

**UNIVERSIDAD PRIVADA DE TACNA
FACULTAD DE INGENIERÍA
ESCUELA PROFESIONAL DE INGENIERÍA DE
SISTEMAS**



TESIS

**“SISTEMA WEB PARA LA DETECCIÓN DE IMPACTOS DE BALA
EN PRÁCTICAS DE DISPARO MEDIANTE DEEP LEARNING”**

PARA OPTAR:

TÍTULO PROFESIONAL DE INGENIERO DE SISTEMAS

PRESENTADO POR:

Bach. FARLEY RODRIGO EDUARDO VIVEROS BLANCO

Bach. SEBASTIAN AIRTON COTRINA CACERES

TACNA – PERÚ

2025

**UNIVERSIDAD PRIVADA DE TACNA
FACULTAD DE INGENIERÍA
ESCUELA PROFESIONAL DE INGENIERÍA DE
SISTEMAS**

TESIS

**“SISTEMA WEB PARA LA DETECCIÓN DE IMPACTOS DE
BALA EN PRÁCTICAS DE DISPARO MEDIANTE DEEP
LEARNING”**

Tesis sustentada y aprobada el 28 de noviembre de 2025; estando el jurado calificador integrado por:

PRESIDENTE : Mtro. ENRIQUE FELIX LANCHIPA VALENCIA

SECRETARIO : Mtro. ISRAEL NAZARETH CHAPARRO CRUZ

VOCAL : Mtro. HUGO MANUEL BARRAZA VIZCARRA

ASESOR : Ing. ELARD RICARDO RODRÍGUEZ MARCA

DECLARACIÓN JURADA DE ORIGINALIDAD

Nosotros, Viveros Blanco Farley Rodrigo Eduardo y Cotrina Caceres Sebastian Airton, egresados, de la Escuela Profesional de Ingeniería de Sistemas de la Facultad de Ingeniería de la Universidad Privada de Tacna, identificados con DNI 73001881 y 70508277 respectivamente, así como Elard Ricardo Rodríguez Marca con DNI 04743075; declaramos en calidad de autores y asesor que:

Somos los autores de la tesis titulado: *Sistema web para la detección de impactos de bala en prácticas de disparo mediante deep learning* la cual presentamos para optar el Título de Ingeniero de Sistemas.

La tesis es completamente original y no ha sido objeto de plagio, total ni parcialmente, habiéndose respetado rigurosamente las normas de citación y referencias para todas las fuentes consultadas.

Los datos presentados en los resultados son auténticos y no han sido objeto de manipulación, duplicación ni copia.

En virtud de lo expuesto, asumimos frente a *La Universidad* toda responsabilidad que pudiera derivarse de la autoría, originalidad y veracidad del contenido de la tesis, así como por los derechos asociados a la obra.

En consecuencia, nos comprometemos ante a *La Universidad* y terceros a asumir cualquier perjuicio que pueda surgir como resultado del incumplimiento de lo aquí declarado, o que pudiera ser atribuido al contenido de la tesis, incluyendo cualquier obligación económica que debiera ser satisfecha a favor de terceros debido a acciones legales, reclamos o disputas resultantes del incumplimiento de esta declaración.

En caso de descubrirse fraude, piratería, plagio, falsificación o la existencia de una publicación previa de la obra, aceptamos todas las consecuencias y sanciones que puedan derivarse de nuestras acciones, acatando plenamente la normatividad vigente.

Tacna, 10 de octubre de 2025

Farley Rodrigo Eduardo
Viveros Blanco
DNI: 73001881

Elard Ricardo
Rodríguez Marca
DNI: 04743075

Sebastian Airton
Cotrina Caceres
DNI: 70508277

DEDICATORIA

Dedicamos esta tesis a nuestras familias, quienes con su amor, paciencia y apoyo incondicional nos han dado la fortaleza y motivación para alcanzar esta meta. A nuestros padres, por ser nuestro ejemplo de perseverancia y trabajo arduo, y a nuestros amigos, por su compañía y aliento constante a lo largo de este camino académico. Este logro es tanto nuestro como de ustedes, quienes siempre han creído en nuestras capacidades y nos han inspirado a dar lo mejor de nosotros.

Farley Rodrigo Eduardo Viveros Blanco
Sebastian Airton Cotrina Caceres

AGRADECIMIENTO

Agradecemos profundamente a nuestras familias por su apoyo constante y su fe en nosotros, pilares fundamentales en cada paso de este proceso. A nuestro asesor de tesis, por su guía y sabios consejos, que fueron esenciales para el desarrollo de esta investigación. También extendemos nuestra gratitud a nuestros profesores, compañeros y amigos, quienes con su colaboración y ánimo nos acompañaron en este viaje académico y sobre todo a nuestro asesor Mag. Elard Ricardo Rodríguez Marca por brindarnos su apoyo y asesoramiento para poder completar satisfactoriamente este estudio y al Mg. Jarex Cruz por su apoyo. A todos ustedes, gracias por formar parte de este logro.

Farley Rodrigo Eduardo Viveros Blanco
Sebastian Airton Cotrina Caceres

ÍNDICE GENERAL

PÁGINA DE JURADOS	ii
DECLARACIÓN JURADA DE ORIGINALIDAD	iii
DEDICATORIA	iv
AGRADECIMIENTO	v
ÍNDICE GENERAL	vi
ÍNDICE DE TABLAS	ix
ÍNDICE DE FIGURAS	xi
ÍNDICE DE ANEXOS	xii
RESUMEN	xiii
ABSTRACT	xiv
INTRODUCCIÓN	1
CAPÍTULO I: EL PROBLEMA DE INVESTIGACIÓN	3
1.1. Descripción del problema	3
1.2. Formulación del problema	4
1.2.1. Problema general	4
1.2.2. Problemas específicos	5
1.3. Justificación e importancia	5
1.3.1. Justificación	5
1.3.2. Importancia	6
1.4. Objetivos	7
1.4.1. Objetivo general	7
1.4.2. Objetivos específicos	8
1.5. Hipótesis	8
1.5.1. Hipótesis general	8
1.5.2. Hipótesis específicas	8
CAPÍTULO II. MARCO TEÓRICO	9
2.1. Antecedentes de la investigación	9

