográfica y publicitaria.

La Teoría de Redes Neuronales Artificiales, propuesta por Geoffrey Hinton, sostiene que las redes neuronales son herramientas poderosas para resolver problemas complejos como el proceso y estudio de imágenes. En este contexto, la utilización de redes neuronales convolucionales (CNN) permite automatizar el tratamiento de imágenes, mejorando la calidad visual de las producciones y reduciendo los tiempos de edición al identificar de forma eficiente patrones visuales que de otra manera requerirían intervención manual.

La Teoría del Procesamiento de Imágenes, desarrollada por Rafael C. González y Richard E. Woods ofrece las técnicas fundamentales para mejorar, analizar y manipular imágenes digitales. Esta teoría es crucial para la tesis, ya que permite implementar algoritmos avanzados que optimicen el tratamiento y perfilamiento de las imágenes en la producción cinematográfica y publicitaria, mejorando así la calidad visual de los contenidos.

La Teoría de la Inteligencia Artificial (IA), formulada a través de John McCarthy, explica cómo las máquinas pueden emular aspectos de la inteligencia de las personas como la toma de decisiones y el razonamiento. En este caso, la aplicación de IA al tratamiento de imágenes permite que los sistemas aprendan y optimicen sus procesos de forma autónoma, mejorando continuamente los resultados sin intervención humana directa.

La Teoría de la Gestión de Tecnologías de la Información (TI) se enfoca en la utilización eficiente de las tecnologías dentro de las organizaciones. En el contexto de esta tesis, permite entender cómo las empresas del sector cinematográfico y publicitario pueden integrar tecnologías avanzadas, como las redes neuronales, en sus procesos productivos para aumentar su competitividad y mejorar la eficiencia.

La Teoría de la Innovación Tecnológica, propuesta por Joseph Schumpeter, es esencial para comprender cómo la tecnología impulsa el cambio en las empresas. Esta teoría destaca cómo la adopción de innovaciones tecnológicas, como las redes neuronales para el tratamiento de imágenes, permite a las empresas generar una ventaja competitiva, mejorando los niveles de calidad de diversos productos y abrir nuevas posibilidades en la creación de contenido audiovisual.

Por último, la Teoría del Aprendizaje Automático (Machine Learning), con contribuciones de Arthur Samuel y otros investigadores, explica cómo las máquinas pueden contar con el debido aprendizaje de la información mejorando con el tiempo los resultados. En este caso, el aprendizaje automático es crucial para el entrenamiento de redes neuronales

convolucionales, que permiten el eficiente proceso de imágenes, disminuyendo el requerimiento de cualquier tipo de intervención manual para optimizar el tratamiento de las mismas.

1.5.4 Justificación social

El estudio tiene un impacto social significativo mejorando los niveles de eficiencia y calidad en la producción visual, la misma que va permitir a las entidades que puedan ser más rentables y competitivas. Esta tecnología no solo agiliza los procesos, reduciendo costos y tiempos de producción, sino que también promueve el desarrollo de nuevas capacidades tecnológicas en el país, impulsando la innovación y creando empleos calificados. Además, hace accesible la tecnología avanzada a medianas y pequeñas empresas, democratizando el uso de herramientas de alto nivel y fomentando la inclusión digital en la industria. Al mismo tiempo, fortalece la visibilidad de la cultura peruana a través de producciones de mayor calidad, contribuyendo a su posicionamiento en mercados internacionales y al reconocimiento global de su patrimonio cultural.

1.5.5 Importancia de la investigación

Se fundamenta en la capacidad para la contribución de la consecución de diversos ODS señalados a través de las Naciones Unidas, especialmente en el rubro de la industria publicitaria y cinematográfica en Lima, Perú.

En primer lugar, optimizar los procedimientos para tratar las imágenes utilizando redes neuronales podrá contribuir al ODS 9: Industria, Innovación e Infraestructura, puesto que promoverá que se innove la tecnología dentro del sector audiovisual. Al aplicar adecuadamente la inteligencia artificial mejora la competitividad de las empresas, permitiendo la implementación de soluciones tecnológicas avanzadas que refuerzan la infraestructura y la capacidad productiva local.

Asimismo, al hacer más accesible la tecnología de procesamiento de imágenes, se fomenta la ODS 8: Trabajo Decente y Crecimiento Económico, puesto que el hecho de optimizar los procedimientos reduce costos y plazos, lo cual favorece el crecimiento y rentabilidad de toda entidad. Esto, a su vez, genera oportunidades de trabajo mejorando las condiciones de carácter laboral en el sector tecnológico y creativo.

En el ámbito social, la investigación tiene un impacto en el ODS 10: Reducción de las Desigualdades, al democratizar el acceso a tecnologías avanzadas, permitiendo que pequeñas y medianas empresas dentro del sector audiovisual puedan competir igualitariamente con otras entidades de mayor magnitud. Esto fomenta una mayor equidad en el acceso a recursos y oportunidades.

Además, la mejora en la calidad de las producciones audiovisuales fortalece la ODS 16: Paz, Justicia e Instituciones Sólidas, en vista que el sector audiovisual desempeña un rol crucial al construir la identidad cultural inclusiva y diversa. Una industria más eficiente y tecnológicamente avanzada tiene la capacidad de representar mejor la diversidad cultural, promoviendo la justicia social y el respeto por las distintas identidades dentro de la población.

1.6 Limitaciones de la investigación

- La escasa bibliografía académica en los repositorios de las facultades de pregrado y posgrado de las principales entidades universitarias del país para investigación de tecnología de la información aplicadas a empresas de giros de la publicidad y/o del giro audio visual aplicando algoritmos de inteligencia artificial.
- Las fuentes de datos para esta investigación están conformadas por las imágenes digitalizadas de rostros humanos recepcionadas entre las convocatorias de los procesos de casting de los años 2021 – 2023 la empresa audiovisual Spiral Producciones Lima, Perú.
- Los datos privados de los candidatos

- Este trabajo de investigación se desarrollará para la empresa audiovisual Spiral producciones
- Este trabajo de investigación se desarrollará en la plataforma Cloud Computing de la empresa Google (Google Cloud Platform - GCP)
- En este trabajo, no busca crear ni modificar algoritmos, sino más bien se explora un conjunto de algoritmos de reconocimiento de imágenes que se emplean habitualmente en aplicaciones de inteligencia artificial, así como la forma en la cual impacta en el proceso abarcado en la presente investigación.
- Para salvar guardar la información utilizada en este trabajo se firmó un acuerdo de confidencialidad con la empresa investigada por el uso y manipuleo de los datos empleados
- Se han definido una población general de 300 imágenes.
- El alcance de este trabajo de investigación se ha limitado a la población general debido a restricciones logísticas y financieras, y se centrará en la asesoría tecnológica para el diseño de una solución en el uso Redes Neuronales Convencionales (CNN) y Cloud Computing para mejorar el aperfilamiento y tratamiento de imágenes en los procesos de casting. Cabe destacar que no se llevará a cabo un despliegue completo de la plataforma, ya que este estudio se ha desarrollado únicamente como una demostración inicial del concepto.

1.7 Objetivos de la investigación

1.7.1 Objetivo general

Determinar el grado de influencia que ejercerá la implementación del uso de las Redes Neuronales Convolucionales para mejorar el proceso de aperfilamiento en la selección de perfiles para el área de casting de la empresa audiovisual Spiral Producciones en Lima, Perú, durante el año 2024.

1.7.2 Objetivos específicos

- Determinar el grado de influencia que ejercerá la implementación del uso de las Redes Neuronales Convolucionales para mejorar los tiempos del proceso de perfilamiento en la selección de perfiles para el área de casting.
- Determinar el grado de influencia que ejercerá la implementación del uso de las Redes Neuronales Convolucionales para reducir el índice de errores del proceso de a perfilamiento en la selección de perfiles para el área de casting.
- Determinar el grado de influencia que ejercerá la implementación del uso de las Redes Neuronales Convolucionales para aumentar el índice de efectividad del proceso de a perfilamiento en la selección de perfiles para el área de casting.

1.8 Hipótesis

1.8.1 Hipótesis general

La implementación del uso de las Redes Neuronales Convolucionales contribuirá en mejorar el proceso de a perfilamiento en la selección de perfiles para el área de casting de la empresa audiovisual Spiral Producciones en Lima, Perú, durante el año 2024.

1.8.2 Hipótesis específicas

- La implementación del uso de las Redes Neuronales Convolucionales contribuirá en mejorar los tiempos del proceso de a perfilamiento en la selección de perfiles para el área de casting.
- La implementación del uso de las Redes Neuronales Convolucionales contribuirá en reducir el índice de errores del proceso de a perfilamiento en la selección de perfiles para el área de casting.
- La implementación del uso de las Redes Neuronales Convolucionales contribuirá en aumentar el índice de efectividad del proceso de a perfilamiento en la selección de perfiles para el área de casting.

II. MARCO TEÓRICO

2.1 Marco conceptual

2.1.1 Teorías generales del estudio

Teoría de la optimización de procesos de Dantzig. Esta teoría se centra en la mejora de los procedimientos y flujos de trabajo dentro de una organización para aumentar los niveles de eficiencia, reduciendo los costos, mejorando los niveles de calidad y minimizar los tiempos de ejecución. En el contexto del estudio, al optimizar procedimientos de perfilamiento y el hecho de tratar las imágenes mediante redes neuronales convolucionales busca hacer más eficiente el trabajo en la industria cinematográfica y publicitaria. La optimización en este caso no solo se refiere a la velocidad de procesamiento, sino también a la calidad de las imágenes y la reducción de errores en el tratamiento

Teoría de Redes Neuronales Artificiales. Se definen como sistemas de aprendizaje que suelen inspirarse en el cerebro humano, que buscan emular las funciones de las neuronas para procesar información. Asimismo, las redes neuronales convolucionales (CNN) son una arquitectura específica de las ANN utilizadas principalmente para procesar determinadas imágenes facilitando que se reconozca el patrón. Esta teoría está relacionada con el aprendizaje de manera automática y el deep learning, donde las redes neuronales se entrenan para realizar tareas específicas de clasificación, segmentación y análisis de imágenes. El uso de CNN está dirigido a mejorar el proceso de perfilamiento y tratamiento de imágenes en la industria cinematográfica y publicitaria (Hinton, 2002).

Teoría del Procesamiento de Imágenes. Está referida a la agrupación de técnicas utilizadas en la mejora, manipulación o estudio de imágenes digitales. Esto incluye una serie de algoritmos y métodos que permiten modificar o extraer información de imágenes, como el ajuste de contraste, suprimiendo el ruido, segmentar objetos y la mejora de calidad visual. En

el estudio, el procesamiento de imágenes será clave para optimizar la calidad visual y la efectividad de los tratamientos aplicados a las imágenes cinematográficas y publicitarias, mediante el uso de redes neuronales convolucionales (González y Thomason, 1978).

Teoría de la Inteligencia Artificial (IA). Está referida a la simulación de procedimientos ligadas a la inteligencia humana por parte de máquinas, con mayor énfasis al tomar decisiones, reconocer determinados patrones y también lo que respecta a la resolución de diversas situaciones problemáticas. La IA en el procesamiento de imágenes permite la mejora y automatización de procedimientos, asimismo, clasificar y mejorar la calidad de las imágenes en la producción cinematográfica y publicitaria. La IA proporciona a las empresas herramientas poderosas para incrementar la calidad y eficiencia de los productos audiovisuales (McCarthy, 2007).

Teoría de la Gestión de Tecnologías de la Información (TI). Esta teoría se centra en el uso eficiente y estratégico de la tecnología para gestionar la información dentro de una organización. En el estudio, la gestión de TI tiene un papel crucial en la integración de nuevas tecnologías (como las redes neuronales convolucionales) en los procedimientos de producción de la entidad cinematográfica y publicitaria. Además, la teoría de la gestión de TI busca alinear las estrategias tecnológicas con los objetivos empresariales, asegurando que, al adoptar tecnologías nuevas, tal como se da en la IA, esté orientada a mejorar la competitividad y los resultados organizacionales (Galliers et al., 2020).

Teoría de la Innovación Tecnológica. Está referida al hecho de introducir nuevas metodologías, productos o procesos que puedan mejorar significativamente las capacidades de una organización. En el estudio, la utilización de redes neuronales convolucionales en el tratamiento de imágenes es una forma de innovación tecnológica en el sector cinematográfico y publicitario, que permite a las entidades que se mantengan en competencia dentro de un dinámico mercado y en evolución constante (Shumpeter, 1996).

Teoría del Aprendizaje Automático (Machine Learning). Se define como el enfoque dentro de la IA que va permitir el aprendizaje de las máquinas con respecto a los datos sin necesidad de que sean programadas explícitamente. El aprendizaje automático es fundamental para entrenar las redes neuronales convolucionales en la mejora del tratamiento de imágenes, permitiendo que el sistema identifique patrones y mejore el procesamiento de imágenes en función de los datos proporcionados. Además, es un enfoque dentro de la IA que permitirá que las máquinas puedan aprender de los datos sin necesidad de que sean programadas de manera explícita. En el estudio, el aprendizaje automático es fundamental para entrenar las redes neuronales convolucionales en la mejora del tratamiento de imágenes, permitiendo que el sistema identifique patrones y mejore el procesamiento de imágenes en función de los datos proporcionados (Kyocera, s.f.).

2.1.2 Redes Neuronales Convulsiónales (CNN)

El reconocimiento facial basado en datos reales, imágenes capturadas, imágenes de sensores y datos de bases de datos es un problema desafiante debido a la gran variación en la apariencia facial, los efectos de iluminación y la complejidad del fondo de la imagen. El reconocimiento facial y el uso de los sistemas de aprendizaje profundo (Deep Learning) con el uso de Inteligencia Artificial (IA) y las arquitecturas de redes neuronales convolucionales (CNN), es una de las aplicaciones más efectivas y relevantes. Procesamiento de imágenes y sistemas de reconocimiento facial (Kasar et al., 2016).

El uso creciente de la inteligencia artificial (IA) en marketing puede catalizar, expandir y transformar los mercados. Las herramientas y dispositivos de inteligencia artificial en marketing están estrechamente relacionados con el comportamiento del consumidor. Empresas y marcas han podido beneficiarse del uso de esta tecnología. Sin embargo, actualmente hay poca investigación sobre la aplicación de la inteligencia artificial en las decisiones de marketing. Estos estudios son relativamente nuevos y raros, especialmente en comparación con

otros temas. Comprender el proceso de la inteligencia artificial en marketing es inevitable. El objetivo es analizar y determinar la dirección de la investigación de la inteligencia artificial en marketing, aclarar la principal contribución e impacto de la inteligencia artificial en marketing y ayudar a identificar futuros temas de investigación. Los debates sobre investigación en todos los campos del conocimiento deben llevarse a cabo de manera sistemática y objetiva para mejorar y actualizar la búsqueda continua de conocimientos. La conclusión es que el marketing impulsado por la IA puede resolver muchos problemas tradicionales y digitales. Además del impacto futuro de la inteligencia artificial en el marketing, también es importante su impacto en la disciplina de la inteligencia artificial (Rosario, 2021).

La integración de la tecnología de (IA), la Deep Learning y el ámbito de la televisión y cine provocaron cambios importantes en la producción y diseño de la programación televisiva, además de crear una variedad de nuevos medios de inteligencia artificial. La popularización de la tecnología de IA ha mejorado la calidad de la producción cinematográfica y televisiva. Por otro lado, la industria de la animación se ha expandido significativamente y la cantidad de películas aumenta cada año. Encontrar las películas animadas favoritas del usuario entre los muchos informes de películas animadas se ha convertido en un gran obstáculo. La inteligencia artificial se utiliza para acelerar la creación de efectos visuales. La eficiencia del proceso de fabricación se puede mejorar a través de la utilización de diversos algoritmos de aprendizaje de manera automática capacitados que faciliten ayudar con tareas como la observación dinámica, el seguimiento de objetos e incluso la generación de texturas realistas (Farzadfard, 2021).

2.1.3 Optimización del proceso de a perfilamiento y tratamiento de imágenes.

Los procedimientos de aperfilamiento y tratamiento de imágenes en las tareas de reconocimiento de patrones sobre un rostro o imagen usando la visión por computadora, las redes neuronales, la ciencia cognitiva, la neurociencia, la psicología y la fisiología, es un

proceso especializado, no meramente una aplicación del proceso general de reconocimiento de objetos. También representa las capacidades más sobresalientes de la visión humana. El reconocimiento facial ha sido uno de los campos de estudio de mayor interés e importancia en las últimas dos décadas. Las razones de esto se deben a la necesidad de sistemas de reconocimiento automático y vigilancia, el interés en el sistema visual humano en el reconocimiento facial y el diseño de interfaces humano-computadora, entre otros (Arya, 2018).

2.1.4. Dimensiones de la Redes Neuronales Convulsiónales (CNN)

Rendimiento del modelo. En el campo de la IA, los algoritmos automáticos de aprendizaje, así como el profundo enfrentan desafíos importantes cuando trabajan con datos donde algunas categorías están menos representadas que otras. Incluso después de utilizar métodos para manejar datos desequilibrados, esta representación de clases desequilibrada a menudo da como resultado una degradación significativa del rendimiento del modelo utilizado. Esta pregunta lleva a los investigadores a utilizar diferentes algoritmos, pero la principal incertidumbre es: ¿qué métricas nos permiten comparar adecuadamente los resultados y cuáles son las mejores métricas para elegir un clasificador adecuado? (Borja et al., 2020).

2.1.5 Dimensiones de la Optimización del proceso de a perfilamiento y tratamiento de imágenes.

Eficiencia. En todo proceso, es hacer las cosas de la forma más económica (es decir, buena relación entre entrada y salida) (Blasch et al., 2018).

Satisfacción del usuario de la gestión. Un estudio realizado sobre el desarrollo de tecnologías y plataformas digitales encontró que todos los atributos clave del servicio tienen un impacto positivo en la satisfacción general del cliente. En cuanto a las dimensiones culturales, la distancia de poder, evitación de la incertidumbre e individualismo pueden afectar negativamente la satisfacción general con el sistema (Mariani, 2019).

2.1.6 Procesos Cognitivos Asociados a la Inteligencia Humana

Inteligencia Artificial (IA). Según AWS Corp. (2024) la IA es una rama concerniente a la informática que se ocupa de resolver problemáticas cognitivas vinculados a la inteligencia de las personas, tales como el reconocimiento, percepción y aprendizaje. Las empresas modernas acumulan grandes volúmenes de información que provienen de diversas fuentes, incluyendo inteligencia en los sensores, creación de contenido por personas, mecanismos de registros y supervisión del sistema. El propósito de la IA es desarrollar mecanismos que aprendan de manera autónoma y extraigan significado de esa información. Posteriormente, la IA puede aplicar este conocimiento para abordar nuevos desafíos de manera similar a como lo harían los seres humanos. Por ejemplo, la tecnología de IA puede interactuar de forma relevante en conversaciones de personas, generar textos e imágenes originales, así como el hecho de la toma de decisiones que se basan en información en tiempo real. Su empresa puede incorporar funcionalidades de IA en su aplicación para mejorar los procedimientos de carácter comercial, enriquecer la experiencia de la clientela y fomentar la innovación.

Aprendizaje Automático (Machine Learning). Según Oracle Latan. (s.f.) el aprendizaje automático (ML) es una subdisciplina de la IA que se dedica a crear sistemas capaces de mejorar o aprender su desempeño a partir de la información que procesan. La IA es un concepto amplio que abarca máquinas o sistemas que replican la inteligencia de las personas. Aunque la IA y el aprendizaje automático suelen mencionarse juntos y a veces se utilizan como sinónimos, no son lo mismo. Es fundamental destacar que, aunque la totalidad del aprendizaje automático forma parte de la IA, no toda la IA se basa en el aprendizaje automático. Hoy en día, el aprendizaje automático está presente en muchos aspectos de nuestra vida. Al interactuar con su entidad bancaria, realizar compras en línea o utilizar plataformas de redes sociales, se aplican algoritmos automáticos de aprendizaje para hacer que la experiencia pueda darse de manera más segura, fluida y eficiente. Las tecnologías de aprendizaje

automático están avanzando de manera rápida y recién se ha comenzado a explorar su verdadero potencial. Tipos de ML:

- Los algoritmos de aprendizaje automático supervisados. Son técnicas para entrenar modelos de IA con el objetivo de desarrollar predicciones o tendencias de datos etiquetados. Por ejemplo, estas técnicas incluyen algoritmos como la regresión lineal, Árboles de Decisión y Random Forests, regresión logística, la clasificación de clases múltiples y las máquinas de vectores de soporte (SVM)
- Los algoritmos de aprendizaje automático No supervisados. Estos métodos facilitan la capacidad de reconocer patrones y procesos complejos sin la supervisión continua y directa de una persona, también está referido a un procedimiento de entrenamiento que utiliza información que carecen de resultados y etiquetas claramente establecidos.
- Algunas técnicas usadas. Son K-Means Clustering, Hierarchical Clustering, Expectation-Maximization (EM), Principal Component Analysis (PCA), t-Distributed Stochastic Neighbor Embedding (t-SNE), Self-Organizing Maps (SOM), Anomaly Detection, Association Rule Learning (Apriori), y Autoencoder-based Clustering
- Los algoritmos de aprendizaje automático por refuerzo. Se conoce comúnmente como la técnica que vincula valores de recompensa a diversas acciones que un algoritmo debe ejecutar. Así, la meta del modelo es reunir la mayor cantidad de puntos de recompensa factible y lograr el objetivo final. En los últimos diez años, la mayor parte de las aplicaciones prácticas de este tipo de aprendizaje se han desarrollado en el ámbito de los videojuegos. Los algoritmos actuales de aprendizaje por refuerzo obtienen resultados sobresalientes en juegos tanto clásicos como contemporáneos, frecuentemente superando a sus equivalentes.

Aprendizaje Profundo (Deep Learning). Según AWS Corp. (2024) es un enfoque de inteligencia artificial (IA) que se basa en el funcionamiento del cerebro de las personas y capacita a las PCs para manejar información. Los modelos de esta técnica son capaces de reconocer complejos patrones en texto, imágenes, sonidos y diversos tipos de información, lo que les permite producir análisis y precisas predicciones. Además, se pueden aplicar métodos de profundo aprendizaje para llevar a cabo tareas que generalmente demandan inteligencia de las personas, como la descripción de imágenes o la conversión de grabaciones de audio a texto.

Las técnicas más usadas para el tratamiento de imágenes, y la desarrolla este trabajo de investigación, es Convolutional Neural Networks (CNNs), otras técnicas son: Feedforward Neural Networks (FNNs), Multi-Layer Perceptrons (MLPs), Residual Networks (ResNets), Recurrent Neural Networks (RNNs).

2.1.7 Redes Neuronales Convulsiónales (CNN)

De acuerdo a Yanan et al. (2020) las Redes Neuronales Convolucionales (CNN) es una técnica dominante basados en algoritmos del aprendizaje profundo y han demostrado una notable superioridad en diversas aplicaciones del mundo real sobre la mayoría de los enfoques de aprendizaje automático.

Sin embargo, el rendimiento de las CNN depende en gran medida de sus arquitecturas tecnológicas donde se despliegan.

Diferentes arquitecturas de CNN pre entrenadas, como VGG-16, ResNet50, Inceptionv3 y EfficientNet, han mostrado un rendimiento excepcional. Estos modelos pueden ajustarse a nuevas tareas con una cantidad relativamente pequeña de datos mediante un proceso llamado ajuste fino.

Según Saha (2018) detalla los elementos de la arquitectura de la CNN con los siguientes conceptos:

Capas convolucionales. Este es el componente inicial de una CNN. Como sugiere su nombre, la principal operación matemática que realiza se conoce como convolución, que consiste en aplicar una función de una deslizante ventana sobre un parámetro de píxeles que representará la imagen. Por otra parte, la función que se desliza sobre la matriz se llama núcleo o filtro, y ambos términos son intercambiables.

En la capa convolucional, se emplean varios filtros de tamaño uniforme, y cada uno se utiliza para detectar un patrón específico en la imagen, como la curvatura de los dígitos, los bordes, la forma completa de los dígitos, entre otros.

En otras palabras, la capa convolucional se usan pequeñas cuadrículas (conocidas como filtros o *núcleos*) que se mueven sobre la imagen. Cada una de estas cuadrículas actúa como una *mini lupa que busca patrones específicos en la imagen*, como líneas, curvas o formas. A medida que se desplaza por la imagen, genera una nueva cuadrícula que resalta los lugares donde se encuentran estos patrones.

Consideremos también el núcleo empleado en la convolución. *Es una matriz de 3×3* . Los pesos de cada elemento del núcleo se muestran en la cuadrícula, donde las cuadrículas negras representan pesos de valor cero y las cuadrículas blancas representan pesos de valor uno (pasando por los grises 0.12, 0.13, 0.44, 0.63...).

La forma de proceder es: Primero, la red toma los píxeles de la imagen como entrada. Cuando se tiene la imagen de sólo 32×32 píxeles de ancho y alto, esto corresponde a 1024 neuronas. Es decir, se tendrá un color (escala de grises). Si se tiene la imagen en color, se utilizará 3 canales (azul, verde y rojo) y luego se utilizará $32 \times 32 \times 3 = 3072$ neuronas de entrada. Esta es la capa de entrada. Se utilizará la imagen con solo 1 color.

Ahora, hay que considerar que las matrices utilizadas en las CNN (Convolutional Neural Networks) no se limitan exclusivamente a un tamaño de 3×3 . Aunque los núcleos de convolución de 3×3 son muy comunes y populares debido a su eficacia en la detección de

patrones y características a diferentes escalas, también se utilizan núcleos de otros tamaños, como 1x1, 5x5, o 7x7, dependiendo de la arquitectura y la tarea específica, por ejemplo, tenemos:

- Núcleos 1x1: Se utilizan para reducir la dimensionalidad sin perder información espacial.
- Núcleos 3x3: Son estándar y muy efectivos para captar detalles locales en la imagen.
- Núcleos 5x5 o 7x7: Se usan para capturar características más amplias y contextos más globales en la imagen.

Tener en consideración que el tamaño del núcleo depende del diseño de la red y del tipo de características que se desea capturar. En la práctica, los pesos de los núcleos se ajustan durante el entrenamiento de la red neuronal. Utilizando estas dos matrices, se puede realizar la operación de convolución mediante el siguiente procedimiento:

- Posicionar la matriz del núcleo en la esquina superior izquierda de la matriz de imagen.
- Aplicar el producto de Hadamard entre la matriz del núcleo y la porción correspondiente de la matriz de imagen.
- Sumar los valores obtenidos en los productos.
- Asignar el valor resultante a la posición correspondiente (esquina superior izquierda) en la matriz convolucionada.
- Mover el núcleo a la siguiente posición en la imagen, según el tamaño de la ventana deslizante.
- Repetir los pasos del 1 al 5 hasta cubrir toda la matriz de imagen.

Otro nombre relacionado con los núcleos es detector de características porque los pesos se pueden ajustar para detectar características específicas en la imagen de entrada, como el

valor promedio de los píxeles del núcleo vecinos, que se pueden usar para desenfocar la imagen de entrada o realizar la detección de bordes.

- Función de activación. La función de activación ReLU se aplica después de cada operación de plegado. Esta característica ayuda a la red a aprender relaciones no lineales entre características de la imagen, lo que hace que la red sea más sólida a la hora de identificar diferentes patrones. También ayuda a mitigar los problemas de desvanecimiento del gradiente.
- Fusionar capas. El propósito de la capa de agrupación es extraer las características más importantes de la matriz convolucional. Esto se hace mediante el uso de algunos pasos de agrupación que reduce las dimensiones espaciales de las características (features) de una imagen mientras retiene la información más importante. La agrupación también consiste en reducir el sobreajuste.

Las funciones agregadas más utilizadas son:

- Max-pooling, es decir, el valor máximo del mapa de objetos
- La suma es la suma de todos los valores en el mapa de características.
- El promedio combinado es el promedio de todos los valores.

Además, el tamaño del mapa de objetos se reduce mediante el uso de la función de combinación. La última capa de agrupación aplanar el mapa de características para que pueda ser procesado por la capa completamente agrupada.

El filtro de max pooling examina un bloque de 2 x 2 píxeles en una imagen o mapa de características. El valor máximo se selecciona en cada bloque. Este filtro se aplica a cada zona de la imagen de forma deslizante. Un paso de 2 significa que el filtro 2x2 se mueve horizontal y verticalmente en incrementos de 2px (2 de alto por 2 de ancho = 4 píxeles). En lugar de mover píxel a píxel, el filtro mueve 4 píxeles a la vez, lo que reduce el tamaño espacial del mapa de

características resultante, e iremos preservando el valor “más alto” de entre esos 4 píxeles (por eso lo de “Max”)

- **Capa completamente conectada.** Estas capas se encuentran en la última capa de la red neuronal convolucional y su entrada corresponde a la matriz unidimensional aplanada producida por la última capa de agrupación. Se les aplica una función de activación ReLU (Rectifier Linear Unit) para lograr la no linealidad. Finalmente, la capa de predicción softmax se utiliza para generar el valor de probabilidad de cada posible etiqueta de salida, y la etiqueta final predicha es la etiqueta con la puntuación de probabilidad más alta.

2.1.8 Bases Teóricas sobre la Optimización del proceso de a perfilamiento y tratamiento de imágenes.

El proceso de tratamiento de imagen usando las Redes Neuronales Convolucionales (CNN) se enfoca en un conjunto de técnicas y procesos aplicados a las imágenes antes de que se ingresen en la red para su análisis o clasificación. Estas técnicas pueden incluir las siguientes etapas:

Pre procesamiento de Imágenes. Es un conjunto de técnicas aplicadas a imágenes antes de introducirlas en un modelo de aprendizaje automático o una red neuronal para su análisis o clasificación. El propósito del pre procesamiento es normalizar los valores. Los colores de los píxeles tienen valores que van de 0 a 255, haremos una transformación de cada pixel: “valor/255” y nos quedará siempre un valor entre 0 y 1. Otro objetivo es mejorar la calidad de la imagen, hacer que los datos sean más consistentes y se ajusten al modelo y, en general, mejorar el rendimiento del modelo.

Redimensionamiento. Según Semma et al. (2021) es el proceso por el cual se cambia el tamaño de la imagen a un tamaño estándar que la red pueda manejar, con el objetivo de:

- Personalizar la entrada del modelo. Los modelos de redes neuronales generalmente requieren que todas las imágenes de entrada tengan el mismo tamaño. Cambiar el tamaño de las imágenes garantiza que la red pueda procesarlas correctamente, evita errores y garantiza que los tamaños de los datos coincidan con las expectativas del modelo.
- Reducir la complejidad computacional. Las imágenes grandes contienen más datos, lo que aumenta la carga computacional y el tiempo de procesamiento. La reducción de escala puede reducir significativamente los costos computacionales, lo que permite entrenar e inferir modelos más rápido.
- Estandarizar. Al cambiar el tamaño de las imágenes a tamaños estándar, se asegurará de que todas las muestras de entrenamiento tengan la misma escala y relación de aspecto, lo que facilitará el aprendizaje del modelo al centrarse en las características relevantes independientemente del cambio de tamaño.
- Generalización mejorada. Cambiar el tamaño de la imagen también ayuda a mejorar la capacidad de generalización del modelo. La reducción de tamaño reduce el ruido y otros detalles irrelevantes, lo que permite que el modelo se centre en las características más importantes que son consistentes en todas las imágenes.
- Compatibilidad con redes previamente entrenadas. Muchos modelos CNN previamente entrenados (como VGG o ResNet) requieren que las imágenes de entrada tengan ciertas dimensiones (como 224x224 píxeles). Cambiar el tamaño de la imagen a estas dimensiones le permite utilizar estos modelos sin ajustes adicionales.

Según Onofrey et al. (2019) la normalización de datos es un paso clave en el pre procesamiento para los algoritmos de aprendizaje automático. En imágenes naturales, los cambios en la iluminación y el brillo contribuyen a la heterogeneidad de la intensidad; sin embargo, la gran cantidad de muestras de imagen disponibles para estas aplicaciones hace que

el entrenamiento sea factible, y simplemente eliminar el valor medio global de intensidad del conjunto de datos de todos los píxeles (ejemplo de 0 a 1) es empíricamente suficiente para redes neuronales profundas con este tipo de imágenes.

Según Mikołajczyk y Grochowski (2018) es la técnica con la cual a la imagen se le aplica métodos de aumento de datos en la tarea de clasificación de imágenes comenzando con transformaciones de imagen clásicas como rotación (Rotating e.g., 90°, 180°, 270°), recorte (Cropping), zoom (Zooming e.g., acercamiento y alejamiento de la imagen para cambiar la escala de la perspectiva), métodos basados en histogramas (Histogram Equalization) y terminando con Transferencia de Estilo y Redes Generativas Antagónicas, junto con ejemplos representativos, para crear variaciones que mejoren la robustez del modelo.

Eliminación de Ruido (Noise Reduction). Según Dibakar et al. (2019) la acumulación de ruido en las imágenes se produce en diferentes etapas de la captura de una imagen, que incluyen la adquisición, cuantificación, formato y compresión. En algunos casos, la acumulación de ruido es inevitable debido a las limitaciones del entorno, por ejemplo, existe un límite máximo de radiación para la tomografía computarizada (CT), lo que resulta en imágenes de bajo contraste, o en el caso de la vigilancia al aire libre, la neblina u otras condiciones meteorológicas generan inconsistencias en la calidad de la imagen. Las imágenes médicas con ruido pueden llevar a un diagnóstico inexacto del paciente.

Por otro lado, si las imágenes satelitales no se deshacen del ruido, se perderá información geográfica crucial. La reducción de ruido es igualmente importante tanto para aplicaciones de defensa críticas como para aplicaciones industriales no críticas. La clasificación del ruido nos permite identificar la distribución de ruido más probable presente en una imagen ruidosa, tras lo cual se puede aplicar un algoritmo de reducción de ruido óptimo para limpiar la imagen. Este método también se utiliza en otras disciplinas de procesamiento de señales.

Extracción de Características (Feature Extraction). En este proceso se identificar y recupera información relevante de la imagen. Este proceso ayuda a reducir el tamaño del material y resaltar las características más importantes que pueden usarse para clasificación, detección u otras aplicaciones analíticas.

Según Eitca (2024) se define como la fase esencial en el reconocimiento de imágenes de la red neuronal convolucional (CNN). En CNN, este proceso implica identificar y extraer información significativa de la imagen de entrada que facilite una precisa clasificación. El mencionado procedimiento resulta ser esencial porque los valores de píxeles sin el debido proceso no resultan ser útil directamente en las labores de clasificación. Al adquirir las características relevantes, las CNN pueden aprender a reconocer imágenes y formas, distinguiendo así entre diferentes categorías de objetos o entidades. La extracción de características de CNN generalmente se realiza mediante capas convolucionales. Estas capas aplican filtros (también llamados núcleos) a la imagen de entrada. Cada filtro pasa a través de las imágenes y realiza operaciones de suma y multiplicación para crear mapas de características. Estos mapas representan patrones de imágenes específicos, como bordes, texturas o formas. El uso de múltiples filtros en la capa convolucional permite a CNN extraer diferentes características en diferentes niveles espaciales.

Después de las capas convolucionales, las CNN suelen incluir funciones de activación como ReLU (unidades lineales corregidas) para introducir no linealidad en el modelo. Las funciones de activación no lineales son esenciales para que las CNN aprendan relaciones y patrones de datos complejos. Aplique una capa de agrupación (como agrupación máxima o agrupación promedio) para reducir la dimensión espacial del mapa de características mientras se conserva la información más relevante. La agrupación ayuda a que la red sea más robusta ante los cambios en la imagen de entrada y reduce la complejidad computacional.

Después de pasar por las capas convolucional y de agrupación, las características resultantes se aplanan en vectores y pasan a través de una o más capas completamente conectadas. Estas capas actúan como clasificadores que aprenden a asignar los objetos resultantes a categorías de salida apropiadas. La capa final completamente conectada generalmente utiliza una función de activación softmax para generar probabilidades de clase en múltiples tareas de clasificación. Para ilustrar el proceso de extracción de características para el reconocimiento de imágenes CNN, considere la clasificación de imágenes de foto de una avenida de la ciudad. En este caso, la CNN aprenderá a extraer características como textura, color y patrones únicos de diferentes tipos de señales, personas, carros, paso de cebra, edificios, zapatos, camisas o pantalones. Al procesar grandes cantidades de imágenes de ropa etiquetadas, CNN ajusta iterativamente sus filtros y pesos para identificar y clasificar con precisión estas características únicas, lo que le permite predecir imágenes invisibles con alta precisión.

La extracción de características es una parte importante del reconocimiento de imágenes de CNN, que permite al modelo aprender y distinguir los patrones y características relevantes en la imagen de entrada. Al utilizar capas convolucionales, funciones de activación, capas de agrupación y capas completamente conectadas, las CNN pueden extraer y utilizar de manera efectiva funciones significativas para realizar tareas de clasificación precisas.

Segmentación de Imágenes. Según Omarzai (2024) la segmentación de imágenes es una técnica para dividir una imagen digital en grupos llamados segmentos de imagen para ayudar a reducir la complejidad de la imagen y simplificar el procesamiento o análisis de la misma. En otras palabras, la segmentación implica etiquetar píxeles. A cada parte de una imagen o píxel que pertenece a una categoría se le asigna una etiqueta única.

Para Developers (2024) el codificador es la primera mitad del diagrama de arquitectura U-Net. La cual fue desarrollada y utilizada por primera vez para la segmentación de imágenes biomédicas. Su arquitectura es similar a la de una red codificadora seguida de una red

decodificadora. A diferencia de la clasificación, donde el resultado de la red profunda es lo único que importa, la segmentación semántica no solo implica la discriminación a nivel de píxel, sino también una técnica para proyectar las características discriminativas aprendidas en diferentes etapas del codificador sobre el espacio de píxeles.

Para Ronneberger et al. (2015) por lo general se trata de una red de clasificación previamente entrenada como VGG o ResNet que utiliza bloques convolucionales y luego reduce la resolución mediante maxpooling para codificar la imagen de entrada en varios niveles de representación de características diferentes. El decodificador es el otro lado de la arquitectura. El objetivo es proyectar semánticamente las características discriminantes (menor resolución) aprendidas por el codificador en el espacio de píxeles (alta resolución) para lograr una clasificación densa. El decodificador consta de muestreo y concatenación seguidos de operaciones de convolución regulares.

Transformación de Imágenes. Según Howard (2013) en la utilización de algoritmos de Deep learning mejoran significativamente a medida que se agregan más datos de entrenamiento. Cuando los datos de entrenamiento ya no están disponibles, se pueden aplicar transformaciones a los datos de entrenamiento existentes que reflejen la variabilidad encontrada en las imágenes, aumentando así el tamaño del conjunto de entrenamiento. Se pueden usar transformaciones de imágenes para expandir el conjunto de entrenamiento. Por ejemplo, un primer paso, a la imagen, se le puede aplicar recortes aleatorios de 224 x 224 píxeles a partir de una imagen de 256 x 256 píxeles que captura cierta invariancia de traducción. El segundo paso es voltear la imagen horizontalmente para capturar la invariancia del reflejo. La transformación de datos final consiste en agregar iluminación generada aleatoriamente que intenta capturar la invariancia de los cambios de luz y los ligeros cambios de color. Agregamos transformaciones adicionales para ampliar la invariancia de traducción y la invariancia de color.

Estas técnicas de tratamiento de imagen ayudan a la mejora de los niveles de calidad concerniente a imágenes de entrada, hacer que los modelos sean más eficientes, y mejorar la precisión de las predicciones en tareas como clasificar imágenes, detectar objetos, y segmentar de manera semántica, entre otras.

2.1.9 Características en el proceso de detección de objetos en las imágenes

La identificación de objetos en imágenes a través de acciones que le permitan clasificar utilizando algoritmos de aprendizaje automático requiere el empleo de una red neuronal convolucional. Este tipo de algoritmo se caracteriza por dotar a las computadoras de la capacidad visual, permitiéndoles reconocer un número determinado o específico de elementos.