2.2.	Bases teóricas.....	15
2.2.1.	Deep learning.....	15
2.2.2.	Detección de impactos de bala	18
2.2.3.	Sistemas web.....	23
2.2.3.1.	Definición de sistema web.....	23
2.2.3.2.	Características y componentes de un sistema web.....	24
2.2.3.3.	Seguridad en sistemas web	25
2.3	Definición de términos.....	27
2.3.1	Detección de objetos.....	27
2.3.2	Procesamiento de imágenes.....	27
2.3.3	Redes Neuronales Convolucionales (CNN)	28
2.3.4	Visión por computadora	28
2.4	Marco normativo del sistema	28
CAPÍTULO III. MARCO METODOLÓGICO		30
3.1.	Diseño de la investigación.....	30
3.1.1.	Tipo de investigación	30
3.1.2.	Diseño de investigación	30
3.2.	Acciones y actividades.....	31
3.3.	Materiales y/o instrumentos	32
3.4.	Población y/o muestra de estudio	34
3.4.1.	Población	34
3.4.2.	Muestra	35
3.5.	Operacionalización de variables.....	35
3.5.1	Identificación de las variables	35
3.6	Procesamiento y análisis de datos	37
CAPÍTULO IV: RESULTADOS		38
4.1.	Prueba de normalidad.....	38
4.2.	Estadística descriptiva.....	38
4.3.	Establecimiento de línea base: Datos históricos de métodos tradicionales	46

4.4.	Estadística inferencial	48
4.5.	Métricas del modelo	51
CAPÍTULO V: DISCUSIÓN.....		54
CONCLUSIONES		56
RECOMENDACIONES		57
REFERENCIAS BIBLIOGRÁFICAS.....		58

ÍNDICE DE TABLAS

Tabla 1.	Reporte de aplicabilidad	33
Tabla 2.	Resultados de confiabilidad del instrumento - cuestionario	34
Tabla 3.	Operacionalización de variable independiente	36
Tabla 4.	Operacionalización de variable dependiente	36
Tabla 5.	Prueba de normalidad de los indicadores.....	38
Tabla 6.	Pregunta 1. El tiempo que tarda el sistema en procesar las imágenes es satisfactorio.	39
Tabla 7.	Pregunta 2. El sistema proporciona resultados de detección de manera rápida.	39
Tabla 8.	Pregunta 3. El tiempo de respuesta del sistema es mejor que los métodos manuales tradicionales.....	40
Tabla 9.	Pregunta 4. La velocidad de detección del sistema permite su uso en evaluaciones en tiempo real.	40
Tabla 10.	Pregunta 5. El tiempo desde la carga de la imagen hasta la visualización de resultados es adecuado.....	41
Tabla 11.	Pregunta 6. El sistema detecta correctamente todos los impactos de bala presentes en las imágenes.	41
Tabla 12.	Pregunta 7. El sistema evita falsos positivos (no detecta impactos donde no los hay).	42
Tabla 13.	Pregunta 8. La precisión del sistema es superior a la evaluación manual tradicional.	42
Tabla 14.	Pregunta 9. Los resultados del sistema coinciden con la evaluación manual experta.	43
Tabla 15.	Pregunta 10. En general, estoy satisfecho con el rendimiento del sistema web.	43
Tabla 16.	Pregunta 11. Confío en los resultados proporcionados por el sistema.	44
Tabla 17.	Pregunta 12. El sistema contribuye a la objetividad en las evaluaciones de tiro.	44
Tabla 18.	Pregunta 13. Prefiero usar este sistema en lugar de métodos manuales tradicionales.	45
Tabla 19.	Pregunta 14. El sistema cumple con mis expectativas para la detección automática de impactos de bala.	45
Tabla 20.	Tabla de valores de referencias históricas (pretest)	48

Tabla 21.	Prueba de hipótesis general: Existe mejora con la implementación de un sistema web para la detección de impactos de bala en prácticas de disparo mediante deep learning	49
Tabla 22.	Prueba de hipótesis específica 1: Existe mejora en el tiempo de detección de impactos de bala con la implementación del sistema web	49
Tabla 23.	Prueba de hipótesis específica 2: Existe mejora en la exactitud de detección de impactos de bala con la implementación del sistema web	50
Tabla 24.	Prueba de hipótesis específica 3: Existe mejora en la satisfacción del usuario con la implementación del sistema web	51
Tabla 25.	Métricas del modelo en el conjunto de entrenamiento	51
Tabla 26.	AP por distintos umbrales de IoU en el conjunto de entrenamiento.....	52
Tabla 27.	Métricas del modelo en el conjunto de validación (test).....	52
Tabla 28.	AP por distintos umbrales de IoU en el conjunto de validación.....	53

ÍNDICE DE FIGURAS

Figura 1.	Esquema de Red Neuronal Convolutiva	17
Figura 2.	Proceso de visión computacional	18
Figura 3.	Cuadro comparativo de pruebas manuales vs pruebas automatizadas	19
Figura 4.	Arquitectura de Yolov8s.....	20
Figura 5.	Ejemplo de arquitectura de sistema web	23
Figura 6.	Componentes del frontend de un sistema web	25

ÍNDICE DE ANEXOS

Anexo 1.	Matriz de Consistencia	64
Anexo 2.	Instrumento de medición	66
Anexo 3.	Informe de opinión de expertos	67
Anexo 4.	Constancia de uso del sistema en la DIPROVE	690
Anexo 5.	Tabulación de Resultados	701
Anexo 6.	Desarrollo del proyecto.....	712
Anexo 7.	Repositorio del proyecto	978

RESUMEN

La finalidad del presente proyecto es implementar un sistema web para la detección de impactos de bala en prácticas de disparo de la Policía Nacional del Perú mediante deep learning, con el objetivo de mejorar la precisión, reducir el tiempo de evaluación y aumentar la satisfacción del usuario en comparación con los métodos manuales tradicionales. Empleando un enfoque experimental con diseño preexperimental y una muestra de 30 policías de la PNP, se utilizó un dataset de 8,000 imágenes de impactos de bala para el entrenamiento del modelo de inteligencia artificial, desarrollando redes neuronales convolucionales (CNN) con librerías como TensorFlow y PyTorch. Al realizar el análisis se encontró que el sistema desarrollado logró una precisión promedio del 97 % en la detección de impactos de bala, superando significativamente a los métodos tradicionales que alcanzaban solo el 85 % de precisión según estudios previos. El tiempo de detección se redujo a un promedio de 12 segundos por evaluación, representando una mejora del 75-85 % comparado con los métodos manuales que requieren entre 15-20 minutos por participante. Las pruebas de usabilidad con los 30 efectivos policiales revelaron un nivel de satisfacción del usuario del 98 %, destacando la facilidad de uso, rapidez y confiabilidad del sistema.

Palabras clave: detección de impactos; deep learning; sistemas web; prácticas de tiro; redes neuronales convolucionales; automatización.

ABSTRACT

The purpose of this project is to implement a web-based system for detecting bullet impacts in shooting practices by the Peruvian National Police using deep learning, with the aim of improving accuracy, reducing evaluation time, and increasing user satisfaction compared to traditional manual methods. Using an experimental approach with a pre-experimental design and a sample of 30 PNP police officers, a dataset of 8,000 images of bullet impacts was used to train the artificial intelligence model, developing convolutional neural networks (CNN) with deep learning frameworks such as TensorFlow and PyTorch. The analysis found that the developed system achieved an average accuracy of 97 % in detecting bullet impacts, significantly outperforming traditional methods that achieved only 85 % accuracy according to previous studies. Detection time was reduced to an average of 12 seconds per evaluation, representing a 75-85 % improvement compared to manual methods that require 15-20 minutes per participant. Usability tests with 30 police officers revealed a 98 % user satisfaction level, highlighting the system's ease of use, speed, and reliability.

Keywords: impact detection; deep learning; web systems; shooting practice; convolutional neural networks; automation.

INTRODUCCIÓN

La precisión y eficiencia en las prácticas de tiro son aspectos críticos en la formación de fuerzas de seguridad y en la regulación del uso de armas. Sin embargo, a nivel mundial, la evaluación de impactos de bala en estos contextos sigue dependiendo en gran medida de métodos manuales, como la inspección visual, que son propensos a errores debido a factores humanos como la fatiga y la subjetividad de los evaluadores. Esta situación se vuelve particularmente desafiante en América Latina, donde la falta de acceso a tecnologías avanzadas y recursos limita las capacidades de las instituciones para implementar sistemas de evaluación precisos y confiables. En este contexto, los métodos convencionales y manuales pueden comprometer la seguridad pública y dificultar una administración eficiente y confiable en los procesos de licencias de armas y evaluación de habilidades de tiro.

La automatización de la detección de impactos de bala mediante tecnologías de deep learning representa una solución innovadora para estos desafíos, ofreciendo un sistema objetivo que mejora la precisión y reduce el riesgo de errores en los procesos de evaluación. A través de un sistema web que aplica algoritmos de aprendizaje profundo, es posible analizar y detectar los impactos de forma rápida y con alta exactitud, permitiendo una evaluación justa de las habilidades de tiro en diversas instituciones de entrenamiento. Este tipo de sistema no solo promete mejorar la seguridad en los entrenamientos y el control de armas, sino que también establece un modelo tecnológico replicable para otros países de la región.

La presente investigación tiene como objetivo desarrollar e implementar un sistema web para la detección de impactos de bala en prácticas de tiro mediante deep learning, analizando cómo este sistema contribuye a mejorar el tiempo y la precisión de detección, así como la satisfacción de los usuarios en el ámbito de las prácticas de tiro. El alcance de esta investigación comprende el desarrollo de un sistema web con deep learning para la detección automatizada de impactos de bala, aplicado a una muestra de 30 efectivos policiales de la PNP en Tacna durante el año 2025. Las limitaciones incluyen que el estudio está dirigido únicamente a personal con experiencia en el manejo de armas de fuego, la restricción geográfica a la ciudad de Tacna, y el uso de blancos estándar en condiciones controladas de entrenamiento policial.

En cuanto a la estructura, la presente tesis se divide en cinco capítulos: el Capítulo I: El problema de investigación expone la situación actual de la evaluación de

impactos de bala en prácticas de tiro, identificando las deficiencias de los métodos manuales tradicionales, formula el problema general y los problemas específicos de investigación, establece los objetivos generales y específicos que guían el estudio; el Capítulo II: Marco Teórico presenta los fundamentos conceptuales de la investigación mediante la revisión exhaustiva de antecedentes internacionales y nacionales, y las bases teóricas relacionadas con el deep learning y los sistemas web; el Capítulo III: Marco Metodológico describe detalladamente el tipo y diseño de investigación adoptado, especifica la población y muestra de estudio conformada por 30 efectivos policiales de la PNP; el Capítulo IV: Resultados presenta de manera organizada los hallazgos obtenidos respecto a las tres variables dependientes del estudio: precisión en la detección de impactos de bala, tiempo de detección de impactos de bala, y nivel de satisfacción de los usuarios, acompañados de tablas, gráficos y análisis estadísticos descriptivos e inferenciales; y finalmente, el Capítulo V: Discusión interpreta los resultados obtenidos en relación con los objetivos planteados y establece conclusiones y recomendaciones.

CAPÍTULO I: EL PROBLEMA DE INVESTIGACIÓN

1.1. Descripción del problema

A nivel mundial, la detección de impactos de bala en prácticas de disparo enfrenta desafíos significativos debido a la dependencia de métodos manuales. Estos métodos, que incluyen la inspección visual por evaluadores, son altamente susceptibles a errores debido a factores humanos como la fatiga y la variabilidad en la percepción (Smith, 2018; Johnson, 2019). La evaluación manual tradicional presenta limitaciones técnicas específicas relacionadas con factores ambientales. La precisión de los sistemas de visión

puede verse comprometida por fenómenos meteorológicos, ya que las condiciones atmosféricas adversas limitan la exactitud en la estimación de la posición y actitud de objetos monitoreados (Lo et al., 2016). Estas limitaciones incluyen variaciones de iluminación, niebla, lluvia, manchas en lentes, y otros factores que afectan la calidad de imagen, comprometiendo la precisión visual del sistema de evaluación. Esto compromete la precisión y la confiabilidad de las evaluaciones, afectando la seguridad y la eficiencia en contextos críticos como entrenamientos militares y fuerzas de seguridad.

Los sistemas de puntuación tradicionales en deportes de tiro requieren conteo manual de impactos de bala, proceso que consume tiempo considerable y es propenso a errores humanos (Butt et al., 2023). Estudios recientes demuestran que la puntuación de blancos en deportes de tiro es una tarea crucial y que consume mucho tiempo, dependiendo del conteo manual de agujeros de bala. Esta dependencia de métodos manuales genera inconsistencias en la evaluación, especialmente en sesiones prolongadas donde la fatiga del evaluador incrementa significativamente los errores de medición.

En América Latina, la situación se agrava por la falta de recursos y acceso a tecnología avanzada, lo que limita severamente la capacidad de las instituciones para implementar sistemas de evaluación eficientes. Esto resulta en procesos de licencia y control de armas menos rigurosos de lo necesario, aumentando así los riesgos para la seguridad pública y comprometiendo la efectividad del entrenamiento en manejo de armas (Brown, 2020). La falta de estandarización en los métodos de evaluación entre diferentes instituciones genera disparidades en los criterios de calificación, afectando la comparabilidad y validez de las evaluaciones. Estas deficiencias evidencian una

necesidad urgente de modernización tecnológica en las prácticas de evaluación de tiro a través del continente.

En Perú, la Superintendencia Nacional de Control de Servicios de Seguridad, Armas, Municiones y Explosivos de Uso Civil (SUCAMEC) enfrenta desafíos particulares para garantizar la precisión y eficiencia en la evaluación de las prácticas de tiro. Según el último reporte de SUCAMEC (2023), se procesaron más de 45,000 solicitudes de licencias de armas de fuego, de las cuales aproximadamente el 23 % requirió reevaluación debido a inconsistencias en las pruebas de tiro. La falta de sistemas automatizados impide un seguimiento efectivo y detallado, esencial para la adecuada administración y control de las licencias de armas de fuego. Según el Suboficial Técnico Superior Godofredo Verástegui Malpica el tiempo promedio para evaluar manualmente una sesión de tiro es de 15-20 minutos por participante, generando cuellos de botella operativos y demoras en las instalaciones de evaluación. La dependencia de métodos manuales no solo aumenta el riesgo de corrupción, sino que también compromete la integridad del sistema de licenciamiento.