Para Horcajada (2021) la problemática detección se caracteriza por:

- Bounding Box. Es un rectángulo “imaginario”, que actúa como guía para identificar objetos. Estos cuadros son trazados por los etiquetadores en las imágenes, delimitando el objeto de interés al establecer sus coordenadas X e Y. Asimismo, esta es una de las metodologías más utilizadas en la etiquetación de imágenes en aprendizaje profundo, ya que, en comparación con otras técnicas, el uso de cuadros delimitadores disminuye los costos y mejora la eficiencia en todo procedimiento ligado a la anotación.
- Clases. Diferenciar diversos tipos de objetos que se estiman detectar.
- Confidence. Posibilidad de que una detección que se realice pueda contener un objeto
- En el ámbito de las técnicas para identificar y clasificar rostros, se hallan enfoques como Eigenfaces y Fisherfaces. Estos enfoques requieren que el algoritmo disponga de un conjunto de imágenes faciales para su proceso de aprendizaje. A través de las acciones que permitan descomponer estas imágenes, empleando técnicas matemáticas y estadísticas, se puede crear un rostro de referencia que servirá para la comparación con una nueva imagen facial y así establecer una conexión.

Según Li et al. (2007) para el manejo de una mayor precisión en los procesos de reconocimiento facial es el uso de la técnica llamada Análisis de Componentes Principales Bidimensional (2DPCA, por sus siglas en inglés) se usa para la representación y reconocimiento facial. La idea principal detrás del 2DPCA es que se basa en matrices 2D en contraposición al PCA estándar, que se basa en vectores 1D. Aunque el 2DPCA obtiene una mayor precisión de reconocimiento que el PCA, un problema vital no resuelto del 2DPCA es que necesita muchos más coeficientes para la representación de imágenes que el PCA.

2.1.10 Modelos Disponibles para la detección de los objetos

Según Grm et al. (2017) los modelos de red neuronal convolucional más usados para el tratamiento de objetos son:

- Modelo AlexNet. El modelo se compone de capas convolucionales y completamente conectadas, y se destaca por su rápida reducción de tamaño en las representaciones intermedias mediante convoluciones con paso y capas de max-pooling
- Modelo GoogLeNet. El modelo utiliza una jerarquía de módulos Inception que combina varias operaciones, incluyendo la re-proyección de canales y la descomposición de convoluciones espaciales con filtros grandes en convoluciones más pequeñas, lo cual ayudará a la reducción del espacio de parámetros.
- Modelo SqueezeNet. La red logra reducir significativamente la cantidad de parámetros y la complejidad computacional mediante ciertas capas de compresión y utiliza conexiones de mapeo de identidad, lo que facilita el entrenamiento de redes más profundas de manera efectiva.

2.1.11 Concepto de las dimensiones de la Redes Neuronales Convulsiónales (CNN)

Rendimiento del modelo. Según Borja et al. (2020) el hecho de disponer de grandes magnitudes de información impulsó el desarrollo de algoritmos nuevos de aprendizaje profundo y automático, enfocados en mejorar la clasificación de clases múltiples con datos

desequilibrados. Para seleccionar el mejor algoritmo, se utilizan diversas métricas del análisis de desempeño, como recall, precisión, matrices de confusión, F1-Score, curva ROC y AUC. Sin embargo, precisión y recall son menos confiables con datos no balanceados. La falta de estandarización en la selección de métricas dificulta la comparación entre estudios, destacando la importancia de estas medidas para distinguir entre diferentes algoritmos y elegir el más adecuado según los objetivos de la investigación.

Las medidas de rendimiento desempeñan un rol indispensable en los problemas de clasificación y tienen como objetivo distinguir entre diferentes algoritmos de aprendizaje profundo y automático para seleccionar el mejor algoritmo según los objetivos de la investigación.

2.1.12 Concepto de las dimensiones de la Optimización del proceso de a perfilamiento y tratamiento de imágenes

Eficiencia. Según George et al. (2022) se considera como la relación más adecuada que realmente se logra utilizando medios medidos en costos y logrando efectos medidos en resultados, lo que significa que toda solución idónea a una problemática ligada a la salud se mide y evalúa en términos de resultado y costo, un enfoque eficaz proporcionará el mayor beneficio de salud al menor costo.

La eficiencia también significa mejorar el gasto, satisfacción de los requerimientos de la ciudadanía garantizando el desarrollo sostenible. En una situación a resolver, se considera eficiente si es capaz de proporcionar productos necesarios aceptables socialmente con la utilización mínima de recursos. Por lo tanto, al momento de luchar por un resultado concreto, también debemos averiguar qué método es óptimo para conseguirlo, y fomentar la búsqueda de un equilibrio adecuado entre eficiencia y calidad.

En los sistemas computacionales, por lo general hay dos dimensiones: eficiencia de tiempo y Eficiencia de recurso (CPU, Personas, Dinero, Energía, etc.)

Satisfacción del usuario de la gestión. Según Zárraga et al. (2018) la satisfacción se refiere a la valoración que hace la clientela sobre un servicio o producto, dependiendo de si este ha satisfecho sus expectativas y necesidades. Este concepto puede relacionarse con una sensación de agrado y es algo que cambia constantemente, adaptándose con el tiempo y afectado por diversos elementos. La percepción de satisfacción de la clientela se encuentra considerablemente determinada por la forma en que se evalúa el servicio o producto en cuestión.

2.2.13 Términos relacionados al tratamiento de imágenes usadas dentro de esta investigación

- SVM (Support vector machines). Según Scikit-Learn (s.f.) es un mecanismo de automático aprendizaje que se emplea para clasificar la y también en la regresión. Es el algoritmo subyacente que fomenta la búsqueda de que se encuentre el óptimo hiperplano para separar diversas clases en un escenario de particularidades para maximizar el margen entre las clases.
- SVC (Support vector Classification). Según Scikit-Learn (s.f.) es una implementación especial de SVM para problemas de clasificación. En la biblioteca Scikit-learn Python, SVC es una categoría utilizada para realizar tareas de clasificación utilizando el algoritmo SVM.
- SVR (Support Vector Regression). Según Scikit-Learn (s.f.) es una variación de la técnica SVM (Support Vector Machine) y se utiliza para problemas de regresión en lugar de problemas de clasificación. Al igual que SVM, SVR busca encontrar un modelo que pueda proporcionar predicciones precisas, pero en el contexto de valores continuos en lugar de etiquetas discretas. Conceptos clave de SVR. A diferencia de la clasificación, donde el objetivo es separar categorías, la regresión pretende ajustar una función que se aproxime a los valores continuos de los datos. SVR intenta encontrar

una característica con un error suficientemente pequeño en comparación con los datos de entrenamiento.

- PCA (Principal Component Analysis). Según Ahmad y Alfian (2022) la reducción dimensional es un mecanismo común para analizar la información y el automático aprendizaje, especialmente cuando se trabaja con agrupaciones de información de cierta magnitud de variables. El estudio de Componentes Principales (ACP o PCA en Inglés) es una alternativa estadística utilizada para reducir la dimensionalidad, manteniendo gran parte de la variabilidad posible del conjunto de información original. Esto es útil para simplificar los modelos, reducir el ruido, y mejorar la visualización y el rendimiento computacional. Las nuevas variables (Componentes Principales) se brindan entre sí, es decir no se encuentran correlacionadas, y se ordenan de tal manera que el primer componente principal explica la mayor parte de la variabilidad, el segundo el siguiente mayor, y así sucesivamente.
- Reconocimiento Facial. Según Scarel (2010) el objetivo es encontrar las áreas de un rostro dentro de una imagen descartando lo que este en el fondo de dicha imagen. Cada rasgo facial (como boca y ojos) se representa utilizando una plantilla. La principal idea es establecer una función de energía que conecte la intensidad de la imagen (los puntos bajos y altos) con las características de la plantilla, apenas se localice la plantilla, se ajustarán los parámetros para reducir al mínimo la función de energía. Otro método es la clasificar los patrones a través de ejemplos. Dado que solo se necesita la detección de rostros (sin necesidad de que se identifique a personas específicas), se desarrollan patrones para áreas que representaran una cara y otras que no.
- Estimación de Postura Humana (Human pose estimation). Para Ouyang et al. (2014) es la estimación de la pose se considera como un reconocimiento holístico. Por otro lado, muchos trabajos recientes utilizan partes locales del cuerpo para manejar los numerosos

grados de libertad en la articulación de las partes del cuerpo. Desde el primer trabajo en este campo, algunos enfoques han agrupado la apariencia de las partes en tipos de mezclas. También existen enfoques que deforman la plantilla de la parte mediante tamaños y orientaciones flexibles.

- **Etiquetados de imágenes.** El procedimiento de etiquetar una imagen de un rostro para un proceso de reconocimiento facial, es fundamental seguir un enfoque sistemático que asegure que la información resulte ser precisos y útiles. Aquí hay algunos pasos que puedes seguir como la normalización de las imágenes (estandarización, reducción de ruido, normalización) para luego usar una herramienta para la etiquetación de las imágenes para poder ser usadas en el proceso de clasificación.
- **Extracción de Atributos.** El proceso de seleccionar y obtener características o atributos específicos de un conjunto de datos para su posterior análisis o uso en algoritmos de aprendizaje automático.
- **RelU.** Según Baeldung (2024) ReLU (Rectified Linear Unit) es una función de activación utilizada en redes neuronales convolucionales (CNN). Su principal función es introducir no linealidades en la red, ratificando " las entradas negativas a cero y deja pasar las entradas positivas sin cambio lo que permite que esta aprenda y modele relaciones complejas en los datos.
- **Segmentación de Imágenes.** Procedimiento que consiste en la división de imágenes en segmentos y regiones más pequeños con el fin de que pueda identificarse y aislarse objetos individuales o sectores de alto interés dentro de la imagen. Este proceso comúnmente suele usarse en el proceso de imágenes y visualización por computadora para analizar y comprender mejor el contenido de una imagen

- Reconocimiento de Objetos. Se define como la labor en el campo de la visión por computadora que se refiere a la capacidad de un sistema de software o algoritmo para identificar y etiquetar objetos específicos en una imagen o un video.
- Representación de Características. Está referida a la transformación de datos brutos, como imágenes, en un formato más adecuado para el análisis de machine learning. Esto implica extraer rasgos relevantes que ayuden a los algoritmos a comprender y procesar la información de manera eficiente
- Organización de Datos. Procedimiento para ordenar y estructurar conjuntos de datos para facilitar su almacenamiento, acceso y análisis. Esto implica la clasificación, etiquetado y almacenamiento eficiente de los datos, lo que facilita su búsqueda y recuperación cuando sea necesario.
- Clasificación de Imágenes. Proceso de categorizar imágenes en diferentes clases o categorías basado en su contenido visual.
- Función Softmax. Según Hebbar (2023) es una función de activación que se utiliza principalmente en la última capa de la red, especialmente cuando se trata de tareas de clasificación multiclase. La función SoftMax convierte los valores de salida (también conocidos como logits) de la última capa de una red neuronal en probabilidades que suman a 1. Esto permite interpretar la salida de la red como una distribución de probabilidad sobre las diferentes clases, siendo la de la probabilidad más alta la de mayor consideración.

2.2.14 Términos relacionados al proceso de casting de una empresa audiovisual

Los siguientes conceptos fueron proporcionados por el cliente para poder tener un mismo lenguaje y terminología en el proceso.

- Casting: Proceso de selección de actores o talentos para un proyecto audiovisual (Soto, 2013).

- Casting de Actores: Selección de actores para interpretar roles en películas, series o teatro (Soto, 2013).
- Prueba de Actuación: Evaluación de habilidades actuales de los candidatos mediante actuaciones (Rodríguez, 2005).
- Director de Casting: Profesional encargado de dirigir y coordinar el proceso de casting (Instituto de Gestión Cultural y Artística, 2020).
- Selección de Talentos: Elección de artistas con habilidades adecuadas para un proyecto (Martínez y Vargas, 2019).
- Casting Abierto: Proceso de audición abierto a un público amplio (Casting and acting, 2021).
- Audición: Acto de interpretación por parte de los candidatos durante el casting (Gerbotto y Paturzo, 2020).
- Casting en Línea: Realización de audiciones a través de plataformas en línea (Soto, 2013).
- Elenco: Conjunto de actores seleccionados para un proyecto (E. García, 2007).
- Casting Presencial: Audiciones realizadas en persona con los candidatos (Saavedra, 2022).

III. MÉTODO

El estudio se relaciona con el paradigma positivista, que es una corriente filosófica y epistemológica que sostiene que el conocimiento auténtico solo puede derivarse de la experiencia sensorial directa y la observación empírica. Este paradigma rechaza las explicaciones no verificables y se enfoca en hechos observables, medibles y verificables a través de métodos científicos. El positivismo fue principalmente desarrollado por Auguste Comte en el siglo XIX, quien señala que la ciencia se basa en datos objetivos y en leyes generales que se puedan comprobar mediante la observación y la experimentación (Tejada et al., 2024).

En términos metodológicos, el paradigma positivista utiliza enfoques cuantitativos y busca generalizar los resultados obtenidos a partir de muestras representativas. Se enfoca en la objetividad, la replicabilidad y la exactitud, postulando que la realidad es externa, concreta y puede ser comprendida a través de leyes universales. El objetivo principal del positivismo es explicar los fenómenos de forma causal, buscando leyes que expliquen cómo y por qué ocurren ciertos eventos (Sánchez et al., 2024).

3.1 Tipo de investigación

La labor investigativa realizada es cuantitativa y aplicada, se considera cuantitativa en vista que utiliza datos de tipo cuantitativo y es aplicada puesto que fomenta la búsqueda de solución de diversas problemáticas.

Según Gallardo (2021) la labor realizada es aplicada en vista que se utilizan conocimientos que se han logrado adquirir, aparte los datos de distintas fuentes bibliográficas. Por otra parte, resulta ser cuantitativa en vista que utiliza datos que son de tipo cuantitativo (Espinoza et al., 2023).

3.2 Población y muestra

3.2.1 Población

Se define a la población como la agrupación de componentes, individuos o unidades que comparten una característica específica y sobre los cuales se desea hacer una inferencia o generalización. La población es el grupo al que se dirige el estudio, y la totalidad de componentes dentro de ella poseen la posibilidad de que pueda ser seleccionada para conformar una muestra (Hernández et al., 2017) postulantes a las convocatorias de casting entre las edades de 20 a 35 años de ambos sexos, de la provincia de Lima – Perú. Para el grupo de las convocatorias de perfilamiento entre el mes de enero del 2023 y mayo del 2024.

3.2.2 Muestra

La muestra de estudio va corresponder a muestras probabilísticas especificadas en forma proporcional en Spiral SAC.

La muestra fue de tipo aleatoria-sistemática y su tamaño será calculado aplicando la siguiente formulación (ver anexo E), de población finita con proporciones:

3.3 Operacionalización de variables

Definición conceptual de la variable independiente. Redes Neuronales Convolucionales.

Son modelos que procesan imágenes mediante convolución para extraer características, utilizando capas de activación y pooling. Son eficaces en tareas de reconocimiento, mejora y segmentación de imágenes, optimizando el tratamiento visual en la industria cinematográfica y publicitaria (Mera y Ochoa, 2021).

Definición conceptual de la variable dependiente. Optimización del proceso de a perfilamiento y tratamiento de imágenes.

Consiste en perfeccionar la eficiencia y calidad en el manejo de imágenes, ajustando atributos visuales como contraste y enfoque. Este enfoque acelera el procesamiento, mejorando

tanto la calidad como el tiempo de edición, especialmente en industrias como la cinematográfica y publicitaria (Cárdenas, 2012).

Tabla 1

Operacionalización de las Variables de estudio

Variable	Dimensiones	Indicadores
Variable Independiente: Redes Neuronales Convolucionales.	Rendimiento del modelo	Precisión (Accuracy) = Numero de predicciones correctas / Total de Predicciones Recall (Sensibilidad o tasa de Verdadero Positivo) = TP/TP + FN F1-Socore = 2. (Precisión. Recall/precisión + Recall
Variable Dependiente: Optimización del proceso de a perfilamiento y tratamiento de imágenes	Eficiencia	Tiempo en clasificar los candidatos Tiempo de a perfilamiento de imágenes digitalizadas Tiempo de identificación de rasgos faciales Tiempo de ordenar y a perfilar las imágenes digitalizadas Tiempo de generación de pre-seleccionados
	Satisfacción del usuario de la gestión	Porcentaje de satisfacción

Fuente: Elaboración propia

3.4 Instrumentos

Validez y confiabilidad de los instrumentos de recolección de datos

Según Hernández y Mendoza (2018) resalta la importancia de ciertas actividades relacionadas, las mismas que son:

a) Elegir un método de evaluación de los que se encuentran en el análisis del comportamiento o crear uno nuevo (el método para recopilar datos). Este método debe ser fiable y válido; de lo contrario, no se podrá confiar en los resultados que se pueda obtener.

b) Utilizar ese método de evaluación. Esto implica recoger las mediciones y observaciones de las variables que son relevantes para la labor investigativa (evaluar variables).

c) Organizar las mediciones que se lograron obtener para que puedan ser analizadas de manera adecuada (a esta tarea se le conoce como codificación de la información o dato).

d) Los métodos de recopilación de datos deben cumplir con dos criterios fundamentales: fiabilidad y validez. La fiabilidad de un método de evaluación se refiere al nivel en que su aplicación repetida a la misma persona u objeto genera resultados consistentes (Hernández y Mendoza, 2018).

e) La fiabilidad de un método de evaluación se refiere al nivel en que su aplicación repetida a la misma persona u objeto genera resultados consistentes.

- **Validez**

Según Sánchez (2019) define “Juicio Experto” a la opinión de individuos con amplia trayectoria en los asuntos reconocidos por otros. Por lo cual la presente investigación, el instrumento de validación a usar, son el juicio Experto. El instrumento ha sido validado por tres expertos doctores, todos con especialidad en Desarrollo de Sistemas y un profesional con las competencias necesarias en estadística.

Tabla 2

Relación de juicio de experto

Nombres y Apellidos	Grado Académico	Tipo de Experto	Determinación
Iván Carlo Petrilk Azabache	Dr. Ing. De Sistemas	Especialista	Aplicable
Pedro Martin Lezama Gonzales	Dr. Ing. de Sistemas	Especialista	Aplicable
Guillermo Pastor Morales	Mg. Ing. De Sistemas	Especialista	Aplicable

- **Confiabilidad**

Según Manterola et al. (2018) hay que afirmar que la confiabilidad está referida al nivel en el que se obtienen resultados sólidos y consistentes, lo cual significa, la medida en que se obtienen resultados similares al utilizar métodos y medidas de coherencia. En esta investigación, se empleó el coeficiente c como instrumento de medición. Este coeficiente necesita una única gestión del instrumento produciendo valores que varían entre cero y uno. Asimismo, es importante señalar que la ventaja radicarán en que no se requiere la división de los ítems del instrumento en dos partes, ya que se aplicará la medición y se realizará el cálculo del coeficiente directamente (ver anexo C).

La labor investigativa incluirá una entrevista con el gerente de los proyectos y a los equipos del área de casting. Además, se utilizarán cuestionarios, que podrán ser completados tanto en línea como fuera de línea, aprovechando herramientas como Google Forms. El cuestionario virtual constará de 15 preguntas cerradas con escala de Likert, diseñadas según las variables definidas en la investigación y que fueron contestadas por 20 personas de los proyectos la empresa Spiral como también por miembros del área de Casting.

Las preguntas cerradas, como lo indica la tabla adjunta, se emplearán para obtener una cobertura exhaustiva del tema, y se validarán posteriormente. La escala de Likert se presenta detalladamente en la Matriz de Consistencia lógica. La elaboración de las preguntas está en concordancia con las dimensiones e indicadores de cada una de las variables. En concordancia con la Matriz de Consistencia.