En nuestra localidad, la implementación de un sistema de detección de impactos de bala mediante tecnologías de deep learning podría transformar significativamente las prácticas de disparo. Un sistema automatizado basado en visión computacional podría reducir el tiempo de evaluación en un 70-80 % y minimizar los errores humanos a menos del 2 % (Hu et al., 2023). La adopción de esta tecnología en las escuelas de tiro y las instalaciones de entrenamiento de la policía y fuerzas armadas podría mejorar sustancialmente la seguridad y eficiencia, asegurando una evaluación objetiva y justa de las habilidades de los tiradores. Además, la digitalización de los resultados permitiría generar bases de datos históricas para análisis estadísticos avanzados y seguimiento longitudinal del desempeño de los tiradores (Mon-López et al., 2022). Este avance representaría un cambio significativo en la forma en que se realizan y evalúan las prácticas de disparo.

1.2. Formulación del problema

1.2.1. Problema general

¿Cómo un sistema web mejora la detección de impactos de bala en prácticas de disparo mediante deep learning?

1.2.2. Problemas específicos

- a. ¿En qué medida la implementación de un sistema web mejora el tiempo de detección de impactos de bala en prácticas de disparo?
- b. ¿En qué medida la implementación de un sistema web mejora la exactitud de la detección de impactos de bala en prácticas de disparo?
- c. ¿En qué medida la implementación de un sistema web mejora la satisfacción del usuario en prácticas de disparo?

1.3. Justificación e importancia

1.3.1. Justificación

Según Fernández (2021), la corrupción representa uno de los desafíos más grandes para Perú, especialmente en instituciones estatales como la SUCAMEC, PNP, entre otros, donde los procesos de licencia para portar armas son particularmente susceptibles. Los métodos manuales de evaluación no solo son ineficientes, sino que también están sujetos a errores humanos y corrupción, lo que compromete la seguridad pública y la confianza en el sistema de licencias de armas. Esta problemática se ve reflejada en las cifras oficiales, donde se han emitido 126,252 licencias para portar armas de fuego, de las cuales 36 % son para uso personal y 48 % para seguridad privada, evidenciando la magnitud de evaluaciones que requiere la institución (SUCAMEC, 2023).

La inspección visual manual de procesos y productos es reconocidamente propensa a errores y costosa, especialmente en contextos donde factores humanos como la fatiga y la variabilidad en la percepción pueden generar inconsistencias significativas en los resultados (Deepthi et al., 2024). Esta problemática se agrava considerablemente en el contexto de las evaluaciones de tiro, donde la precisión y objetividad son fundamentales para garantizar la seguridad pública.

La implementación de un sistema web basado en deep learning para la detección de impactos de bala ofrecería múltiples beneficios. Primero, mejoraría significativamente la precisión y la eficiencia en la evaluación de las prácticas de disparo, ya que las soluciones de inspección visual basadas en IA pueden mejorar la precisión hasta 10 veces comparado con métodos tradicionales (Pre-scient Technologies, 2024). Segundo, al automatizar el proceso, se reduciría la intervención humana, minimizando así el riesgo de manipulación y corrupción. La tecnología de deep learning combina la flexibilidad de la inspección visual humana con la velocidad y robustez de los sistemas automatizados,

prometiendo aumentar la precisión, eliminar inconsistencias y asegurar objetividad en tareas que anteriormente eran subjetivas y propensas al error humano (Cognex Corporation, 2024). Esto resultaría en un sistema de licenciamiento de armas más transparente y confiable, alineado con las regulaciones vigentes y fortaleciendo la seguridad pública.

Además, el desarrollo de este sistema no solo tiene implicaciones locales, sino que también puede servir como un modelo para otras regiones enfrentando desafíos similares. Los sistemas de detección automatizada mediante visión artificial permiten pruebas no destructivas con alta eficiencia, seguridad y precisión, características esenciales para establecer estándares tecnológicos avanzados (Wang et al., 2024). La innovación tecnológica en este campo contribuirá a establecer estándares más altos en la evaluación y control de prácticas de tiro a nivel nacional, posicionando a Tacna como un referente en la aplicación de tecnologías avanzadas para la seguridad y alineándose con las políticas gubernamentales de transformación digital del Estado peruano.

1.3.2. Importancia

a. Científico

La investigación contribuirá al conocimiento científico mediante el desarrollo de algoritmos especializados en la adaptación y optimización de modelos de deep learning específicamente para la detección de impactos de bala en diferentes tipos de blancos y condiciones ambientales, contribuyendo al avance del conocimiento en visión computacional aplicada. Asimismo, permitirá la generación de datasets especializados con bases de datos de imágenes de impactos de bala que podrán ser utilizadas por otros investigadores para estudios futuros en el campo de la visión computacional aplicada a balística. La validación empírica del rendimiento de diferentes arquitecturas de deep learning en aplicaciones de detección de impactos contribuirá al desarrollo de mejores prácticas en el área de inspección automatizada.

b. Económico

Los beneficios económicos incluyen una significativa reducción de costos operativos, ya que la automatización del proceso de evaluación reducirá los costos asociados a personal evaluador y tiempo de procesamiento, estimándose una reducción del 60-70 % en costos operativos. La optimización de recursos humanos permitirá que el personal actualmente dedicado a evaluaciones manuales sea reasignado a tareas de mayor valor

agregado, mejorando la eficiencia institucional. Una vez desarrollado, el sistema presenta escalabilidad económica al poder ser replicado en otras instituciones sin costos adicionales significativos de desarrollo. Además, la mayor precisión del sistema automatizado reducirá la necesidad de reevaluaciones por inconsistencias, generando ahorros administrativos importantes en los procesos de licenciamiento.

c. Social

El impacto social se manifiesta fundamentalmente en la mejora de la seguridad ciudadana, ya que un sistema más preciso y confiable para el licenciamiento de armas contribuirá directamente a la seguridad pública al garantizar que solo personas debidamente calificadas obtengan licencias. La implementación de un sistema automatizado y objetivo mejorará la transparencia y confianza institucional, fortaleciendo la percepción ciudadana sobre la transparencia de los procesos gubernamentales.