Tabla 3

Lista de entrevistados y su distribución

Cargo	Empresa	Número de Personas Entrevistadas
Director de Casting	Spiral Prod.	1
Equipo de Casting	Spiral Prod.	2
Asistentes de Dirección	Spiral Prod.	2
Productor	Cliente A	2
Director	Cliente A	2
Equipo de Casting	Cliente A	3
Productor	Cliente B	1
Director	Cliente B	2
Equipo de Casting	Cliente B	1
Productor	Cliente C	1
Director	Cliente C	1
Equipo de Casting	Cliente C	2
Total		20

Fuente: Elaboración propia

Tabla 4

Escala de valoración

Totalmente desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
1	2	3	4	5

3.5 Procedimientos

Se aplican los pasos siguientes para la evaluación de los modelos sobre el caso de uso:

- Detalle de las actividades
- Se va a seleccionar una muestra de fotos digitalizadas, datasets de una convocatoria, por el área de Casting
- Se procedió al etiquetado de las imágenes (código de postulante). Normalmente se deriva este servicio a un tercero para la ejecución del etiquetado.
- Se procedió a crear una cuenta en la Nube y la creación de un proyecto (creación de *tag* para el costeo de recursos).
- Se creó una máquina virtual (NVIDIA L4 GPUs c/ Ada Lovelace Architecture)

- Las instancias G2 de NVIDIA son máquinas en la nube diseñadas para tareas de aprendizaje automático y procesamiento gráfico avanzado. Utilizan la GPU NVIDIA L4, basada en la arquitectura Ada Lovelace, que ofrece un alto rendimiento para inferencia en aprendizaje automático y codificación de video, con soporte para FP8, FP16 y TF32. Además, incorporan núcleos RT de tercera generación y tecnología DLSS 3.0, lo que las hace ideales para aplicaciones gráficas intensivas, como renderización y estaciones de trabajo virtuales. Estas instancias son adecuadas para aplicaciones en tiempo real en juegos y la creación de contenido 3D de alta calidad para medios y entretenimiento.
- Se asoció los recursos de storage, VCN y credenciales al proyecto
- Se procedió a la instalación del Software base y librerías Python:
 - `pip install face_recognition opencv-python`
 - `pip install pyspark==3.3.0`
 - `pip install sparkdl`
 - `pip install tensorframes`
 - `pip install tensorflowonspark`
 - `pip install kafka-python`
- Se realizaron las migraciones del datasets a un directorio de la Nube (fuente de datos) y validación de las imágenes.

3.6 Análisis de datos

- **Análisis documental:** facilita comprender, examinar, interpretar y analizar una variedad de fuentes documentales sobre la gestión, incluyendo artículos, libros, textos, revistas, normativas, entre otros.
- **Indagación:** facilita el hecho de que se obtenga la información cuantitativa y cualitativa con un nivel de precisión razonable sobre el tema en cuestión.

- **Tabulación de cuadros con cantidades y porcentajes:** Esta técnica posibilitó la organización de los datos cuantitativos acerca del proceso de casting y aperfilamiento de la empresa Spiral Producciones en Lima-Perú, en tablas especiales para su análisis e interpretación.
- **Contratación de hipótesis:** A través de la observación, experimentación y/o revisión documental, esta técnica permitió verificar si la hipótesis era verdadera o falsa.
- **Tamaño de la muestra representativa.** Como se menciona en la descripción del tamaño y muestra, dado que las poblaciones son finitas, estos valores no variarán dependiendo del momento en que se realice la recopilación de datos.
- **Análisis de Datos.** Se realiza el estudio del nivel de significancia y la normalidad de los datos; para lo cual se aplicó el SPSS vs 26.0. Para calcular la Tabla de Pruebas de Normalidad se considera el número de muestras (NM). Si $NM > 50$ sujetos se usan Kolmogorov –Smirnov, caso contrario se debe de usar Shapiro – Wilk. En este caso la muestra es de 20 muestras por lo tanto se usará Shapiro – Wilk.

Posteriormente se pasó a verificar si los datos son normales, para lo cual se usó el Nivel de significancia (Sig). En caso el $Sig > 0,05$ entonces quiere decir que los datos son normales, por lo que se puede aplicar Pruebas Paramétricas como R de Pearson. En caso contrario, los datos no son normales entonces puede aplicar Pruebas No Paramétricas como por ejemplo de T de Wilcoxon, Chi Cuadrado, Kendall o Rho de Spearman.

Tabla 5

Resultados de la Pruebas de Normalidad

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Pre Test	,378	20	,000	,668	20	,000
Pos Test	,264	20	,001	,659	20	,000

a. Corrección de significación de Lilliefors

Fuente: Elaboración propia

En cuanto a la Prueba de Normalidad. Tomando los valores de la siguiente tabla, se observa un *pvalor* (Sig) menor que 0.05. Para la primera muestra (Pre Test) se observa un *pvalor* (Sig) menor (0.000), lo que indica que sus datos no son normales.

Para la segunda muestra (Pos Test) observa un *pvalor* (Sig) menor que 0.05. Para la primera muestra (Pos Test) se observa un *pvalor* (Sig) menor (0.000), lo que indica que sus datos no son normales. Por lo tanto, al ser este una investigación pre-experimental, se usará la prueba de T de Wilcoxon de tipo no paramétricas.

La información de los análisis de resultados de las Dimensiones y sus Indicadores, Ver el Anexo de Resultados.

3.7 Consideraciones éticas

En el marco del estudio de investigación, se recopiló la información de manera imparcial y objetiva, asegurando que no se alterara ni manipulara, con el objetivo de garantizar la fiabilidad de los resultados obtenidos. Se consideraron aspectos éticos, como la confidencialidad de los sujetos investigados y el respeto a la voluntad de los estudiantes que decidieron participar o no. Para asegurar una estructura sólida en el trabajo de investigación, se implementaron las pautas establecidas en las Normas APA 7ª Edición.

También dentro de las consideraciones Éticas se está considerando la firma de un acuerdo de confidencialidad y un acuerdo de tratamiento de datos personales bajo la Ley Peruana 29733, Ley de protección de datos personales

IV. RESULTADOS

4.1 Análisis y Resultados de la Variable Independiente y sus Indicadores

- Variable Independiente: Redes Neuronales Convolucionales.
- Dimensión: Rendimiento del modelo
- Indicadores:
 - Accuracy
 - Recall
 - F1-Score

Sobre el trabajo de la muestra representativa se procedió a elaborar los trabajos división el conjunto de datos en tres subconjuntos: entrenamiento, validación, y prueba

- Entrenamiento: que se usó para ajustar los parámetros del modelo. Se usó 70% de la muestra representativa.
- Validación: El cual se utilizó para ajustar los hiperparámetros y evitar el sobreajuste. Se uno un 15% de la muestra representativa.
- Prueba: Con este proceso se evaluó el rendimiento final del modelo, permitiendo que los datos que no fueron vistos durante el entrenamiento ni la validación sean aceptados. Un 15% de la muestra representativa.

Luego de evaluar el modelo de reconocimiento facial en 168 imágenes, obtenemos la siguiente matriz de confusión:

Tabla 6

Matriz de confusión para el caso

	Predicción: Éxito		Predicción: Fallo
Realidad (+)	Éxito	80 (TP)	3 (FN)
Realidad (-)	Fallo	2 (FP)	83 (TN)

Fuente: Elaboración Propia

Los verdaderos positivos (TP), falsos positivos (FP), verdaderos negativos (TN) y falsos negativos (FN) son métricas clave para evaluar un modelo. Los verdaderos positivos indican cuando el modelo ha identificado correctamente la presencia de una clase particular.

Los falsos positivos se refieren a los casos en que el modelo ha identificado erróneamente la presencia de esa clase. Los verdaderos negativos corresponden a los casos en los que el modelo ha identificado correctamente la ausencia de la clase, mientras que los falsos negativos ocurren cuando el modelo no logra identificar la presencia de la clase específica, prediciendo su ausencia incorrectamente.

Siguiendo con el trabajo de análisis, se procedió a desarrollar los siguientes Indicadores para evaluar la eficiencia del modelo de Deep learning usado:

- Accuracy (Precisión global). Esta métrica mide la proporción de predicciones correctas sobre el total de predicciones realizadas.

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

Remplazando los valores, tenemos

$$80 + 83 / 80 + 83 + 2 + 3 = 163 / 168 = 0.9702 = 97,2\%$$

- Recall (sensibilidad o tasa de verdaderos positivos). Esta métrica mide la proporción de verdaderos positivos sobre el total de positivos reales.

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

Remplazando los valores, tenemos

$$\text{Recall} = 80 / 80 + 3 = 80 / 83 = 0.9639 = 96.39\%$$

- F1 – Score. Es la media armónica entre la *Precisión* y el *Recall*. Hallamos la precisión primero:

$$\text{Precisión} = \frac{TP}{TP + FP}$$

$$\text{Precisión} = 80 / 80 + 2 = 80 / 82 = 0.9756 = 97.56\%$$

Luego calculamos el F1 Score:

$$F1\text{-Score} = 2 \times \text{Precision} \times \text{Recall} / \text{Precision} + \text{Recall}$$

$$F1\text{-Score} = 2 \times (0.9756 \times 0.9639) / 0.9756 + 0.9639$$

$$F1\text{-Score} = 2 \times (0.9401 / 1.9395) = 0.9686 = 96.86\%$$

Teniendo el siguiente resumen de las métricas

- Accuracy: 97.02%
- Recall: 96.39%
- F1-Score: 96.86%

Con estos valores, el modelo de reconocimiento facial tiene un rendimiento muy alto, con una precisión global superior al 97%, lo que indica que es altamente eficiente en la identificación de imágenes exitosas frente a fallidas.

4.2 Análisis y resultados de la variable dependiente y sus indicadores

- Variable Dependiente: Optimización del proceso de a perfilamiento y tratamiento de imágenes
- Dimensión: Eficiencia
 - Indicador: Tiempo en clasificar los candidatos

Tabla 7

Prueba de rangos con signo de Wilcoxon para el indicador

	Preg_Post_1 - Preg_Pre_1
Z	-3,944 ^b
Sig. Asintótica (bilateral)	,000

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos negativos.

Nota. Se puede observar en la estadística de la prueba de Wilcoxon el grado de significancia nos da un valor de (0.000) menor a 0.05, por lo cual significa, que ha habido una mejora significativa luego de la implementación de la variable independiente, en este caso, reduciendo los tiempos en la clasificación de candidatos.

- Variable Dependiente: Optimización del proceso de a perfilamiento y tratamiento de imágenes
- Dimensión: Eficiencia
- Indicador: Tiempo de a perfilamiento de imágenes digitalizadas.

Tabla 8

Prueba de rangos con signo de Wilcoxon para el indicador

	Preg_Post_1 -
	Preg_Pre_1
Z	-3,946 ^b
Sig. Asintótica (bilateral)	,000

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos negativos.

Nota. Se puede observar en la estadística de la prueba de Wilcoxon el grado de significancia nos da un valor de (0.000) menor a 0.05, por lo cual significa, que ha habido una mejora significativa luego de la implementación de la variable independiente, en este caso, reduciendo los tiempos de aperfilamiento de imágenes digitalizadas.

- Variable Dependiente: Optimización del proceso de a perfilamiento y tratamiento de imágenes
- Dimensión: Eficiencia
- Indicador: Tiempo de identificación de rasgos faciales.

Tabla 9

Prueba de rangos con signo de Wilcoxon para el indicador

	Preg_Post_1 -
	Preg_Pre_1
Z	-3,969 ^b
Sig. asintótica (bilateral)	,000

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos negativos.

Nota. Se puede observar en la estadística de la prueba de Wilcoxon el grado de significancia nos da un valor de (0.000) menor a 0.05, por lo cual significa, que ha habido una mejora significativa luego de la implementación de la variable independiente, en este caso, reduciendo los tiempos de identificación de rasgos faciales.

- Variable Dependiente: Optimización del proceso de a perfilamiento y tratamiento de imágenes
- Dimensión: Eficiencia
- Indicador: Tiempo de ordenar y a perfilar las imágenes digitalizadas.

Tabla 10

Prueba de rangos con signo de Wilcoxon para el indicador

	Preg_Post_1 - Preg_Pre_1
Z	-3,988 ^b
Sig. asintótica (bilateral)	,000

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos negativos.

Nota. Se puede observar en la estadística de la prueba de Wilcoxon el grado de significancia nos da un valor de (0.000) menor a 0.05, por lo cual significa, que ha habido una mejora significativa luego de la implementación de la variable independiente, en este caso, reduciendo los tiempos de ordenar y a perfilar las imágenes digitalizadas.

- Variable Dependiente: Optimización del proceso de a perfilamiento y tratamiento de imágenes
- Dimensión: Eficiencia
- Indicador: Tiempo de generación de pre-seleccionados.

Tabla 11*Prueba de rangos con signo de Wilcoxon para el indicador*

	Preg_Post_1 - Preg_Pre_1
Z	-3,942 ^b
Sig. asintótica (bilateral)	,000
a. Prueba de rangos con signo de Wilcoxon	
b. Se basa en rangos negativos.	

Interpretación. Se puede observar en la estadística de la prueba de Wilcoxon el grado de significancia nos da un valor de (0.000) menor a 0.05, por lo cual significa, que ha habido una mejora significativa luego de la implementación de la variable independiente, en este caso, reduciendo los tiempos de generación de pre-seleccionados.

- Variable Dependiente: Optimización del proceso de a perfilamiento y tratamiento de imágenes
- Dimensión: Satisfacción del usuario de la gestión.

Se contaron los puntajes son de cada una de las escalas de 1 al 5, siendo 1 el valor mínimo y 5 el máximo, Se consideró los valores de las preguntas según el nivel de satisfacción de cada indicador adicionando (Preguntas 2,6,10,14,18) y los valores de satisfacción relacionado a la nueva tecnología. (Preguntas del 21 al 23).

Los resultados de la encuesta para el indicador fueron:

Tabla 12*Resultados para el indicador de satisfacción*

Pregunta	1	2	3	4	5
Valor	0	0	0	0	160

4.3 Prueba de Hipótesis

4.3.1 Prueba de Hipótesis Principal

Ha. La implementación del uso de las Redes Neuronales Convolucionales contribuirá en mejorar el proceso de a perfilamiento en la selección de perfiles para el área de casting de la empresa audiovisual Spiral Producciones en Lima, Perú, durante el año 2024.

Ho. La implementación del uso de las Redes Neuronales Convolucionales No contribuirá en mejorar el proceso de a perfilamiento en la selección de perfiles para el área de casting de la empresa audiovisual Spiral Producciones en Lima, Perú, durante el año 2024.

Tabla 13

Prueba de rangos con signo de Wilcoxon para la Hipótesis General

	Preg_Post_1 - Preg_Pre_1
Z	-3,929 ^b
Sig. asintótica (bilateral)	,000

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos negativos.

Fuente: Elaboración propia

Nota. Se puede observar en la estadística de la prueba de Wilcoxon el grado de significancia nos da un valor de (0.000) inferior a 0.05, debido a ello se procede al rechazo de la hipótesis Nula y se procede a la aceptación de la hipótesis Alternativa. Lo que significa, que la implementación del nuevo modelo de redes neuronales contribuye en mejorar el proceso de a perfilamiento en la selección de perfiles para el área de casting.

4.3.2 Prueba de Hipótesis Específica 1

Ha. La implementación del uso de las Redes Neuronales Convolucionales contribuirá en mejorar los tiempos del proceso de a perfilamiento en la selección de perfiles para el área de casting.

Ho. La implementación del uso de las Redes Neuronales Convolucionales No contribuirá en mejorar los tiempos del proceso de a perfilamiento en la selección de perfiles para el área de casting.

Tabla 14

Prueba de rangos con signo de Wilcoxon para la hipótesis específica 1

	Preg_Post_1 - Preg_Pre_1
Z	-3,927 ^b
Sig. asintótica (bilateral)	,000

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos negativos.

Fuente: Elaboración propia

Nota. Se puede observar en la estadística de la prueba de Wilcoxon el grado de significancia nos da un valor de (0.000) menor a 0.05, por lo cual se rechaza la hipótesis Específica I Nula y se acepta la hipótesis Alternativa. Lo que significa, que la implementación del nuevo modelo de redes neuronales contribuye en mejorar los tiempos del proceso de a perfilamiento en la selección de perfiles para el área de casting.

4.3.3 Prueba de Hipótesis Específica 2

Ha. La implementación del uso de las Redes Neuronales Convolucionales contribuirá en reducir el índice de errores del proceso de a perfilamiento en la selección de perfiles para el área de casting.

Ho. La implementación del uso de las Redes Neuronales Convolucionales No contribuirá en reducir el índice de errores del proceso de a perfilamiento en la selección de perfiles para el área de casting.

Tabla 15

Prueba de rangos con signo de Wilcoxon para la hipótesis específica 2

	Preg_Post_1 - Preg_Pre_1
Z	-3,934 ^b
Sig. asintótica (bilateral)	,000

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos negativos.

Fuente: Elaboración propia

Nota. Se puede observar en la estadística de la prueba de Wilcoxon el grado de significancia nos da un valor de (0.000) inferior a 0.05, debido a ello se procede al rechazo de la hipótesis Nula y se procede a la aceptación de la hipótesis Alternativa. Lo que significa, que la implementación del nuevo modelo de redes neuronales contribuye en reducir el índice de errores del proceso de a perfilamiento en la selección de perfiles para el área de casting.

4.3.4 Prueba de Hipótesis Específica 3

Ha. La implementación del uso de las Redes Neuronales Convolucionales No contribuye en aumentar el índice de efectividad del proceso de a perfilamiento en la selección de perfiles para el área de casting.

Ho. La implementación del uso de las Redes Neuronales Convolucionales contribuirá en aumentar el índice de efectividad del proceso de a perfilamiento en la selección de perfiles para el área de casting.

Tabla 16

Prueba de rangos con signo de Wilcoxon para la hipótesis específica 3

	Preg_Post_1 - Preg_Pre_1
Z	-3,966 ^b
Sig. asintótica (bilateral)	,000

a. Prueba de rangos con signo de Wilcoxon

b. Se basa en rangos negativos.

Fuente: Elaboración propia

Nota. Se puede observar en la estadística de la prueba de Wilcoxon el grado de significancia nos da un valor de (0.000) inferior a 0.05, debido a ello se procede al rechazo de la hipótesis Nula y se procede a la aceptación de la hipótesis Alternativa. Lo que significa, que la implementación del nuevo modelo de redes neuronales contribuye en aumentar el índice de efectividad del proceso de a perfilamiento en la selección de perfiles para el área de casting.

V. DISCUSIÓN DE RESULTADOS

El estudio realizado se enfoca en la optimización del proceso de aperfilamiento y tratamiento de imágenes a través de redes neuronales convolucionales en una empresa de la industria cinematográfica y publicitaria. El uso de la teoría de optimización de procesos, propuesta por Dantzig (2002) se refleja en los resultados obtenidos, donde se logró mejorar la eficiencia del proceso, reduciendo el tiempo necesario para clasificar y seleccionar perfiles. Esta mejora en la eficiencia está directamente relacionada con la aplicación de redes neuronales artificiales, las cuales, al simular el procesamiento cognitivo humano, permiten clasificar las imágenes con alta precisión, adaptándose a diferentes características y variaciones en las fotos de los participantes.

El procesamiento de imágenes también desempeñó un papel crucial, ya que permitió transformar y mejorar la calidad visual de las imágenes, facilitando el trabajo de las redes neuronales. Cuando se fomenta mejoras en los niveles de calidad de las imágenes, se optimizó la precisión y la efectividad del proceso de aperfilamiento. La IA, así como el profundo aprendizaje, permitió automatizar el proceso, lo que redujo la intervención humana y agilizó elegir el perfil más idóneo del proyecto. La integración de estas tecnologías avanzadas valida la relevancia de la IA en la optimización de procesos en el sector.

Por otro lado, la teoría de gestión de tecnologías de la información fue clave para implementar las soluciones tecnológicas de manera efectiva. La correcta administración de las tecnologías y la infraestructura adecuada facilitó el éxito de la optimización del proceso de aperfilamiento, asegurando que los sistemas involucrados funcionaran de manera eficiente. Este estudio también resalta cómo la innovación tecnológica desempeña un esencial rol en la transformación de procesos en la industria cinematográfica y publicitaria, al permitir la adopción de nuevas herramientas puedan establecer mejoras en la calidad que mejoran la calidad y competitividad de los proyectos.

Finalmente, el aprendizaje automático demostró ser fundamental para que las redes neuronales mejoraran constantemente a medida que procesaban más datos. Esta capacidad de aprendizaje automático permitió que el sistema se adaptara y mejorara, logrando una clasificación más precisa con el tiempo.


En conjunto, las teorías aplicadas en el estudio ofrecen un marco sólido que demuestra la eficacia y la viabilidad de las redes neuronales convolucionales en la optimización de procesos dentro de la industria, logrando resultados que no solo optimizan la eficiencia operativa, sino también la calidad de los proyectos.

Respecto al análisis de datos los resultados de la labor investigativa fueron los siguientes:

Tras realizar el estudio de la información para la obtención de resultados, aceptando la hipótesis general que establece el vínculo positivo e influyente entre las variables tomadas antes de la aplicación del nuevo modelo de redes neuronales y después de la aplicación del nuevo.

El resultado obtenido está alineado con lo señalado por Cadena (2021), donde reportó un incremento del 97% en la precisión de los procesos de reconocimiento facial. De manera similar, Rami et al. (2019) en su estudio "Facial Emotion Recognition Using NLPCA and SVM," alcanzó una precisión en el reconocimiento facial entre el 97.3% y el 98%.

Al revisar el desarrollo de la hipótesis general, se puede observar la influencia significativa en un 99.78% del uso de redes neuronales en la mejora del proceso de perfilamiento para la selección de candidatos en el área de casting. (Figura 1).

Figura 1*Impacto (%) sobre el proceso de aperfilamiento*

Fuente: Elaboración propia

Por otro lado, el consumo de tiempo en los procesos de clasificación afecta no solo la eficiencia del proceso de selección, sino también la seguridad y calidad del servicio. Esto puede comprometer las operaciones administrativas y financieras, así como la reputación y la integridad de la información de la organización

Al implementarse el proceso de redes neuronales ha permitido mejorar el tiempo en los procesos de la clarificación de las imágenes, comparándolo con el proceso actual que se desarrolla manualmente.


Según Balbuena (2022) la implementación de modelos CNN mejora la clasificación de la detección de imágenes y a su vez (Yufeng Wang, 2019) precisa que la implementación de modelos CNN sobre imágenes se puede obtener una reducción del tiempo de clasificación y ejecución en un 20%. Demostrando su eficiencia y eficacia.

Al revisar el desarrollo de la hipótesis específica I (capítulo 4, anexo 4.2.2), podemos observar la influencia significativa en un 93.22% del uso de redes neuronales en la mejora los

tiempos del proceso de perfilamiento para la selección de candidatos en el área de casting. (Figura 2).

Figura 2

Impacto (%) sobre el tiempo de perfilamiento en la selección de perfiles



Fuente: Elaboración propia


Como parte de la aplicación de modelos de redes neuronales (CNN), el departamento de casting se planteó la implementación de un nuevo modelo de trabajo para reducir el índice de errores del proceso de a perfilamiento en la selección de perfiles de esta área.

Según Waldie (2021) resalta en su tesis la significativa mejora en la precisión y confiabilidad del procesamiento automático de imágenes mediante Redes Neuronales Convolucionales (CNN), aunque su aplicabilidad se ve limitada por los altos requisitos de hardware. Por su parte Benedikt et al. (2024) demuestra en su publicación que las Redes Neuronales Convolucionales 3D (3D-CNN) pueden lograr una alta precisión (92%-96%) en la evaluación de calidad de imágenes topográficas, evidenciando su eficacia en aplicaciones médicas de alta resolución.

Al revisar el desarrollo de la hipótesis específica II, podemos observar la influencia significativa en un 98.22% del uso de redes neuronales en la reducción el índice de errores del proceso de a perfilamiento en la selección de perfiles de esta área. (Figura 3).

Figura 3

Impacto (%) sobre la reducción de errores en los procesos de perfilamiento



Fuente: Elaboración propia

Por otro lado, un objetivo primordial para la empresa es aumentar el índice de efectividad del proceso de a perfilamiento en la selección de perfiles para el área de casting.

Al implementarse el proceso de redes neuronales ha permitido mejorar la efectividad en los procesos de la clarificación de las imágenes, comparándolo con el proceso actual que se desarrolla manualmente.


Según Fernández (2024) en su estudio sobre el diagnóstico de COVID-19 mediante tomografías computarizadas utilizando modelos Deep Learning y CNN, logró una precisión superior al 90% con GoogleNet. Por otro lado, Acuña et al. (2024) empleó modelos CNN combinados con SVM, RF y GBM para la predicción de permeabilidad de células Caco-2 en productos naturales, alcanzando un rendimiento del 76%. Cadena (2021), en su tesis doctoral, desarrolló un mecanismo de reconocimiento facial global que supera el 97% de eficiencia

utilizando wavelets de Gabor y máquinas de vectores de soporte en imágenes 3D, contribuyendo significativamente a la seguridad ciudadana. Finalmente, Roy et al. (2022) presentó un modelo para detectar objetos que se basen en YOLOv4 para identificar enfermedades de plantas, logrando una precisión del 90.33%, una puntuación F1 del 93.64% y un valor promedio de precisión del 96.29%.

Al revisar el desarrollo de la hipótesis específica II, podemos observar la influencia significativa en un 98.78 % en la efectividad por el uso de redes neuronales en el proceso de a perfilamiento en la selección de perfiles (Figura 4).

Figura 4

Impacto (%) en la efectividad en los procesos de perfilamiento



Fuente: Elaboración propia

Basados en estos resultados podemos afirmar que las hipótesis descritas dentro de este proceso de investigación se relacionan eficazmente con el aumento de los niveles de calidad de los procedimientos de perfilamiento en la selección de perfiles para el área de casting. Incrementando la eficacia del producto, el tiempo de entrega, la calidad en los procesos y reducciones los defectos.

VI. CONCLUSIONES

- La implementación del uso de las Redes Neuronales Convolucionales ayudó a mejorar el procedimiento de a perfilamiento en la selección de perfiles para el área de casting respaldada por un valor de significancia resultó ser 0,000, es significativamente menor al umbral teórico equivalente a 0,05. Además, La implementación de Redes Neuronales Convolucionales (CNN) ha demostrado una influencia significativa en la mejora del proceso de aperfilamiento en la selección de perfiles para el área de casting en Spiral Producciones. El modelo ha optimizado la clasificación y análisis de las imágenes de los candidatos, permitiendo una selección más precisa y rápida, lo cual mejora la eficiencia general del proceso de casting y facilitando que se tomen decisiones de manera informada.
- La implementación del uso de las Redes Neuronales Convolucionales mejorar los tiempos del proceso de a perfilamiento, respaldada por un valor de significancia es de 0,000, lo cual es significativamente menor al umbral teórico equivalente a 0,05. Asimismo, el uso de Redes Neuronales Convolucionales ha tenido un positivo impacto en la disminución de los plazos necesarios para realizar el proceso de aperfilamiento. La automatización del análisis de imágenes y la rápida clasificación de los perfiles permitieron disminuir significativamente el tiempo total del proceso de selección, mejorando la eficiencia operativa y agilizando la entrega de resultados para los proyectos de la empresa.
- La implementación de un modelo de desarrollo de software ayudó a contribuir a reducir el índice de errores del proceso de a perfilamiento, respaldada por un valor de significancia es de 0,000, lo cual es significativamente inferior al umbral teórico de 0,05. La implementación de las Redes Neuronales Convolucionales ha contribuido notablemente a la reducción de los errores en el proceso de aperfilamiento. La precisión

y capacidad de aprendizaje del modelo han permitido clasificar las imágenes de manera más precisa, disminuyendo los errores humanos en la selección de perfiles y aumentando la fiabilidad del proceso de casting.

- La implementación de un modelo de desarrollo de software ayudó a aumentar el índice de efectividad del proceso de perfilamiento, respaldada por un valor de significancia es de 0,000, lo cual es significativamente inferior al umbral teórico de 0,05. Las Redes Neuronales Convolucionales han incrementado considerablemente el índice de efectividad del proceso de perfilamiento al mejorar la calidad de la selección de perfiles. El modelo ha sido capaz de identificar con mayor precisión a los candidatos adecuados para los roles específicos en los proyectos de la empresa, lo que ha contribuido a la optimización del proceso y al aumento de la satisfacción de los directores de casting y otros involucrados en la producción.

VII. RECOMENDACIONES

- El uso de las Redes Neuronales Convolucionales (CNN) permitirá automatizar y optimizar el proceso de aperfilamiento, mejorando la precisión en la clasificación y selección de perfiles. Esto se logra al entrenar el modelo para reconocer patrones clave en las imágenes y características de los candidatos, lo que agiliza el proceso y reduce la intervención manual, optimizando el tiempo y los recursos empleados.
- La implementación de las Redes Neuronales Convolucionales reducirá significativamente el tiempo de clasificación de las imágenes de los candidatos al automatizar el análisis de grandes volúmenes de datos. Esto permitirá procesar rápidamente las imágenes y realizar la selección de perfiles en un plazo más corto, disminuyendo el tiempo total del proceso de casting.
- Al aplicar Redes Neuronales Convolucionales, el modelo aprenderá a identificar y clasificar los perfiles con mayor precisión, reduciendo así el margen de error. Este tipo de red neuronal es altamente eficaz en tareas de reconocimiento de patrones y mejora en la precisión de clasificación, lo que minimiza los posibles errores de identificación que puedan ocurrir durante el proceso de aperfilamiento.
- Las Redes Neuronales Convolucionales permitirán mejorar la efectividad del proceso de aperfilamiento al garantizar una selección más precisa y adaptativa de los perfiles, ajustándose a las especificaciones del proyecto. El aprendizaje automático permitirá que el sistema optimice continuamente su capacidad para identificar a los candidatos más adecuados, incrementando la calidad del proceso de casting y su alineación con los requisitos de cada producción.

VIII. REFERENCIAS

- Acuña, V., Montoya, M., Negrón, L., y Solis, C. (2024). A Machine Learning Approach for Predicting Caco-2 Cell Permeability in Natural Products from the Biodiversity in Perú. *Pharmaceuticals*, 17, 1-19. <https://doi.org/10.3390/ph17060750>.
- Ahmad, P., y Alfian, H. (2022). Application of PCA-CNN (Principal Component Analysis – Convolutional Neural Networks) Method on Sentinel-2 Image Classification for Land Cover Mapping. *International Journal of Advanced Engineering Research and Science (IJAERS)*, 9(8), 188-192. https://ijaers.com/uploads/issue_files/22IJAERS-07202264-Application.pdf.
- Arya, S. (2018). Face Recognition with Partial Face Recognition and Convolutional Neural Network. *International Journal of Advanced Research in Computer Engineering & Technology*, 7(1), 91-94. https://www.academia.edu/42920715/Face_Recognition_with_Partial_Face_Recognition_and_Convolutional_Neural_Network_Shraddha_Arya_Arpit_Agrawal_Senior_Lecturer?auto=download.
- AWS Corp. (2024). *Three Types of Offers*. <https://aws.amazon.com/es/what-is/artificial-intelligence/>
- Baeldung. (2024). *How ReLU and Dropout Layers Work in CNNs*. <https://www.baeldung.com/>.
- Balbuena, J. (2022). *Modelos de Detección de Emociones en Texto y Rostros para Agentes Conversacionales Multimodales*. [Tesis de maestría, Pontificia Universidad Católica del Perú]. Repositorio Institucional PUCP. <http://hdl.handle.net/20.500.12404/22090>.
- Belver, C. (2016). *Comparative study of human age estimation based on hand-crafted and deep face features*. [Tesis de maestría, Universidad del País Vasco]. Repositorio Institucional

- Universidad del País Vasco. <https://addi.ehu.es/bitstream/handle/10810/19054/master-thesis-upv-Carlos-Belver.pdf?sequence=1&isAllowed=y>.
- Benedikt, S., Zelger, P., Horling, L., Stock, K., Pallua, P., Schirmer, M., Degenhart, G., Ruzicka, A. y Arora, R. (2024). Las redes neuronales convolucionales profundas proporcionan clasificación del movimiento para la tomografía computarizada cuantitativa periférica de alta resolución del escafoides. *Diagnostics*, 14(5), 1-11. <https://doi.org/10.3390/diagnostics14050568>.
- Blasch, E., Liu, S., Liu, Z., y Zheng, Y. (2018). Deep Learning Measures of Effectiveness. *Conference: NAECON 2018 - IEEE National Aerospace and Electronics Conference*, 1, 1-9. <https://www.researchgate.net/publication/329473400>.
- Borja, R., Monleon, A., y Benedé, J. (2020). Estandarización de Métricas de Rendimiento para Clasificadores Machine y Deep Learning. *Revista Ibérica de Sistemas e Tecnologías de Informação Iberian Journal of Information Systems and Technologies*, 30, 172-184. https://www.researchgate.net/publication/339943922_Estandarizacion_de_Metricas_de_Rendimiento_para_Clasificadores_Machine_y_Deep_Learning.
- Cabello, E. (2004). *Técnicas de reconocimiento facial mediante redes neuronales*. [Tesis doctoral, Universidad Politécnica de Madrid]. Repositorio Institucional Universidad Politécnica de Madrid. <https://oa.upm.es/215/1/10200404.pdf>.
- Cadena, A. (2021). *Técnica eficiente para reconocimiento facial global utilizando wavelets y máquinas de vectores de soporte en imágenes 3D*. [Tesis doctoral, Universidad Nacional Mayor de San Marcos]. Repositorio Institucional UNMSM. <https://cybertesis.unmsm.edu.pe/backend/api/core/bitstreams/d39081f3-7cde-4368-9d1f-d3d31048b28b/content>.
- Cárdenas, M. (2012). *Optimización en el proceso de actualización informativa del portal de noticias*. [Tesis de pregrado, Universitat Oberta de Catalunya]. Repositorio

- Institucional Universitat Oberta de Catalunya.
<https://openaccess.uoc.edu/bitstream/10609/14731/9/mussioTFM0612memoria.pdf>.
- Casting And Acting. (06 de julio de 2021). ¿Qué es un casting abierto/cerrado? *casting and acting*. <https://www.castingandacting.com/que-es-un-casting-abierto-cerrado>
- Dantzig, G. (2002). Liner programming. *Operations Research*, 50(1), 42-47.
https://courses.cs.duke.edu/spring07/cps296.2/papers/LinearProgramming_article.pdf.
- Developers. (2024). ¿Cómo funciona U-net? developers arcgis
<https://developers.arcgis.com/python/latest/guide/how-unet-works/>
- Dibakar, S., Dutta, A., y Chandra, A. (2019). Convolutional Neural Networks for Noise Classification and Denoising of Images. *National Institute of Technology*, 1-6.
https://www.researchgate.net/publication/340128594_Convolutional_Neural_Networks_for_Noise_Classification_and_Denoising_of_Images.
- Eitca. (2024). *Academia Eitca y certificación en corto*. eitca org
<https://es.eitca.org/certificaciones/>
- Espinoza, R., Sánchez, M., Velasco, M., Sánchez, A., Romero, R. y Mory, W. (2023). *Metodología y estadística en la investigación científica*. (1ª ed.) Editorial Puerto Madero <https://doi.org/10.55204/PMEA.17>
- Farzadfard, K. (2021). Artificial intelligence in the visual effects and film industry. *omjournal*, 1, 1-10. https://www.omjournal.ir/files/cd_papers/r_1_240623233421.pdf.
- Fernández, F. (2024). Modelos Deep Learning para Diagnóstico de Covid-19 con Tomografías Computarizadas de Kaggle. *Revista Científica Multidisciplinar*, 8(3), 552-562.
https://doi.org/10.37811/cl_rcm.v8i3.11264.
- Gallardo, L. (2021). *Diseño y metodología de la investigación*. (1ª ed.). Enfoques Consulting EIRL. <https://eesppnsrmaadrededios.edu.pe/libros/3.pdf>

- Galliers, R., Leidner, D., y Simeonova, B. (2020). *Gestión de la Información Estratégica: Teoría y Práctica* (5.^a ed.). Routledge. <https://doi.org/10.4324/9780429286797>.
- García, E. (2007). The concept of the actor. Reflections and proposals for political science. *Andamios*, 3(6), 199-216. <https://www.scielo.org.mx/pdf/anda/v3n6/v3n6a8.pdf>.
- García, J. (2019). *Identificación automática de las fases del gesto de recepción en el vóley mediante análisis de videos usando redes neuronales convolucionales*. [Tesis de maestría, Pontificia Universidad Católica del Perú]. Repositorio Institucional PUCP. <http://tesis.pucp.edu.pe/repositorio/handle/20.500.12404/16690>.
- George, R., Gámez, Y., Matos, D., González, Iván., Labori, R., y Guevara, S. (2021). Eficacia, efectividad, eficiencia y equidad en relación con la calidad en los servicios de salud. *Infodir*, (35) 1-27. http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1996-35212021000200013
- Gerbotto, M., y Paturzo, C. (2020). Eating habits and body image perception in a group of adolescents who perform musical comedy. *Diaeta*, 38(172), 32-42. <https://www.scielo.org.ar/pdf/diaeta/v38n172/1852-7337-diaeta-38-172-26.pdf>.
- Gonzalez, C., y Thomason, M. (1978). *Syntactic pattern recognition: an introduction*. OSTI GOV. <https://www.osti.gov/biblio/5850937>
- Grm, K., Struc, V., Artiges, A., Caron, M., y Ekenel, H. (2017). Strengths and weaknesses of deep learning models for face recognition against image degradations. *IET Biom.*, 7(1), 81-99. <https://doi.org/10.1049/iet-bmt.2017.0083>.
- Hebbar, S. (17 de setiembre de 2023). Softmax para capas CNN intermedias. *Medium* <https://medium.com/@sharathhebbar24/softmax-for-intermediate-cnn-layers-f6d3b8b7d1d2>

- Hernández, R., y Mendoza, C. (2018). *Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta*. Mc Graw Hill Interamericana Editores, S.A. de C.V.
<https://doi.org/10.22201/fesc.20072236e.2019.10.18.6>
- Hernández, R., Mendez, S., Mendoza, C., & Cuevas, A. (2017). *Fundamentos de investigación*. Mc Graw Hill education. <https://es.scribd.com/document/748654581/Fundamentos-de-Investigacion-2017-Sampieri-R-Mendez-S-Mendoza-C-y-Cuevas-A>
- Hinton, G. (2002). Entrenamiento de productos de expertos mediante la minimización de la divergencia contrastiva. *Neural Comput* 14(8), 1771–1800.
<https://doi.org/10.1162/089976602760128018>.
- Horcajada, D. (2021). *Metodología para la detección de objetos en imágenes basada en la librería YOLO con aplicación a la detección de carros*. [Tesis de pregrado, Universidad de Sevilla]. Repositorio Institucional de la Universidad de Sevilla.
<https://idus.us.es/server/api/core/bitstreams/7180ef5c-5ae4-43d6-a26d-c0e6b5a73066/content>.
- Howard, A. (2013). Some Improvements on Deep Convolutional Neural Network Based Image Classification. *Computer Vision and Pattern Recognition*, 1, 1-6.
<https://arxiv.org/pdf/1312.5402>.
- Instituto de Gestión Cultural y Artística. (30 de septiembre de 2020). En qué consiste la dirección de casting. *IGCA*. <https://igeca.net/blog/322-en-que-consiste-la-direccion-de-casting>
- Kasar, M., Bhattacharyya, D., y Kim, T. (2016). Face Recognition Using Neural Network: A Review. *International Journal of Security and Its Applications*, 10(3), 81-100.
<http://dx.doi.org/10.14257/ijisia.2016.10.3.08>.