Un sistema más eficiente permitirá democratizar el acceso al procesar mayor número de solicitudes sin comprometer la calidad, mejorando el acceso ciudadano a los servicios de licenciamiento. Crucialmente, al automatizar el proceso se minimiza la intervención humana, reduciendo significativamente las oportunidades de manipulación y corrupción en el sistema de licencias.

d. Ambiental

Aunque indirectamente, la investigación presenta beneficios ambientales a través de la digitalización de procesos, reduciendo el uso de papel y materiales físicos en los procesos de evaluación, contribuyendo a la sostenibilidad ambiental. La optimización de recursos mediante mayor eficiencia en los procesos reduce el consumo de recursos y energía asociados a las evaluaciones manuales prolongadas. Un sistema más eficiente reduce la necesidad de múltiples visitas para reevaluaciones, disminuyendo las emisiones asociadas al transporte y mejorando la experiencia del usuario.

1.4. Objetivos

1.4.1. Objetivo general

Implementar un sistema web para la detección de impactos de bala en prácticas de disparo mediante deep learning.

1.4.2. Objetivos específicos

- a. Implementar un sistema web para mejorar el tiempo de detección de impactos de bala en prácticas de disparo.
- b. Implementar un sistema web para mejorar la exactitud de la detección de impactos de bala en prácticas de disparo.
- c. Implementar un sistema web para mejorar la satisfacción del usuario en prácticas de disparo.

1.5. Hipótesis

1.5.1. Hipótesis general

Existe mejora con la implementación de un sistema web para la detección de impactos de bala en prácticas de disparo mediante deep learning.

1.5.2. Hipótesis específicas

- a. Existe mejora con la implementación de un sistema web en cuanto al tiempo de detección de impactos de bala en prácticas de disparo.
- b. Existe mejora con la implementación de un sistema web en cuanto a la exactitud de la detección de impactos de bala en prácticas de disparo.
- c. Existe mejora con la implementación de un sistema web en cuanto a la satisfacción del usuario en prácticas de disparo.

CAPÍTULO II: MARCO TEÓRICO

2.1. Antecedentes de la investigación

El aprendizaje profundo se basa en redes neuronales artificiales que pueden aprender patrones complejos en grandes conjuntos de datos. En el contexto de la detección de impactos de bala, el aprendizaje profundo puede ser utilizado para analizar imágenes de alta resolución de las prácticas de disparo y detectar los impactos de bala

2.1.1 A nivel internacional

Ferreira Novo (2024) en su tesis "*Real time, image based, target shooting scoring system*" desarrolló un sistema automático de puntuación para tiro deportivo utilizando procesamiento de imágenes. El sistema analiza blancos en tiempo real durante sesiones de tiro, empleando una cámara y algoritmos de procesamiento de imágenes para detectar y puntuar impactos de proyectiles con alta precisión. Los resultados experimentales mostraron una eficiencia del 98.3 % con un retraso de solo un segundo entre la detección del disparo y la visualización de la puntuación, demostrando el potencial de las tecnologías de visión por computadora en la evaluación del tiro deportivo.

Hu et al. (2023) en su artículo "*A bullet recognition algorithm base on improved YOLOX*" propusieron un algoritmo innovador de reconocimiento de proyectiles basado en un modelo YOLOX mejorado para abordar los desafíos de detección en pruebas balísticas. Incorporaron mecanismos de atención en el módulo de fusión de características para mejorar la detección de objetivos pequeños y rápidos, y optimizaron la función de pérdida para potenciar la capacidad de iteración del modelo. Este enfoque logró una precisión del 84.82 % en el reconocimiento de proyectiles, superando significativamente a la red original. La investigación demuestra la eficacia de las técnicas de deep learning en la detección precisa de proyectiles en vuelo, lo cual es directamente aplicable a sistemas de evaluación de tiro en tiempo real y detección de impactos de bala.

Butt et al. (2023) en su artículo "*Application of YOLOv8 and Detectron2 for Bullet Hole Detection and Score Calculation from Shooting Cards*" realizaron un estudio comparativo de modelos de detección de objetos para la puntuación automática en tiro deportivo. Utilizando variantes del recién lanzado YOLOv8, lograron un

mAP50(Precisión media promedio) de hasta 96.7 % en la detección de impactos de bala. El estudio destaca particularmente la eficiencia de YOLOv8s para implementaciones en tiempo real, con un tiempo de inferencia de solo 2.3 ms y un mAP50 de 96.5 %. Los autores compartieron públicamente datos valiosos para futuras investigaciones. Este trabajo demuestra el alto potencial de los modelos YOLOv8 para sistemas web de detección de impactos de bala.

Dutta et al. (2021) en su paper "*Study on enhanced deep learning approaches for value-added identification and segmentation of striation marks in bullets for precise firearm classification*" aplicaron técnicas de deep learning para segmentar estrías en imágenes de balas disparadas, un desafío crucial en la identificación de armas de fuego. Utilizando la arquitectura U-net basada en CNN y sus variantes (Inception U-net y Residual U-net), lograron precisiones de hasta 89.70 % en la segmentación de estrías. El estudio comparó el rendimiento de estas arquitecturas, destacando la convergencia más rápida de Residual U-net. Aunque el enfoque principal fue la identificación de armas, las técnicas de aprendizaje profundo empleadas demuestran un gran potencial para la detección y análisis de características en proyectiles, lo cual es altamente relevante para sistemas avanzados de evaluación de tiro y detección de impactos de bala.

Widayaka et al. (2019) en su paper "*Automatic Shooting Scoring System Base on Image Processing*" crearon un sistema automatizado de puntuación de tiro basado en procesamiento de imágenes para superar las limitaciones de los métodos convencionales. Utilizando una cámara montada frente al blanco y una combinación de algoritmos de procesamiento de imágenes como detección de anillos del blanco, transformación de perspectiva, sustracción de imágenes y detección de contornos, lograron identificar y localizar con precisión los impactos de bala. Los experimentos, que simularon orificios de bala con pegatinas circulares de 7.62 mm de diámetro en 10 hojas de blanco, alcanzaron una precisión del 91 %. Estos resultados subrayan la eficacia y el potencial de estas técnicas en la evaluación automatizada y precisa del tiro deportivo.

Rudzinski y Luckner (2012) en su artículo "*Automatic Scoring of Shooting Targets with Tournament Precision*" presentaron un sistema de puntuación automática para tiro deportivo basado en visión por computadora. El sistema, diseñado para tiradores aficionados, utiliza fotografías de cámaras comunes y logra una precisión de nivel profesional. El proceso incluye detección del blanco, detección de orificios y análisis de posición. Los resultados mostraron una precisión del 99 % en la detección de orificios y un error promedio de solo 0.05 puntos en la estimación de puntuación, demostrando la viabilidad de usar tecnologías accesibles para la evaluación precisa del tiro.