- Kloster, A. (2023). *Robustez en sistemas de Deep learning para detección de imágenes médicas*. [Tesis de maestría, Universidad Nacional de Cuyo]. Repositorio Institucional de la Universidad Nacional de Cuyo. <https://core.ac.uk/download/587008559.pdf>.
- Kokkiralala, N. (2019). Deep Neural Networks to Denoise Images. 2019.[Tesis de Maestria, Universidad Estatal de Georgia]. Repositorio Institucional Universidad Estatal de Georgia. <https://doi.org/10.57709/14946276>
- Kyocera. (sf). ¿Qué es el aprendizaje automático? *KYOCERA* <https://www.kyoceradocumentsolutions.es/es/smarter-workspaces/insights-hub/articles/que-es-el-aprendizaje-automatico.html>
- Li, J., Chu, S., y Shyang, J. (2007). Face Recognition with One Training Image per Person. *IEEE Xplore*, 1, 1-11. <https://doi.org/10.1109/IIH-MSP.2007.3>
- Manterola, C., Grande, L., Otzen, T., García, N., Salazar, P., y Quiroz, G. (2018). Confiabilidad, precisión o reproducibilidad de las mediciones. Métodos de valoración, utilidad y aplicaciones en la práctica clínica. *Rev. chil. infectol.* 35(6), 680-688. <http://dx.doi.org/10.4067/S0716-10182018000600680>.
- Mariani, M. (2019). Understanding customer satisfaction with services by leveraging big data: the role of services attributes and consumers' cultural background. *IEEE*, 7, 8195-8208. <https://doi.org/10.1109/ACCESS.2018.2887300>.
- Martínez, O., & Vargas, T. (2019). Procedure for managing the process of recruitment and selection of personnel based on local development. *Coodes*, 7(2), 225-242. <http://scielo.sld.cu/pdf/cod/v7n2/2310-340X-cod-7-02-225.pdf>.
- McCarthy, J. (12 de noviembre de 2007). What Is Artificial Intelligence. *formal stanford* <http://www-formal.stanford.edu/jmc/whatisai/node1.html>

- Mera, L. y Ochoa, J. (2021). Redes neuronales convolucionales para la clasificación de componentes independientes de rs-fMRI. *TecnoLógicas*, 24(50), 1-19. <https://doi.org/10.22430/22565337.1626>.
- Mikołajczyk, A. y Grochowski, M. (2018). Aumento de datos para mejorar el aprendizaje profundo en el problema de clasificación de imágenes. *Conference Paper*, 1, 1-7. https://www.researchgate.net/publication/325920702_Data_augmentation_for_impro.
- Omarzai, F. (18 de agosto de 2024). Segmentación de imágenes en profundidad. *Medium*. <https://medium.com/@fraidoonomarzai99/image-segmentation-in-depth-8ec11fb56371>
- Onofrey, J., Casetti, D., Lauritzen, A., Sarkar, S., Venkataraman, R., Fan, R., Sonn, G., Sprenkle, P., Staib, H. y Papademetris, X. (2019). Entrenamiento y pruebas generalizables en múltiples sitios de redes neuronales profundas mediante normalización de imágenes. *Proc IEEE Int Symp Biomed Imaging*, 1, 348-351. <https://pubmed.ncbi.nlm.nih.gov/32874427/>.
- Oracle Latam. (s.f.). Inteligencia artificial (IA). *Oracle Latinoamérica*. <https://www.oracle.com/latam/artificial-intelligence/>
- Ouyang, W., Chu, X., y Wang, X. (2014). Aprendizaje profundo multifuente para la estimación de la pose humana. *Conferencia IEEE*, 1, 2329-2336. doi: 10.1109/CVPR.2014.299.
- Palomino, J., Pérez, N., Quiñonez, L., y Cayatopa, B. (2023). Determination of Steel Area in Reinforced Concrete Beams Using Data Mining Techniques. *Revue d'Intelligence Artificielle*, 37(4), 817-824. <https://doi.org/10.18280/ria.370401>.
- Rami, C., Srinivasulu, U., y Krishna, K. (2019). Facial Emotion Recognition Using NLPCA and SVM. *Traitement du Signal*, 36(1), 13-22. <https://doi.org/10.18280/ts.360102>.
- Rodríguez, B. (2005). Documentary treatment of the audio–visual message. *Investig. bibl.*, 19(38), 140-160. <https://www.scielo.org.mx/pdf/ib/v19n38/v19n38a8.pdf>.

- Ronneberger, O., Fischer, P., y Brox, T. (2015). U-Net: Redes convolucionales para la segmentación de imágenes biomédicas. *arXiv*, 1, 1-8. <https://doi.org/10.48550/arXiv.1505.04597>.
- Rosario, A. (2021). El contexto de la inteligencia artificial aplicada al marketing. *Academy of strategic management journal*, 20(6), 1-19. <https://www.abacademies.org/articles/the-background-of-artificial-intelligence-applied-to-marketing-12567.html>.
- Roy, A., Bose, R., & Bhaduri, J. (2022). A fast accurate fine-grain object detection model based on YOLOv4 deep neural network. *arXiv* 1, 1-33. <https://arxiv.org/pdf/2111.00298>.
- Saavedra, C. (2022). It's better if you're a tomboy": construction of gender identity in the performance of female k-pop cover artists from Lima. *Desde el Sur*, 14(2), 1-22. <http://dx.doi.org/10.21142/des-1402-2022-0020>.
- Saha, S. (2018). A Comprehensive Guide to Convolutional Neural Networks - the ELI5 way. *Data Scientist*. 1, 1-10. https://ise.ncsu.edu/wp-content/uploads/sites/9/2022/08/A-Comprehensive-Guide-to-Convolutional-Neural-Networks-%E2%80%94-the-ELI5-way-_by-Sumit-Saha-_Towards-Data-Science.pdf
- Sánchez, A. (2019). Fundamentos epistémicos de la investigación cualitativa y cuantitativa: Consensos y disensos. *Revista Digital De Investigación En Docencia Universitaria*, 13(1). 1-21. <http://dx.doi.org/10.19083/ridu.2019.644>.
- Scarel, M. (2010). *Sistema de reconocimiento facial*. [Tesis de pregrado, Universidad Nacional del Litoral]. Repositorio Institucional Universidad Nacional del Litoral. https://sinc.unl.edu.ar/sinc-publications/2010/SMS10/sinc_SMS10.pdf.
- Scikit Learn. (s.f.). Máquinas de vectores de soporte *scikit learn org* <https://scikit-learn.org/stable/modules/svm.html>.
- Semma, A., Lazrak, S., Hannad, Y., Boukhan, M., y Kettan, Y. (2021). Writer Identification: The effect of image resizing on CNN performance. *Remote Sensing and Spatial*

- Information Sciences*, 45, 501-507. <https://doi.org/10.5194/isprs-archives-XLVI-4-W5-2021-501-2021>.
- Senousy, Z. (2023). *Medical Image Classification using Deep Learning Techniques and Uncertainty Quantification*. [Tesis Doctoral, Birmingham City University]. Repositorio Institucional Birmingham City University. https://www.open-access.bcu.ac.uk/14278/2/Zakaria%20Senousy%20PhD%20Thesis%20published_Final%20version_Submitted%20Oct%202022_Final%20Award%20Mar%202023.pdf.
- Shumpeter, J. (1996). *Capitalismo, socialismo y democracia*. (1ª ed.) Creative Commons. <https://archive.org/details/schumpeter-joseph.-capitalismo-socialismo-y-democracia.-vol.-i-1996/page/n3/mode/2up>
- Soto, J. (2020). Estandarización de organigramas y modelamiento del proceso de producción audiovisual: una propuesta basada en la toma de decisiones. *Cuadernos Info*, (33), 121–131. <https://doi.org/10.7764/cdi.33.525>
- Tejada, G., Flores M., Cruzado, W., Pajuelo C., Torres J., Sánchez, M., Patricio, S. y Velasco M. (2024). Inteligencia artificial en la gestión pública en Lima, 2024. *Revista de Climatología*, 24, 2094-2101. https://rclimatol.eu/wp-content/uploads/2024/09/Articulo-RCLIMCS24_Gina.pdf.
- Tennakoon, N., Senaweera, O., y Dharmarathne, H. (2024). Emotion-Based Movie Recommendation System. *International Journal on Advances in ICT for Emerging Regions*, 17 (1), 1-6. <https://icter.sljol.info/articles/7275/files/6659644ae69e5.pdf>.
- Thunuguntla, S., Murugaanandam, S., & Pitchai, R. (2023). Densenet121-DNN-Based Hybrid Approach for Advertisement Classification and User Identification. *International Journal of Intelligent Engineering and Systems*, 16(3), 162-174. <https://inass.org/wp-content/uploads/2023/01/2023063013-2.pdf>.

- Waldie, G. (2022). *Automated compilation of deep learning neural networks for image processing*. [Tesis de maestría, Loughborough University]. Repositorio Institucional Loughborough University. <https://doi.org/10.26174/thesis.lboro.19292414.v1>.
- Wang, Y., Liu, S., Li, S., Duan, J., Hou, Z., Yu, J., y Ma, K. (2019). Aprendizaje conjunto basado en apilamiento de datos de medios propios para la detección de intenciones de marketing. *Future Internet*, 11, 1-12. <https://ideas.repec.org/a/gam/jftint/v11y2019i7p155-d247252.html>.
- Weng, L. (2017). *Object Detection for Dummies Part 3: R-CNN Family*. Obtenido de <https://lilianweng.github.io/posts/2017-12-31-object-recognition-part-3/>
- Xu, L. (2021). *Aprendizaje profundo para la clasificación y segmentación de imágenes con datos etiquetados escasos*. [Tesis doctoral, Universidad de Australia Occidental]. Repositorio Institucional de la Universidad de Australia Occidental. <https://doi.org/10.26182/yddb-g338>
- Yamashita, R., Nishio, M., Do, R. y Togashi, k. (2018). Redes neuronales convolucionales: descripción general y aplicación en radiología. *Insights Imaging* 9, 611–629. doi:<https://doi.org/10.1007/s13244-018-0639-9>
- Yanan, S., Mengjie, Z., y Yen, G. (2020). Automatically designing CNN architectures using genetic algorithm for image classification. *ArXiv*, 1, 1-14. <https://arxiv.org/pdf/1808.03818>.
- Zárraga, L., Molina, V., y Corona, E. (2018). La satisfacción del cliente basada en la calidad del servicio a través de la eficiencia del personal y eficiencia del servicio: un estudio empírico de la industria restaurantera. *RECAI Revista de Estudios en Contaduría, Administración e Informática*, 7(18), 46-65. <https://recai.uaemex.mx/article/view/9268>.

IX ANEXOS

Anexo A. Matriz de consistencia

Problema	Objetivos	Hipótesis	Variables	Indicador	Índices	Metodología	Técnicas	Instrumento
Problema Principal	Objetivo General	Hipótesis General	Variables Independiente	Rendimiento del modelo	Precisión (Accuracy) = Numero de predicciones correctas / Total de Predicciones Recall (Sensibilidad o tasa de Verdadero Positivo) = TP/TP + FN F1-Socore = 2. (Precisión. Recall/precisión + Recall	Según (Gallardo, 2021).” El tipo de investigación usada es la Investigación Aplicada, ya que utilizamos los conocimientos adquiridos, además de la información de diferentes fuentes bibliográficas, todos ellos referidos a metodologías de calidad de software” (p.68). En consecuencia, se	- Encuesta -Análisis Documental	- Google Forms - Cuestionarios / Entrevistas - SPSS (versión 26).
Problema Secundario	Objetivo Secundario	Hipótesis Secundaria	Variables Dependientes		-Tiempo en clasificar los candidatos -Tiempo de a perfilamiento de imágenes digitalizadas -Tiempo de identificación de rasgos faciales -Tiempo de ordenar y a perfilar las imágenes digitalizadas -Tiempo de generación de pre-seleccionados			
PG: ¿En qué medida el uso de las Redes Neuronales Convolucionales contribuirá a mejorar el proceso de a perfilamiento en la selección de perfiles para el área de casting de la empresa audiovisual Spiral Producciones en Lima, Perú, durante el año 2024?	OG: Determinar el grado de influencia que ejercerá la implementación del uso de las Redes Neuronales Convolucionales para mejorar el proceso de a perfilamiento en la selección de perfiles para el área de casting de la empresa audiovisual Spiral Producciones en Lima, Perú, durante el año 2024.	HG: La implementación del uso de las Redes Neuronales Convolucionales contribuirá en mejorar el proceso de a perfilamiento en la selección de perfiles para el área de casting de la empresa audiovisual Spiral Producciones en Lima, Perú, durante el año 2024.	VI (X): Redes Neuronales Convolucionales	Proceso de Selección				
PE1: ¿En qué medida el uso de las Redes Neuronales Convolucionales contribuirá a reducir los tiempos del proceso de a perfilamiento en la selección de perfiles para el área de casting?	OE1: Determinar el grado de influencia que ejercerá la implementación del uso de las Redes Neuronales Convolucionales para reducir los tiempos del proceso de a perfilamiento en la selección de perfiles para el área de casting.	HE1: La implementación del uso de las Redes Neuronales Convolucionales contribuirá en reducir los tiempos del proceso de a perfilamiento en la selección de perfiles para el área de casting.	VD(Y): Optimización del proceso de a perfilamiento y tratamiento de imágenes					

PE2: ¿En qué medida el uso de las Redes Neuronales Convolucionales contribuirá a reducir el índice de errores del proceso de a perfilamiento en la selección de perfiles para el área de casting?	OE2: Determinar el grado de influencia que ejercerá la implementación del uso de las Redes Neuronales Convolucionales para reducir el índice de errores del proceso de a perfilamiento en la selección de perfiles para el área de casting.	HE2: La implementación del uso de las Redes Neuronales Convolucionales contribuirá en reducir el índice de errores del proceso de a perfilamiento en la selección de perfiles para el área de casting.				utilizará el tipo de investigación Aplicativa.	
PE3: ¿En qué medida el uso de las Redes Neuronales Convolucionales contribuirá a aumentar el índice de efectividad del proceso de a perfilamiento en la selección de perfiles para el área de casting?	OE3: Determinar el grado de influencia que ejercerá la implementación del uso de las Redes Neuronales Convolucionales para aumentar el índice de efectividad del proceso de a perfilamiento en la selección de perfiles para el área de casting.	HE3: La implementación del uso de las Redes Neuronales Convolucionales contribuirá en aumentar el índice de efectividad del proceso de a perfilamiento en la selección de perfiles para el área de casting.		Satisfacción del usuario de la gestión	Porcentaje de Satisfacción		

Anexo B. Validación de instrumentos

UNIVERSIDAD NACIONAL FEDERICO VILLARREAL ESCUELA UNIVERSITARIA DE POSGRADO MAESTRIAS: INGENIERÍA, ARQUITECTURA Y CIENCIAS BÁSICAS

Título de la Investigación: OPTIMIZACIÓN DEL PROCESO DE A PERFILAMIENTO Y TRATAMIENTO DE IMÁGENES UTILIZANDO REDES NEURONALES CONVOLUCIONALES PARA UNA EMPRESA DE LA INDUSTRIA CINEMATOGRAFICA Y PUBLICITARIA

PRE- TEST

Variable	Dimensiones	Indicador	Ítem	Pregunta	(1)	(2)	(3)	(4)	(5)
Variable Dependiente	Optimización del proceso de a perfilamiento y tratamiento de imágenes	Proceso de Selección	1	¿Está de acuerdo con los tiempos del proceso de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campañas?					
			2	¿Cree que es satisfactorio el actual proceso de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campañas?					
			3	¿Está de acuerdo con la calidad en los tiempos del proceso de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campañas?					
			4	¿Está de acuerdo con los resultados en los tiempos del proceso de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campañas?					

			5	¿Está de acuerdo con los tiempos del proceso de a perfilamiento de imágenes para la atención de las campañas?					
			6	¿Cree que es satisfactorio el actual del proceso de a perfilamiento de imágenes para la atención de las campañas?					
			7	¿Está de acuerdo con la calidad del proceso de a perfilamiento de imágenes para la atención de las campañas?					
			8	¿Está de acuerdo con los resultados del proceso de a perfilamiento de imágenes para la atención de las campañas?					
			9	¿Está de acuerdo con los tiempos del proceso de identificación de rasgos faciales para la atención de las campañas?					
			10	¿Cree que es satisfactorio el actual del proceso de identificación de rasgos faciales para la atención de las campañas?					
			11	¿Está de acuerdo con la calidad del proceso de a perfilamiento de imágenes para la atención de las campañas?					
			12	¿Está de acuerdo con los resultados del proceso de a perfilamiento de imágenes para la atención de las campañas?					

			13	¿Está de acuerdo con los tiempos ordenar y a perfilar las imágenes digitalizadas para la atención de las campañas?					
			14	¿Cree que es satisfactorio el actual del proceso de ordenar y a perfilar las imágenes digitalizadas para la atención de las campañas?					
			15	¿Está de acuerdo con la calidad del proceso de ordenar y a perfilar las imágenes digitalizadas para la atención de las campañas?					
			16	¿Está de acuerdo con los resultados del proceso de ordenar y a perfilar las imágenes digitalizadas para la atención de las campañas?					
			17	¿Está de acuerdo con los tiempos de generación de pre seleccionados para la atención de las campañas?					
			18	¿Cree que es satisfactorio el actual del proceso de generación de pre seleccionados para la atención de las campañas?					
			19	¿Está de acuerdo con la calidad del proceso de de generación de pre seleccionados para la atención de las campañas?					

			20	¿Está de acuerdo con los resultados del proceso de generación de pre seleccionados para la atención de las campañas?					
		Satisfacción del usuario de la gestión	21	¿Está de acuerdo con nivel de complejidad del actual proceso de perfilamiento y tratamiento de imágenes para la atención de las campañas?					
			22	¿Está de acuerdo con los procedimientos que usa el actual proceso de perfilamiento y tratamiento de imágenes para la atención de las campañas?					
			23	¿Está de acuerdo con la confiabilidad de los resultados que usa el actual proceso de perfilamiento y tratamiento de imágenes para la atención de las campañas?					

Donde:

Codificación en los Criterio de Evaluación/Escala de Valoración

Total mente desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	D'acuerdo	Total mente d'acuerdo
1	2	3	4	5

Elaborado por el Bachiller:

Carlos Joaquín Cuadra Rivera

EUPG - Cód. 2021005599

**UNIVERSIDAD NACIONAL FEDERICO VILLARREAL
ESCUELA UNIVERSITARIA DE POSGRADO
MAESTRIAS: INGENIERÍA, ARQUITECTURA Y CIENCIAS BÁSICAS**

Título de la Investigación: OPTIMIZACIÓN DEL PROCESO DE A PERFILAMIENTO Y TRATAMIENTO DE IMÁGENES UTILIZANDO REDES NEURONALES CONVOLUCIONALES PARA UNA EMPRESA DE LA INDUSTRIA CINEMATOGRAFICA Y PUBLICITARIA

POST – TEST

Variable	Dimensiones	Indicador	Ítem	Pregunta	(1)	(2)	(3)	(4)	(5)
Variable Dependiente	Optimización del proceso de a perfilamiento y tratamiento de imágenes	Proceso de Selección	1	¿Está de acuerdo con los tiempos del <i>nuevo proceso</i> de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campañas?					
			2	¿Cree que es satisfactorio el <i>nuevo proceso</i> de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campañas?					
			3	¿Está de acuerdo con la calidad en los tiempos del <i>nuevo proceso</i> de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campañas?					
			4	¿Está de acuerdo con los resultados en los tiempos del <i>nuevo proceso</i> de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campañas?					

			5	¿Está de acuerdo con los tiempos del <i>nuevo proceso</i> de a perfilamiento de imágenes para la atención de las campañas?					
			6	¿Cree que es satisfactorio el <i>nuevo proceso</i> de a perfilamiento de imágenes para la atención de las campañas?					
			7	¿Está de acuerdo con la calidad del <i>nuevo proceso</i> de a perfilamiento de imágenes para la atención de las campañas?					
			8	¿Está de acuerdo con los resultados del <i>nuevo proceso</i> de a perfilamiento de imágenes para para la atención de las campañas?					
			9	¿Está de acuerdo con los tiempos del <i>nuevo proceso</i> de identificación de rasgos faciales para la atención de las campañas?					
			10	¿Cree que es satisfactorio el <i>nuevo proceso</i> de identificación de rasgos faciales para la atención de las campañas?					
			11	¿Está de acuerdo con la calidad del <i>nuevo proceso</i> de a perfilamiento de imágenes para la atención de las campañas?					