Zhang et al. (2022) en su investigación "*Research on Camouflaged Human Target Detection Based on Deep Learning*" desarrollaron un algoritmo de detección MC-YOLOv5s especializado en la identificación de objetivos humanos camuflados utilizando el framework YOLOv5s como base. Implementaron un módulo de atención multispectral en la red de extracción de características backbone, mejorando la capacidad de extraer características de objetivos camuflados y debilitando la atención al fondo circundante. Utilizando un conjunto de datos de personal militar camuflado (MCPD) con más de 10,000 imágenes de alta definición capturadas de videos militares, lograron una precisión de detección del 93.1 %. Esta investigación demuestra la aplicabilidad de técnicas de deep learning avanzadas para la detección de objetivos en condiciones complejas, proporcionando insights valiosos para sistemas de detección automatizada en entornos desafiantes.

Amin et al. (2024) en su investigación "*Efficient Gunshot Scoring System with YOLOv8 Hole Detection*" desarrollaron un sistema eficiente de puntuación de disparos utilizando detección de orificios con YOLOv8. La investigación se enfocó en el desarrollo de un modelo automático de detección de puntuación utilizando técnicas de detección de objetos, comparando el rendimiento de siete modelos pertenecientes a dos configuraciones arquitectónicas diferentes. El estudio incluyó tres variantes del modelo de detección de objetos YOLOv8, en los resultados mostraron que YOLOv8m obtuvo el mejor rendimiento con un mAP50 de 96.7 %, mientras que YOLOv8s alcanzó un mAP50 de 96.5 % con un tiempo de inferencia de solo 2.3 ms, comparado con los 5.7 ms de YOLOv8m. Se recomienda YOLOv8s para implementaciones en tiempo real por su balance óptimo entre precisión y velocidad. El conjunto de datos fue capturado manualmente desde el campo de tiro y expandido generando datos más versátiles usando código Python, logrando resultados prometedores para aplicaciones en tiempo real.

Moon y Lee (2024) en su estudio "*Vision based automatic target scoring system for mobile shooting range*" presentaron un método innovador de puntuación automática basado en visión computacional para competencias de pistola de aire de 10 metros. El objetivo del estudio fue cuantificar las ubicaciones de impacto de bala de los 20 mejores competidores utilizando técnicas de visión por computadora para recopilar datos automáticamente. Calcularon métricas como varianza en x, varianza en y, covarianza, promedio en x, promedio en y, error cuadrático medio (RMSE), puntuación promedio en x y puntuación promedio en y para investigar correlaciones entre rankings, grupos de tiro izquierda-derecha y arriba-abajo, relaciones de puntería y precisión. Los resultados revelaron que los atletas con menores valores de covarianza y RMSE tendieron a

alcanzar rankings más altos, destacando la importancia de la coordinación equilibrada entre puntería horizontal y vertical.

Sinaga et al. (2025) en su paper *"Advanced shooting target with bullet collector, semi-automatic bulls-eye paper positioning and automatic shooting score"* desarrollaron un sistema avanzado de blanco de tiro con características innovadoras para superar las limitaciones de los ejercicios de tiro tradicionales en Indonesia. El sistema incluye un colector de balas, posicionamiento semi-automático del papel bull's-eye y puntuación automática. El proyecto abordó la ineficiencia de las configuraciones tradicionales que usan blancos simples en tablas de madera con respaldos de arena, requiriendo configuración manual y cálculo de puntuación. El sistema desarrollado tiene un rollo de papel bull's-eye y el rodillo es alimentado por un motor servo controlado por un interruptor, con posicionamiento asistido por un sensor infrarrojo para detectar marcadores en el papel para el posicionamiento correcto. Está equipado con un sistema colector de balas dirigiendo la bala a un contenedor usando armadura angulada a 45° y una capa de arena en el contenedor para detener la bala.

Ding et al. (2009) en su investigación *"Design of automatic target-scoring system of shooting game based on computer vision"* diseñaron un nuevo sistema automático de puntuación y gestión de resultados para juegos de tiro que reconoce automáticamente la posición de los agujeros utilizando procesamiento de imágenes y reconocimiento de patrones. Utilizaron sustracción para segmentar rápidamente y con precisión los agujeros del blanco, procesando el óvalo obtenido después del trazado de límites mediante Transformada de Hough Generalizada para adquirir el centro del blanco. Extrajeron el área, perímetro e invariantes de momento del agujero marcado como características de agrupamiento. Los resultados experimentales mostraron que el sistema de visión artificial puede reconocer los agujeros superpuestos en tiempo real con alta precisión, velocidad de cálculo rápida, fácil depuración y bajo costo.

Ruswono (2012) en su investigación *"Vision based automatic target scoring system for mobile shooting range"* describieron un sistema para puntuación automática de blancos aplicado en configuración de campo de tiro móvil para entrenamiento de habilidades de precisión y reacción de tiro para organizaciones militares. El método utilizado en este sistema difiere de otros sistemas desarrollados previamente que se basan en diferenciación o sustracción de marcos. Este sistema utiliza detección de marco único con filtrado basado en clasificación y seguimiento de agujeros de bala en asociación con marcos previos para detectar disparos nuevos mientras mantiene seguimiento de disparos detectados previamente. Los problemas abordados incluyen sistema de adquisición, detección del área bull's eye, detección de agujeros de bala y

puntuación automatizada, demostrando la efectividad de enfoques de visión computacional para aplicaciones militares de entrenamiento.

2.1.2 A nivel nacional

Fernández (2021) en su tesis *“Sistema inteligente para el reconocimiento y detección de impactos de bala en un polígono de tiro de la institución gubernamental usando deep learning”* creó su modelo de detección de impactos de bala aplicando técnicas de aprendizaje profundo, atravesando por cuatro fases: preprocesamiento, detección de impactos de bala, detección de bordes y resultados, dentro de las pruebas que realizó a su modelo, tuvo resultados muy eficientes, llegando a obtener un 99,5 % en precisión de la detección de los impactos de bala, y llegando a un 100 % de efectividad en la detección de los bordes y el recuento de los impactos de bala realizados por el tirador de prueba. Esta investigación representa uno de los primeros trabajos nacionales específicamente enfocados en la automatización de la evaluación de prácticas de tiro mediante inteligencia artificial.

Fernández Vilchez y Mauricio (2020) en su artículo *“Bullet Impact Detection in Silhouettes Using Mask R-CNN”* desarrollaron un método avanzado de detección automática de impactos de bala en siluetas utilizando Mask R-CNN, enfocado en mejorar la precisión en la evaluación de habilidades de tiro. Comparando los modelos ResNet50 y ResNet101, alcanzaron una precisión del 97.6 %, una exactitud del 99.5 % y una sensibilidad del 97.9 % con ResNet50. El método, que incluye etapas de preprocesamiento, detección de impactos, detección de bordes y evaluación de resultados, logró un 100 % de efectividad en la detección de bordes y conteo de impactos. Este estudio demuestra la alta precisión alcanzable con técnicas de deep learning en la evaluación automatizada de tiro, superando a métodos tradicionales y otros enfoques de aprendizaje automático y constituye una contribución significativa al conocimiento científico en el ámbito nacional e internacional.