			12	¿Está de acuerdo con los resultados del <i>nuevo proceso</i> de a perfilamiento de imágenes para la atención de las campañas?					
			13	¿Está de acuerdo con los nuevos tiempos de ordenar y a perfilar las imágenes digitalizadas para la atención de las campañas?					
			14	¿Cree que es satisfactorio el nuevo del proceso de ordenar y a perfilar las imágenes digitalizadas para la atención de las campañas?					
			15	¿Está de acuerdo con la calidad del nuevo proceso de ordenar y a perfilar las imágenes digitalizadas para la atención de las campañas?					
			16	¿Está de acuerdo con los resultados del <i>nuevo proceso</i> de ordenar y a perfilar las imágenes digitalizadas para la atención de las campañas?					
			17	¿Está de acuerdo con los <i>nuevos tiempos</i> de generación de pre seleccionados para la atención de las campañas?					
			18	¿Cree que es satisfactorio el <i>nuevo proceso</i> de generación de pre seleccionado para la atención de las campañas?					

			19	¿Está de acuerdo con la calidad del <i>nuevo proceso</i> de generación de pre seleccionados para la atención de las campañas?					
			20	¿Está de acuerdo con los resultados <i>del nuevo proceso</i> de generación de pre seleccionados para la atención de las campañas?					
		Satisfacción del usuario de la gestión	21	¿Está de acuerdo con el nivel de complejidad del nuevo proceso de perfilamiento y tratamiento de imágenes para la atención de las campañas?					
			22	¿Está de acuerdo con los procedimientos que usa el nuevo proceso de perfilamiento y tratamiento de imágenes para la atención de las campañas?					
			23	¿Está de acuerdo con la confiabilidad de los resultados que usa el nuevo proceso de perfilamiento y tratamiento de imágenes para la atención de las campañas?					

Donde:

Codificación en los Criterio de Evaluación/Escala de Valoración

Total mente desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Total mente de acuerdo
1	2	3	4	5

Elaborado por el Bachiller:

Carlos Joaquín Cuadra Rivera

EUPG - Cod. 2021005599

Juicio de expertos



**UNIVERSIDAD NACIONAL FEDERICO VILLARREAL
ESCUELA UNIVERSITARIA DE POSGRADO
MAESTRIA: INGENIERÍA, ARQUITECTURA Y CIENCIAS BÁSICAS**

**FICHA DE VALIDACIÓN DEL INSTRUMENTO DE INVESTIGACIÓN
JUICIO DE EXPERTOS**

I. DATOS GENERALES

I.1. Apellidos y Nombres: PEDRO MARTIN LEZAMA GONZALES

I.2. Grado académico: Doctor en Ingeniería de Sistemas, Maestría en Ingeniería de sistemas con mención en gestión de tecnologías de la información

I.3. Cargo e institución donde labora: Docente Universitario, Maestría en la UNMSM, UCV y la EUPG-UNFV, Pregrado en la UNMSM y la UNFV

I.4. Nombre del instrumento motivo de evaluación: CUESTIONARIO

I.5. Autor(A) de Instrumento: CUADRA RIVERA CARLOS JOAQUIN

I.6. Criterios de aplicabilidad:

a. De 01 a 09: (No válido, reformular)

d. De 16 a 17: (Válido, precisar)

b. De 10 a 12: (No válido, modificar)

e. De 19 a 20: (Válido aplicar)

c. De 13 a 15: (Válido, mejorar)

II. ASPECTOS DE VALIDACIÓN

INDICADORES DE EVALUACION DEL INSTRUMENTO	CRITERIOS CUALITATIVOS CUANTITATIVOS	Deficiente (01-09)	Regular (10-12)	Bueno (13-15)	Muy Bueno (16-18)	Excelente (19-20)
		1	2	3	4	5
1. CLARIDAD	Esta formulado con lenguaje comprensible.					X
2. OBJETIVIDAD	Esta adecuado a las leyes y principios científicos.					X
3. ACTUALIDAD	Esta adecuado a los objetivos y las necesidades reales de la investigación.					X
4. ORGANIZACIÓN	Existe una organización lógica.					X
5. SUFICIENCIA	Toma en cuenta los aspectos metodológicos esenciales					X
6. INTENCIONALIDAD	Esta adecuado para valorar las variables de la Hipótesis.					X
7. CONSISTENCIA	Se respalda en fundamentos técnicos y/o científicos.					X
8. COHERENCIA	Existe coherencia entre los problemas objetivos, hipótesis, variables e indicadores.					X
9. METODOLOGÍA	La estrategia responde una metodología y diseño aplicados para lograr probar las hipótesis.					X
10. PERTINENCIA	El instrumento muestra la relación entre los componentes de la investigación y su adecuación al Método Científico.					X

VALORACIÓN CUANTITATIVA (TOTAL X 0.4): 20.

Lima, 18 de Enero del 2024

VALORACIÓN CUALITATIVA: **VÁLIDO**

OPINIÓN DE APLICABILIDAD: **APLICAR**

DNI No 09656793

Telf.: 945473135

FIRMA DEL EXPERTO INFORMANTE

FICHA DE VALIDACIÓN DEL INSTRUMENTO DE INVESTIGACIÓN JUICIO DE EXPERTOS

c. De 13 a 15: (Válido, mejorar)

I. retalike

FIRMA DEL EXPERTO INFORMANTE

FICHA DE VALIDACIÓN DEL INSTRUMENTO DE INVESTIGACIÓN

- I.1. Apellidos y Nombres: GUILLERMO PASTOR MORALES ROMERO
- I.2. Grado académico: Dr. Ciencias de la Educación, Mg. Ingeniería de Sistemas
- I.3. Cargo e institución donde labora: Universidad Nacional Enrique Guzmán y Valle - Director de la Escuela Académica de Matemática e Informática
- I.4. Nombre del instrumento motivo de evaluación: CUESTIONARIO
- I.5. Autor(A) de Instrumento: CUADRA RIVERA CARLOS JOAQUIN
- I.6. Criterios de aplicabilidad:
 - a. De 01 a 09: (No válido, reformular)
 - b. De 10 a 12: (No válido, modificar)
 - c. De 13 a 15: (Válido, mejorar)
 - d. De 16 a 17: (Válido, precisar)
 - e. De 19 a 20: (Válido aplicar)

INDICADORES DE EVALUCION DEL INSTRUMENTO	CRITERIOS CUALITATIVOS CUANTITATIVOS	Deficiente (01-09)	Regular (10-12)	Bueno (13-15)	Muy Bueno (16-18)	Excelente (19-20)
		1	2	3	4	5
1. CLARIDAD	Esta formulado con lenguaje comprensible.					X
2. OBJETIVIDAD	Esta adecuado a las leyes y principios científicos.					X
3. ACTUALIDAD	Esta adecuado a los objetivos y las necesidades reales de la investigación.					X
4. ORGANIZACIÓN	Existe una organización lógica.					X
5. SUFICIENCIA	Toma en cuenta los aspectos metodológicos esenciales					X
6. INTENCIONALIDAD	Esta adecuado para valorar las variables de la Hipótesis.					X
7. CONSISTENCIA	Se respalda en fundamentos técnicos y/o científicos.					X
8. COHERENCIA	Existe coherencia entre los problemas objetivos, hipótesis, variables e indicadores.					X
9. METODOLOGÍA	La estrategia responde una metodología y diseño aplicados para lograr probar las hipótesis.					X
10. PERTINENCIA	El instrumento muestra la relación entre los componentes de la investigación y su adecuación al Método Científico.					X

Lima, 18 de Enero del 2024

GYRONALES

FIRMA DEL EXPERTO INFORMANTE

Telf.: 939319870

Anexo C. Confiabilidad de Instrumentos

Figura 5

Formula del Alfa de Cronbach

$$\alpha = \frac{N * \bar{c}}{\bar{v} + (N - 1) * \bar{c}}$$

Fuente: Elaboración propia

Donde:

- N = el número de elementos.
- $\bar{c}$ = covarianza promedio entre pares de ítems.
- $\bar{v}$ = varianza promedio.

El alfa de Cronbach va de 0 a 1. Mayor fiabilidad cuando se acerca a 1, menor fiabilidad o consistencia cuando se acerca a cero.

Cuando tiende a cero indica que no hay ninguna correlación entre los elementos. Son totalmente independientes. Es decir, conocer el valor de una respuesta a una pregunta no proporciona información sobre las respuestas a las otras preguntas.

Cuando tiende a 1 indica que están perfectamente correlacionados. Conocer el valor de una respuesta proporciona información completa sobre los demás elementos.

Figura 6

Rangos del Alfa de Cronbach

Alfa de Cronbach	Consistencia Interna
$\alpha \geq 0,9$	Excelente
$0,8 \leq \alpha < 0,9$	Buena
$0,7 \leq \alpha < 0,8$	Aceptable
$0,6 \leq \alpha < 0,7$	Cuestionable
$0,5 \leq \alpha < 0,6$	Pobre
$\alpha < 0,5$	Inaceptable

- Confiabilidad Pre-Test

Para el instrumento que midió la variable dependiente antes de la aplicación del nuevo modelo de desarrollo de software y puede observar que el alfa de Cronbach fue de 0.833 , que denota que es instrumento confiable.

Tabla 17

Resultado de Fiabilidad Pre- Test

Alfa de Cronbach	N de elementos
0,833	23

- Confiabilidad Pos-Test

Para el instrumento que midió la variable dependiente después de la aplicación del nuevo modelo de desarrollo de software y puede observar que el alfa de Cronbach fue de 0.820 , que denota un instrumento confiable, motivo por el cual se aprueba el instrumento.

Tabla 18

Resultado de Fiabilidad Post - Test

Alfa de Cronbach	N de elementos
,820	23

Anexo D. Instrumento de medición

Programa de Convulcion de Matrices

```
import numpy as np

# Definir las matrices
matriz_imagen = np.array([
    [0.0, 0.0, 0.2, 0.2, 0.2, 0.2],
    [0.0, 0.0, 0.2, 0.2, 0.2, 0.8],
    [0.0, 0.0, 0.0, 0.0, 0.6, 0.6],
    [0.0, 0.0, 0.0, 0.0, 0.3, 0.5],
    [0.0, 0.0, 0.0, 0.0, 0.3, 0.9],
    [0.0, 0.0, 0.0, 0.0, 0.0, 0.0]
])

matriz_nucleo = np.array([
    [1, 0, 1],
    [0, 1, 0],
    [1, 0, 1]
])

# Realizar la convolución usando el producto de Hadamard y sumando los resultados
output_size = matriz_imagen.shape[0] - matriz_nucleo.shape[0] + 1
resultado_convolucionado = np.zeros((output_size, output_size))

for i in range(output_size):
    for j in range(output_size):
        # Extraer la porción de la imagen que corresponde al tamaño del núcleo
        sub_matriz = matriz_imagen[i:i+matriz_nucleo.shape[0], j:j+matriz_nucleo.shape[1]]

        # Producto de Hadamard y suma
        resultado = np.sum(sub_matriz * matriz_nucleo)
        resultado_convolucionado[i, j] = resultado

resultado_convolucionado
```

```
array([[0.2, 0.4, 1.2, 1.2],
       [0.2, 0.2, 0.7, 2.1],
       [0. , 0. , 0.9, 1.8],
       [0. , 0. , 0.3, 0.8]])
```

Distribución de la encuesta según los indicadores y las hipótesis

	PRE	POS	IND	Hipotesis
1	¿Esta de acuerdo con los tiempos del proceso de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campaña?	¿Esta de acuerdo con los tiempos del <i>nuevo proceso</i> de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campaña?	1	H1
2	¿Cree que es satisfactorio el actual proceso de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campaña?	¿Cree que es satisfactorio el <i>nuevo proceso</i> de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campaña?	1	H3
3	¿Esta de acuerdo con la calidad en los tiempos del proceso de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campaña?	¿Esta de acuerdo con la calidad en los tiempos del <i>nuevo proceso</i> de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campaña?	1	H1
4	¿Esta de acuerdo con los resultados en los tiempos del proceso de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campaña?	¿Esta de acuerdo con los resultados en los tiempos del <i>nuevo proceso</i> de clasificación de candidatos en el perfilamiento y tratamiento de imágenes para la atención de las campaña?	1	H1
5	¿Esta de acuerdo con los tiempos del proceso de perfilamiento de imágenes para la atención de las campaña?	¿Esta de acuerdo con los tiempos del <i>nuevo proceso</i> de perfilamiento de imágenes para la atención de las campaña?	2	H1
6	¿Cree que es satisfactorio el actual del proceso de perfilamiento de imágenes para la atención de las campaña?	¿Cree que es satisfactorio el <i>nuevo proceso</i> de perfilamiento de imágenes para la atención de las campaña?	2	H3
7	¿Esta de acuerdo con la calidad del proceso de perfilamiento de imágenes para la atención de las campaña?	¿Esta de acuerdo con la calidad del <i>nuevo proceso</i> de perfilamiento de imágenes para la atención de las campaña?	2	H2
8	¿Esta de acuerdo con los resultados del proceso de perfilamiento de imágenes para la atención de las campaña?	¿Esta de acuerdo con los resultados del <i>nuevo proceso</i> de perfilamiento de imágenes para la atención de las campaña?	2	H2
9	¿Esta de acuerdo con los tiempos del proceso de identificación de rasgos faciales para la atención de las campaña?	¿Esta de acuerdo con los tiempos del <i>nuevo proceso</i> de identificación de rasgos faciales para la atención de las campaña?	3	H1
10	¿Cree que es satisfactorio el actual del proceso de identificación de rasgos faciales para la atención de las campaña?	¿Cree que es satisfactorio el <i>nuevo proceso</i> de identificación de rasgos faciales para la atención de las campaña?	3	H3
11	¿Esta de acuerdo con la calidad del proceso de identificación de rasgos faciales para la atención de las campaña?	¿Esta de acuerdo con la calidad del <i>nuevo proceso</i> de perfilamiento de imágenes para la atención de las campaña?	3	H2
12	¿Esta de acuerdo con los resultados del proceso de identificación de rasgos faciales para la atención de las campaña?	¿Esta de acuerdo con los resultados del <i>nuevo proceso</i> de perfilamiento de imágenes para la atención de las campaña?	3	H2
13	¿Esta de acuerdo con los nuevos tiempos de ordenar y a perfilar las imágenes digitalizadas para la atención de las campaña?	¿Esta de acuerdo con los nuevos tiempos de ordenar y a perfilar las imágenes digitalizadas para la atención de las campaña?	4	H1
14	¿Cree que es satisfactorio el actual del proceso de ordenar y a perfilar las imágenes digitalizadas para la atención de las campaña?	¿Cree que es satisfactorio el <i>nuevo</i> del proceso de ordenar y a perfilar las imágenes digitalizadas para la atención de las campaña?	4	H3
15	¿Esta de acuerdo con la calidad del proceso de ordenar y a perfilar las imágenes digitalizadas para la atención de las campaña?	¿Esta de acuerdo con la calidad del <i>nuevo proceso</i> de ordenar y a perfilar las imágenes digitalizadas para la atención de las campaña?	4	H2
16	¿Esta de acuerdo con los resultados del proceso de ordenar y a perfilar las imágenes digitalizadas para la atención de las campaña?	¿Esta de acuerdo con los resultados del <i>nuevo proceso</i> de ordenar y a perfilar las imágenes digitalizadas para la atención de las campaña?	4	H3
17	¿Esta de acuerdo con los tiempos de generación de pre-seleccionados para la atención de las campaña?	¿Esta de acuerdo con los <i>nuevos tiempos</i> de generación de pre-seleccionados para la atención de las campaña?	5	H1
18	¿Cree que es satisfactorio el actual del proceso de generación de pre-seleccionados para la atención de las campaña?	¿Cree que es satisfactorio el <i>nuevo proceso</i> de generación de pre-seleccionados para la atención de las campaña?	5	H3
19	¿Esta de acuerdo con la calidad del proceso de de generación de pre-seleccionados para la atención de las campaña?	¿Esta de acuerdo con la calidad del <i>nuevo proceso</i> de de generación de pre-seleccionados para la atención de las campaña?	5	H2
20	¿Esta de acuerdo con los resultados del proceso de de generación de pre-seleccionados s para la atención de las campaña?	¿Esta de acuerdo con los resultados <i>del nuevo proceso</i> de de generación de pre-seleccionados s para la atención de las campaña?	5	H3
21	¿Esta de acuerdo con nivel de complejidad del actual proceso de perfilamiento y tratamiento de imágenes para la atención de las campaña ?	¿Esta de acuerdo con nivel de complejidad del <i>nuevo proceso</i> de perfilamiento y tratamiento de imágenes para la atención de las campaña ?		H3
22	¿Esta de acuerdo con los procedimientos que usa el actual proceso de perfilamiento y tratamiento de imágenes para la atención de las campaña ?	¿Esta de acuerdo con los procedimientos que usa el <i>nuevo proceso</i> de perfilamiento y tratamiento de imágenes para la atención de las campaña ?		H3
23	¿Esta de acuerdo con los confiabilidad de los resultados que usa el actual proceso de perfilamiento y tratamiento de imágenes para la atención de las campaña ?	¿Esta de acuerdo con los confiabilidad de los resultados que usa el <i>nuevo proceso</i> de perfilamiento y tratamiento de imágenes para la atención de las campaña ?		H3

Anexo E. Determinación de la muestra de estudio

Figura 7

Formula: de Muestra Población Finita

$$n = \frac{(p.q) Z^2 \cdot N}{(E^2) (N-1) + (p.q) Z^2}$$

Donde:

Parámetro	Valor	Donde
N	300	Tamaño de Población o Universo
Z	1,960	Parámetro estadístico de nivel de Confianza
P	0.5%	Probabilidad que ocurra el evento estudiado (éxito)
Q	0.5%	Probabilidad que no ocurra el evento estudiado (p – 1)
e	5%	Error de estimación máximo Aceptado

Fuente: Elaboración propia

Sustituyendo y Calculando, tenemos que el tamaño de la muestra es de 168 imágenes.

Anexo F. Procesamiento

Por lo general, el alfa es calculada mediante el uso de software estadístico, como SPSS, R Studio, cuya fórmula es la siguiente:

Figura 8

Código Python de carga de imágenes

```
from IPython import get_ipython
from IPython.display import display
from pyspark.sql import SparkSession
from pyspark.conf import SparkConf
from pyspark.sql.functions import udf, lit
from pyspark.sql.types import BinaryType, StringType
import cv2
import numpy as np

try:
    spark.stop()
except:
    pass

# Configure Spark
conf = SparkConf().setAppName("ImageProcessing").setMaster("local[*]")
spark = SparkSession.builder.config(conf=conf).getOrCreate()

images_input = '/content/drive/MyDrive/extracted_faces'
image_df = spark.read.format("binaryFile") \
    .option("pathGlobFilter", "*. {jpg,jpeg,png,bmp}") \
    .option("recursiveFileLookup", "true") \
    .load(images_input)
```

Fuente: Elaboración propia

Figura 9*Revisión del Dataset*

```
[ ] image_df.show(truncate=False)
```

path	modificationTime	length	content
file:/content/drive/MyDrive/extracted_faces/dp02_face_1.jpg	2024-07-16 00:08:09	20015	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/dp02_face_2.jpg	2024-07-16 00:08:09	17218	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/dp02_face_0.jpg	2024-07-16 00:08:09	17060	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/dp02_face_4.jpg	2024-07-16 00:08:09	15211	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/led01_face_0.jpg	2024-07-16 00:08:16	14696	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/dp02_face_3.jpg	2024-07-16 00:08:09	14113	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/led01_face_2.jpg	2024-07-16 00:08:16	10454	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/led01_face_3.jpg	2024-07-16 00:08:16	10243	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/led01_face_1.jpg	2024-07-16 00:08:16	10013	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/dp05_face_4.jpg	2024-07-16 00:08:13	8966	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/bs3_face_1.jpg	2024-07-16 00:08:06	8887	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/bs3_face_3.jpg	2024-07-16 00:08:06	8068	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/led03_face_2.jpg	2024-07-16 00:08:19	7173	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/bs3_face_2.jpg	2024-07-16 00:08:06	6422	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/dp05_face_3.jpg	2024-07-16 00:08:13	6324	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/dp05_face_1.jpg	2024-07-16 00:08:13	6242	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/bs3_face_0.jpg	2024-07-16 00:08:06	6000	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/led04_face_2.jpg	2024-07-16 00:08:21	5849	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/led04_face_3.jpg	2024-07-16 00:08:21	5519	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB
file:/content/drive/MyDrive/extracted_faces/led03_face_3.jpg	2024-07-16 00:08:19	5111	[FF D8 FF E0 00 10 4A 46 49 46 00 01 01 00 00 01 00 01 00 00 FF DB


only showing top 20 rows

Fuente: Elaboración propia

- Para el pre-procesamiento Primero, ajustamos todas las imágenes a un tamaño uniforme para que tengan las mismas dimensiones. Esto se realiza redimensionando cada imagen a nivel de píxeles, asegurando que todas tengan el mismo tamaño y forma. Luego, homogenizamos las imágenes convirtiéndolas a una escala de grises estandarizada. Esto nos ayuda a mantener la consistencia en la representación de la intensidad de los píxeles, eliminando las variaciones de color. A continuación, aplicamos técnicas de reducción de ruido para limpiar las imágenes de cualquier interferencia no deseada. Usamos filtros específicos, como el desenfoque gaussiano, para suavizar las imágenes y mejorar su calidad. Finalmente, una vez completado el proceso de limpieza, el sistema genera imágenes mejoradas que están listas para ser utilizadas por los modelos de redes neuronales convolucionales (CNN). Estas imágenes pre procesadas ofrecen una entrada más uniforme y clara, lo que optimiza el rendimiento y la precisión de los modelos en tareas de clasificación y reconocimiento.