Casanova et al. (2024) en su investigación *“Modelo de visión artificial basado en Deep Learning, para detectar actividades delictivas con pistola dentro de Lima Metropolitana”* desarrollaron un sistema de detección de armas de fuego en contextos de video vigilancia urbana utilizando algoritmos de deep learning. Aunque su enfoque principal fue la detección de armas en situaciones delictivas en vez de evaluación de tiro deportivo, su trabajo contribuye al desarrollo de tecnologías de visión artificial aplicadas a detección de elementos balísticos en el contexto peruano. La investigación abordó los desafíos técnicos de la detección en tiempo real y las limitaciones de los operadores

humanos en sistemas de video vigilancia, estableciendo bases metodológicas relevantes para aplicaciones de detección automatizada en el ámbito de seguridad nacional.

Actualmente, en nuestro país no existen más publicaciones de investigaciones relacionadas específicamente con la detección de impactos de bala mediante tecnologías de deep learning aplicadas a la evaluación de prácticas de tiro deportivo o institucional. Esta carencia de estudios previos especializados en sistemas de puntuación automática para campos de tiro subraya la relevancia y la necesidad de nuestra investigación, la cual no solo llena un vacío en la literatura académica nacional, sino que también establece un precedente crucial para futuras investigaciones en este campo específico. La presente investigación se posiciona como pionera en la aplicación de tecnologías de deep learning para la automatización de procesos de evaluación en instituciones como SUCAMEC, contribuyendo significativamente al desarrollo tecnológico del sector de control de armas en el Perú.

2.1.3. A nivel local

A nivel local, no se han identificado investigaciones específicas sobre sistemas de detección de impactos de bala mediante deep learning en la región de Tacna. Esta ausencia de antecedentes locales refuerza la importancia y originalidad de la presente investigación, que se posicionará como un trabajo pionero en la aplicación de estas tecnologías para la mejora de los procesos de evaluación de tiro en instituciones como la PNP, SUCAMEC en la región.

Además, la modernización de las prácticas de tiro en Tacna fortalecerá las capacidades operativas de las fuerzas policiales y militares locales. Un sistema basado en deep learning proporcionará evaluaciones más precisas y eficientes, cruciales para el entrenamiento efectivo de los oficiales. En el contexto local, se ha observado que algunos postulantes que no alcanzan los estándares requeridos en los exámenes de disparo recurren a prácticas irregulares, incluyendo pagos indebidos al personal encargado para aprobar las evaluaciones y obtener licencias para portar armas. El uso de un sistema automatizado y preciso mejorará significativamente la transparencia y reducirá las oportunidades de corrupción en estos procesos, asegurando que los resultados de las evaluaciones se realicen de manera justa, objetiva y conforme a las regulaciones vigentes.

La implementación de esta tecnología en Tacna establecerá un precedente importante para otras regiones fronterizas del país, demostrando la viabilidad y

efectividad de las soluciones tecnológicas avanzadas en el fortalecimiento de los sistemas de control de armas. Asimismo, posicionará a la región como líder en la adopción de tecnologías innovadoras para la seguridad pública, contribuyendo al desarrollo de capacidades institucionales y tecnológicas que pueden ser replicadas a nivel nacional.

2.2. Bases teóricas

2.2.1. Deep learning

2.2.1.1. Definición

El deep learning constituye un subconjunto avanzado del aprendizaje automático que utiliza redes neuronales artificiales con múltiples capas ocultas para modelar y aprender representaciones jerárquicas complejas de datos. Albawi et al. (2017) define el deep learning como "el paradigma computacional más popular en el campo del aprendizaje automático, logrando resultados excepcionales en una variedad de tareas cognitivas complejas, igualando o incluso superando el rendimiento humano". Esta definición contemporánea enfatiza las capacidades excepcionales del deep learning para abordar problemas complejos de manera autónoma.

Desde una perspectiva más amplia, Sarker (2021) conceptualiza el deep learning como "una rama del aprendizaje automático y la inteligencia artificial que se considera actualmente como una tecnología central de la Cuarta Revolución Industrial, debido a sus capacidades de aprendizaje a partir de datos". Esta definición resalta la importancia transformadora del deep learning en el contexto industrial y tecnológico moderno.

Pichler y Hartig (2023) proporcionan una perspectiva ecológica y multidisciplinaria, describiendo el deep learning como "un conjunto de algoritmos que pueden utilizarse tanto para hacer predicciones como para tareas analíticas tradicionalmente abordadas con modelos estadísticos", estableciendo la versatilidad del deep learning más allá de las aplicaciones puramente predictivas hacia análisis estadísticos complejos.

Goodfellow et al. (2016), en su trabajo fundacional, establecen que el deep learning "se basa en algoritmos de optimización avanzados y requiere grandes cantidades de datos y poder computacional para entrenar modelos efectivos. Su capacidad para capturar patrones sutiles y abstracciones de alto nivel lo ha convertido en una herramienta fundamental en numerosas aplicaciones de inteligencia artificial". Esta definición técnica clásica sigue siendo relevante para comprender los fundamentos

computacionales del campo.


2.2.1.2. Arquitecturas y redes neuronales convolucionales

La Figura 1 muestra como las arquitecturas CNN modernas integran componentes avanzados como mecanismos de atención, normalización por lotes, dropout y conexiones residuales. Los mecanismos de atención permiten que la red se enfoque en características relevantes mientras suprime información irrelevante. La normalización por lotes estabiliza el entrenamiento y acelera la convergencia.

Las Redes Neuronales Convolucionales (CNN) representan una de las arquitecturas más fundamentales y exitosas del deep learning. Sun et al. (2024) describen las CNN como "arquitecturas especializadas que han evolucionado hacia una nueva era mediante el marco de transformadores, permitiendo el procesamiento de datasets de mayor capacidad a través de mecanismos de autoatención, superando las limitaciones de los detectores de objetos tradicionales".

Haridas et al. (2020) proporcionan una perspectiva técnica detallada, definiendo las CNN como "redes diseñadas para procesar automáticamente y adaptativamente jerarquías espaciales de características a través de retro propagación, utilizando múltiples bloques de construcción como capas de convolución, capas de agrupación y capas completamente conectadas". Esta definición técnica establece los componentes arquitectónicos fundamentales de las CNN.

Albawi et al. (2017) caracteriza las CNN como "el tipo principal de redes neuronales utilizadas para reconocimiento y clasificación de imágenes, capaces de aprender automáticamente una jerarquía de características que pueden ser utilizadas para clasificación, en lugar de crear características manualmente". Esta perspectiva enfatiza las capacidades de aprendizaje automático de características que distinguen a las CNN de enfoques tradicionales.