Figura 10

Flujo de proceso de limpieza de las imágenes usando CNN



Fuente Elaboración propia

- Ajustar las imágenes a un tamaño estándar (128 x 128)

```
# Define UDFs
def resize_image_udf(content, standard_size=(128, 128)):
    image = cv2.imdecode(np.frombuffer(content, np.uint8), cv2.IMREAD_COLOR)
    resized_image = cv2.resize(image, standard_size)
    _, buffer = cv2.imencode('.jpg', resized_image)
    return buffer.tobytes()
```

- Normalización de imágenes (usando el método MinMax)

```
def normalize_image_udf(content, normalization_type='minmax'):
    image = cv2.imdecode(np.frombuffer(content, np.uint8), cv2.IMREAD_COLOR)
    if normalization_type == 'minmax':
        normalized_image = cv2.normalize(image, None, alpha=0, beta=1, norm_type=cv2.NORM_MINMAX, dtype=cv2.CV_32F)
    elif normalization_type == 'meanstd':
        normalized_image = (image - image.mean()) / image.std()
    else:
        raise ValueError("Tipo de normalización no válido. Elija 'minmax' o 'meanstd'.")
    _, buffer = cv2.imencode('.jpg', (normalized_image * 255).astype('uint8'))
    return buffer.tobytes()
```

```
# Se Aplica las transformaciones
resized_df = image_df.withColumn("resized_content", resize_udf(image_df["content"]))
normalized_df = resized_df.withColumn("normalized_content", normalize_udf(resized_df["resized_content"], lit("minmax")))
```

```
# Se graban las imagenes normalizadas en un nuevo directorio
normalized_pandas_df = normalized_df.select("path", "normalized_content").toPandas()
output_folder_minmax = "/content/drive/MyDrive/fotos_minmax"
for index, row in normalized_pandas_df.iterrows():
    image_path = row['path']
    image_content = row['normalized_content']

    print ('la ruta ' + image_path + ' la imagen ' + str(image_content) + '\n')
```

- Aplicación de reducción de Ruidos y normalización en escala de Grises

```

image_array = cv2.imdecode(np.frombuffer(image_data, np.uint8), cv2.IMREAD_COLOR)
if image_array is None:
    return None

###
# Reduccion de Ruido
blurred_image = cv2.GaussianBlur(image_array, (5, 5), 0) # Adjust kernel size as needed
# Convertir en escala de Gris
gray_image = cv2.cvtColor(blurred_image, cv2.COLOR_BGR2GRAY)
###


# Se aplican filtros para la reduccion
denoised_image = cv2.GaussianBlur(gray_image, (5,5),0)

# Ruta de Salida
image_name = os.path.basename(image_path)
output_path = os.path.join(output_folder, image_name)

# Grabar la Nueva Imagen
cv2.imwrite(output_path, (denoised_image).astype(np.uint8)) # Imagen en escala de Gris
return output_path # Retorna la ruta de grabacion de la nueva imagen

```

- Después, se dividió el conjunto de datos en tres partes: el 70% se destinó al entrenamiento del modelo, el 15% se usó para la validación, y el 15% restante se reservó para la prueba del modelo. El conjunto de entrenamiento se utiliza para enseñar al modelo CNN, permitiéndole aprender de los datos y ajustar sus parámetros. El conjunto de validación ayuda a ajustar y optimizar el modelo durante el proceso, asegurando que no se ajuste en exceso a los datos de entrenamiento. Finalmente, el conjunto de prueba se usa para evaluar el rendimiento del modelo en datos nuevos y desconocidos, proporcionando una medida de su capacidad para generalizar y hacer predicciones precisas.


Figura 11*Procese de entrenamiento y validación de modelo*

Fuente: (Yamashita et al., 2018)

- Una vez que tenga el modelo CNN organizado, se realizara la actividad de validación de las fotos para los procesos de selección.
- Contenido de la carpeta de imágenes de referencia y conocer el porcentaje de coincidencia vs El contenido de la carpeta de las imágenes que quiere comparar

Figura 12

Flujo de proceso de selección de imágenes según la referencia



Fuente Elaboración propia

- Se cargará la foto a evaluar por el modelo CNN.

```
def load_images_from_folder(folder):
    images = []
    labels = []
    for filename in os.listdir(folder):
        img = face_recognition.load_image_file(os.path.join(folder, filename))
        if img is not None:
            images.append(img)
            labels.append(os.path.splitext(filename)[0])
    return images, labels

# Cargar imágenes de referencia y codificar los rostros
reference_images, labels = load_images_from_folder('/content/drive/MyDrive/fotos_gr/')

# Filtrar imágenes que contienen rostros y obtener sus codificaciones
reference_encodings = []
valid_labels = []
valid_images = []
for i, image in enumerate(reference_images):
    encodings = face_recognition.face_encodings(image)
    if len(encodings) > 0:
        reference_encodings.append(encodings[0])
        valid_labels.append(labels[i])
        valid_images.append(image)
```

- Se iniciará el proceso de comparación y de perfilado de candidatos, según la muestra con el objetivo de medir el % de acierto del modelo CNN. Se define umbral de un porcentaje de coincidencia de un 97% en el proceso de comparación:

```

# Cargar las imágenes que quieres comparar (modificado para multiples imágenes)
unknown_images_folder = '/content/drive/MyDrive/fotos Fu/'
unknown_images = []
for filename in os.listdir(unknown_images_folder):
    img = face_recognition.load_image_file(os.path.join(unknown_images_folder, filename))
    if img is not None:
        unknown_images.append(img)

match_threshold = 97

# Iterar sobre cada imagen desconocida
for unknown_image in unknown_images:
    unknown_encodings = face_recognition.face_encodings(unknown_image)

    if len(unknown_encodings) > 0:
        unknown_encoding = unknown_encodings[0]

        # Listas para almacenar imágenes coincidentes y no coincidentes
        matching_images = []
        non_matching_images = []

        # Comparar con cada imagen de referencia
        for i, ref_encoding in enumerate(reference_encodings):
            face_distance = face_recognition.face_distance([ref_encoding], unknown_encoding)[0]
            match_percentage = (1 - face_distance) * 100

            if match_percentage >= match_threshold:
                matching_images.append((valid_images[i], valid_labels[i], match_percentage))
            else:
                non_matching_images.append((valid_images[i], valid_labels[i], match_percentage))

```

- Continuación: (hace el filtro para solo mostrar las imágenes con un % mayor del 97 % de similitud con las imágenes de muestra.

```

# Mostrar resultados para la imagen desconocida actual (condicionado a >97%)
print(f"Resultados para la imagen: {filename}")

if matching_images: # Verificar si hay coincidencias
    print("Imágenes coincidentes:")
    for img, label, match_percentage in matching_images:
        if match_percentage >= 97: # Condición para mostrar solo coincidencias >= 97%
            print(f'{label}: {match_percentage:.2f}%')
            img_bgr = cv2.cvtColor(img, cv2.COLOR_RGB2BGR)
            cv2.imshow(img_bgr)
else:
    print("No se encontraron coincidencias con un porcentaje mayor al 97%.")

# Mostrar imágenes no coincidentes (opcional)
# ... (código para mostrar imágenes no coincidentes si es necesario)

unknown_image_bgr = cv2.cvtColor(unknown_image, cv2.COLOR_RGB2BGR)
cv2.imshow(unknown_image_bgr)


cv2.waitKey(0)
cv2.destroyAllWindows()

else:
    print(f"No se encontró ningún rostro en la imagen: {filename}")

```

- Evaluación de los resultados de las imágenes de digitalizadas obtenidas como válidas (con un % Mayor igual al 97 % de similitud). Este parámetro de configuro a solicitud del cliente para poder acortar la diferencia de las coincidencias según la conveniencia del proceso tanta para reducir los candidatos seleccionados, como para ampliar el abanico de las posibilidades.

Tabla 19*Muestra de resultado del proceso de selección*

Imágenes Aceptadas ($\geq 97\%$)	Imágenes Rechazadas ($< 90\%$)	
Resultados para la imagen: dp02_face_1.png Imágenes coincidentes: dp02_face_1: 99.97% 	Resultados para la imagen: dp02_face_4.png Imágenes coincidentes: dp02_face_4: 89.13% 	Resultados para la imagen: bs2_face_2.png Imágenes coincidentes: bs2_face_2: 48.31% 
Resultados para la imagen: dp02_face_2.png Imágenes coincidentes: dp02_face_2: 99.93% 	Resultados para la imagen: dp03_face_4.png Imágenes coincidentes: dp03_face_4: 88.32% 	Resultados para la imagen: pf01_face_2.png Imágenes coincidentes: pf01_face_2: 30.23% 
Resultados para la imagen: BS1_face_0.png Imágenes coincidentes: dp02_face_2: 97.44% 	Resultados para la imagen: led04_face_0.png Imágenes coincidentes: led04_face_0: 73.32% 	Resultados para la imagen: dp02_face_1.png Imágenes coincidentes: dp02_face_1: 28.32% 
Resultados para la imagen: pf01_face_3.png Imágenes coincidentes: dp02_face_2: 97.18% 	Resultados para la imagen: dp01_face_4.png Imágenes coincidentes: dp01_face_4: 59.02% 	Resultados para la imagen: uh01_face_4.png Imágenes coincidentes: dp01_face_4: 20.02% 

Elaboración propia

- Se procederá a recopilar los resultados
- El usuario del Área llena la encuesta hecha en Google-Forms para medir los resultados durante 1 semana.
- Se ejecutará el proceso computarizado con SPSS de las encuestas.
- Redacción del informe final.

Anexo G. Resultados – figuras

Figura 13

Resultados del Indicador: Tiempo en clasificar los candidatos

Muestra	Pregunta_1	Pregunta_2	Pregunta_3	Pregunta_4	Pre_Post_1	Pre_Post_2	Pre_Post_3	Pre_Post_4	T_Pre	T_Pos
1	2	1	3	2	5	5	5	5	8	20
2	1	3	2	3	5	5	5	4	9	19
3	3	2	1	1	4	5	5	5	7	19
4	2	1	3	2	5	5	4	4	8	18
5	3	2	2	1	4	5	5	4	8	18
6	1	3	1	2	5	5	4	5	7	19
7	2	2	3	3	4	5	5	5	10	19
8	3	1	2	1	5	5	4	4	7	18
9	1	2	1	3	4	5	5	4	7	18
10	2	3	3	2	5	5	4	5	10	19
11	3	2	1	1	4	5	5	5	7	19
12	1	1	2	3	5	5	4	4	7	18
13	2	3	3	2	4	5	5	4	10	18
14	3	1	1	1	5	5	4	5	6	19
15	1	2	2	3	4	5	5	5	8	19
16	2	3	1	2	5	5	4	4	8	18
17	3	2	3	1	4	5	5	4	9	18
18	1	1	2	3	5	5	4	5	7	19
19	2	3	1	2	4	5	5	5	8	19
20	2	3	1	2	4	5	5	5	8	19

Fuente: Elaboración propia

Leyenda:

- Pregunta_#: Valor obtenido en el número de pregunta, según corresponda (Pre-Test)
- Pre_Post_#: Valor obtenido en el número de pregunta, según corresponda (Pos-Test)
- T_Pre : Sumatoria de valores Pre Test
- T_Pos : Sumatoria de valores Pos Test

Figura 14

Resultados del Indicador: Tiempo de a perfilamiento de imágenes digitalizadas

Muestra	Pregunta_5	Pregunta_6	Pregunta_7	Pregunta_8	Pre_Post_5	Pre_Post_6	Pre_Post_7	Pre_Post_8	T_Pre	T_Pos
1	3	2	1	2	5	5	5	5	8	20
2	2	1	3	3	5	5	5	4	9	19
3	1	3	2	1	4	5	5	5	7	19
4	3	1	2	3	5	5	4	4	9	18
5	2	3	1	1	4	5	5	4	7	18
6	1	2	3	2	5	5	4	5	8	19
7	3	3	2	1	4	5	5	5	9	19
8	2	1	1	3	5	5	4	4	7	18
9	1	2	3	2	4	5	5	4	8	18
10	3	3	1	2	5	5	4	4	9	18
11	2	1	3	3	4	5	5	4	9	18
12	1	3	2	1	5	5	5	4	7	19
13	3	2	3	1	5	5	5	4	9	19
14	2	3	1	2	5	5	5	5	8	20
15	1	1	2	3	5	5	5	5	7	20
16	3	2	3	1	5	5	4	4	9	18
17	2	1	1	2	4	5	5	4	6	18
18	1	3	3	1	5	5	4	5	8	19
19	3	1	2	3	4	5	5	5	9	19
20	3	1	2	3	4	5	5	5	9	19

Fuente: Elaboración propia

Leyenda:

- Pregunta_#: Valor obtenido en el número de pregunta, según corresponda (Pre-Test)
- Pre_Post_#: Valor obtenido en el número de pregunta, según corresponda (Pos-Test)
- T_Pre : Sumatoria de valores Pre Test
- T_Pos : Sumatoria de valores Pos Test

Figura 15*Resultados del Indicador: Tiempo de identificación de rasgos faciales*

Muestra	Pregunta_9	Pregunta_10	Pregunta_11	Pregunta_12	Pre_Post_9	Pre_Post_10	Pre_Post_11	Pre_Post_12	T_Pre	T_Pos
1	2	3	1	3	5	5	4	5	9	19
2	3	1	2	2	5	5	4	4	8	18
3	1	2	3	1	4	5	5	5	7	19
4	3	2	1	3	5	5	4	4	9	18
5	2	1	3	2	4	5	5	4	8	18
6	1	3	2	1	5	5	5	5	7	20
7	3	1	2	3	4	5	5	5	9	19
8	2	3	1	2	5	5	4	4	8	18
9	1	2	3	1	5	5	4	4	7	18
10	3	2	1	3	5	5	4	4	9	18
11	2	1	3	2	4	5	5	4	8	18
12	1	3	2	1	5	5	5	4	7	19
13	3	1	2	3	5	5	4	4	9	18
14	2	3	1	2	5	5	5	5	8	20
15	1	2	3	1	5	5	5	5	7	20
16	3	2	1	3	5	5	4	4	9	18
17	2	1	3	2	4	5	5	4	8	18
18	1	3	2	1	5	5	4	5	7	19
19	3	1	2	3	4	5	5	5	9	19
20	3	1	2	3	4	5	5	5	9	19

Fuente: Elaboración propia

Leyenda:

- Pregunta_#: Valor obtenido en el número de pregunta, según corresponda (Pre-Test)
- Pre_Post_#: Valor obtenido en el número de pregunta, según corresponda (Pos-Test)
- T_Pre : Sumatoria de valores Pre Test
- T_Pos : Sumatoria de valores Pos Test

Figura 16

Resultados del Indicador: Tiempo de ordenar y a perfilar las imágenes digitalizadas

Muestra	Pregunta_13	Pregunta_14	Pregunta_15	Pregunta_16	Pre_Post_13	Pre_Post_14	Pre_Post_15	Pre_Post_16	T_Pre	T_Pos
1	3	1	2	3	5	5	5	5	9	20
2	1	2	3	1	5	5	4	4	7	18
3	2	3	1	2	4	5	5	5	8	19
4	3	2	3	1	5	5	4	4	9	18
5	1	3	2	2	5	5	5	4	8	19
6	2	1	3	3	5	5	5	5	9	20
7	3	2	1	2	4	5	5	5	8	19
8	1	3	2	1	5	5	4	4	7	18
9	2	1	3	3	5	5	5	4	9	19
10	3	3	1	2	5	5	4	4	9	18
11	1	2	2	3	4	5	5	4	8	18
12	2	3	3	1	4	5	5	4	9	18
13	3	1	1	2	5	5	4	4	7	18
14	1	2	2	3	5	5	5	5	8	20
15	2	3	3	1	5	5	5	5	9	20
16	3	1	2	2	5	5	4	4	8	18
17	1	2	3	3	5	5	5	4	9	19
18	2	3	1	1	4	5	4	5	7	18
19	3	2	3	2	4	5	5	5	10	19
20	3	2	3	2	4	5	5	5	10	19

Fuente: Elaboración propia

Leyenda:

- Pregunta_#: Valor obtenido en el número de pregunta, según corresponda (Pre-Test)
- Pre_Post_#: Valor obtenido en el número de pregunta, según corresponda (Pos-Test)
- T_Pre : Sumatoria de valores Pre Test
- T_Pos : Sumatoria de valores Pos Test

Figura 17*Resultados del Indicador: Tiempo de generación de pre-seleccionados*

Muestra	Pregunta_17	Pregunta_18	Pregunta_19	Pregunta_20	Pre_Post_17	Pre_Post_18	Pre_Post_19	Pre_Post_20	T_Pre	T_Pos
1	2	3	2	1	5	5	5	5	8	20
2	3	2	1	3	5	5	5	4	9	19
3	1	1	3	2	5	5	5	5	7	20
4	2	2	3	1	5	5	5	5	8	20
5	3	3	1	2	5	5	5	4	9	19
6	1	2	2	3	5	5	5	5	8	20
7	2	1	3	2	4	5	5	5	8	19
8	3	2	2	3	5	5	4	4	10	18
9	1	3	1	1	5	5	5	4	6	19
10	2	2	3	2	5	5	4	4	9	18
11	3	1	2	3	5	5	5	4	9	19
12	1	2	1	2	4	5	5	5	6	19
13	2	3	3	1	5	5	4	4	9	18
14	3	1	2	2	5	5	5	5	8	20
15	1	3	3	3	4	5	5	5	10	19
16	2	2	1	2	5	5	4	4	7	18
17	3	3	2	1	5	5	5	4	9	19
18	1	1	3	2	5	5	4	5	7	19
19	2	3	2	3	5	5	5	5	10	20
20	2	3	2	3	5	5	5	5	10	20


Fuente: Elaboración propia

Leyenda:

- Pregunta_#: Valor obtenido en el número de pregunta, según corresponda (Pre-Test)
- Pre_Post_#: Valor obtenido en el número de pregunta, según corresponda (Pos-Test)
- T_Pre : Sumatoria de valores Pre Test
- T_Pos : Sumatoria de valores Pos Test

Figura 18

Distribución de frecuencias del indicador dimensión satisfacción del Usuario con el proceso de Pos – test



Fuente: Elaboración propia

Nota. expresada en forma categórica donde el 100% del personal encuestado, se muestra satisfecho con el uso, la fiabilidad y confiabilidad del uso del modelo de redes neuronales para mejorar el proceso de aperfilamiento dentro del área de casting; Nadie muestra insatisfacción alguna

Anexo H. Prueba de normalidad

Tabla 20

Prueba de normalidad Shapiro Wilk

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TOTAL_PR	,378	20	,000	,668	20	,000
E						
TOTAL_PO	,264	20	,001	,659	20	,000
S						

a. Corrección de significación de Lilliefors

Nota. Dado que el valor de significancia (Sig.) es menor que 0.05 en ambos casos, se rechaza la hipótesis nula de normalidad. Esto significa que los datos de ambas variables no siguen una distribución normal según la prueba de Shapiro-Wilk.