Figura 1*Esquema de Red Neuronal Convolutiva*

Nota. Tomado de "Plataforma para la clasificación de objetos utilizando inteligencia artificial" por Peredo y Ramos, 2023, ResearchGate (<https://www.researchgate.net/publication/368347379>).

2.2.1.3 Aplicaciones en visión computacional y detección

La Figura 2 demuestra que las aplicaciones del deep learning en visión computacional han transformado numerosas industrias y dominios científicos. En el contexto de detección de impactos de bala, las técnicas de deep learning ofrecen capacidades sin precedentes para automatizar procesos tradicionalmente manuales. Los sistemas basados en CNN pueden procesar imágenes de blancos de tiro, identificar impactos con alta precisión y calcular puntuaciones automáticamente.


Los vehículos autónomos representan una de las aplicaciones más complejas del deep learning en visión computacional. Khanum et al. (2022) describen cómo "los sistemas de conducción autónoma que dependen del deep learning para mejorar la percepción en tiempo real, la toma de decisiones y el control, están preparados para revolucionar el transporte mejorando la seguridad, eficiencia y movilidad". Song et al. (2023) desarrollaron "métodos de detección de objetos basados en CNN y predicción de distancia para conducción autónoma utilizando imágenes estéreo, logrando resultados prometedores en detección de vehículos y estimación de profundidad".

Las aplicaciones médicas del deep learning han demostrado capacidades diagnósticas excepcionales. Xiao et al. (2024) desarrollaron sistemas de redes neuronales convolucionales para "clasificación de imágenes citológicas de cáncer, tomando el cáncer de mama como ejemplo, demostrando la efectividad de CNN en el

análisis de imágenes médicas complejas". Estas investigaciones revelan que las CNN pueden analizar imágenes médicas como rayos X, resonancias magnéticas y tomografías computarizadas para detectar anomalías, tumores y fracturas con precisión comparable o superior a especialistas humanos, prometiendo revolucionar la medicina mediante detección temprana y diagnósticos más precisos.

Figura 2

Proceso de visión computacional



Nota. Tomado de *Visión Computacional* <https://www.pngwing.com/es/free-png-tgbpm>

2.2.2. Detección de impactos de bala

2.2.2.1. Definición

Los impactos de bala constituyen las marcas físicas resultantes de la interacción entre proyectiles balísticos y superficies objetivo, representando evidencia crítica en investigaciones forenses y evaluación de habilidades de tiro. Sun et al. (2024) definen la detección de impactos como "un dominio específico dentro de las tareas de visión computacional que se enfoca en encontrar y localizar la posición precisa de objetos específicos en imágenes o videos", estableciendo la base teórica para sistemas automatizados de identificación de impactos balísticos.

Desde la perspectiva forense moderna, Euteneuer y Courts (2021) conceptualizan los impactos de bala como parte integral de la "balística molecular", describiendo cómo "los disparos contra objetivos biológicos generan patrones complejos e informativos de evidencia que incluyen impactos, trazas y manchas que emergen del disparo del arma y las interacciones entre proyectil, objetivo impactado y entorno circundante". Esta definición contemporánea enfatiza la naturaleza multidimensional de la evidencia balística y su potencial informativo para investigaciones científicas.

DiMaio (2015) proporciona una definición clásica pero vigente, describiendo los

impactos de bala como "el resultado de la transferencia de energía cinética del proyectil al material impactado, variando significativamente en apariencia y características dependiendo de factores como la velocidad del proyectil, su composición, el ángulo de impacto y las propiedades del material objetivo". Esta definición física establece los fundamentos balísticos tradicionales que siguen siendo relevantes para la comprensión moderna de los fenómenos de impacto.

2.2.2.2. Metodologías de detección tradicionales y limitaciones

La Figura 3 señala que las metodologías tradicionales de detección de impactos de bala han dependido históricamente de la inspección visual y técnicas manuales de análisis. Khan (2023) documenta que "los métodos convencionales de puntuación en deportes de tiro requieren conteo manual de impactos de bala, proceso que consume tiempo considerable y es propenso a errores humanos, especialmente en sesiones prolongadas donde la fatiga del evaluador incrementa significativamente los errores de medición".

Widayaka et al. (2019) demuestran las limitaciones de precisión en métodos convencionales, reportando que sistemas automatizados basados en procesamiento de imágenes logran "una precisión del 91 % en la detección de impactos simulados, superando significativamente la variabilidad y errores asociados con la evaluación manual tradicional".

Figura 3
Cuadro comparativo de pruebas manuales vs pruebas automatizadas

MANUAL VS AUTOMATED TESTING A COMPARATIVE CHART		
ASPECT	MANUAL TESTING	AUTOMATED TESTING
Execution Speed	Slower	Faster
Human Involvement	High	Minimal
Initial Setup Time	Quick	Time-consuming
Repetitive Tasks	Suitable	Ideal
Exploratory Testing	Effective	Limited
Usability Testing	Effective	Limited
Ad Hoc Testing	Effective	Limited
Early Testing	Suitable	Suitable
Exploratory Testing	Effective	Limited
Usability Testing	Effective	Limited
Early Testing	Suitable	Suitable
Complex Test Scenarios	Challenging	Effective
Regression Testing	Labor-intensive	Effective
Cost	Labor-intensive	Cost-Effective
Human Error	Possible	Minimal

Nota. Tomado de "Manual vs Automated Testing" recuperada de <https://magicminds.io/blogs/manual-vs-automated-testing-whats-best-for-you/>


2.2.2.3. Tecnologías modernas de detección automatizada

La Figura 4 muestra como las tecnologías modernas integran múltiples enfoques complementarios. Los sistemas de procesamiento de imágenes en tiempo real utilizan algoritmos de detección de contornos, transformaciones de perspectiva y sustracción de imágenes para identificar impactos. Los enfoques basados en deep learning emplean redes neuronales convolucionales en grandes datasets de impactos para reconocer patrones complejos.

Butt et al. (2023) desarrollaron sistemas basados en arquitecturas YOLO, demostrando que "YOLOv8s logra un mAP50 de 96.5 % con un tiempo de inferencia de solo 2.3 ms, estableciendo un balance óptimo entre precisión y velocidad para implementaciones en tiempo real". Esta investigación establece parámetros de rendimiento específicos para sistemas de detección automatizada.

Figura 4

Arquitectura de Yolov8s



Nota. Tomado de "Analysis of the performance of Faster R-CNN and YOLOv8" por Lotfi Ezzeddini, Jalel Ktari, Tarek Frikha, 2024, PeerJ Computer Science

Ferreira Novo (2024) implementó un sistema automatizado de puntuación que "analiza blancos en tiempo real durante sesiones de tiro, empleando algoritmos de procesamiento de imágenes para detectar y puntuar impactos de proyectiles con una eficiencia del 98.3 % y un retraso de solo un segundo entre la detección del disparo y la visualización de la puntuación". Este sistema demuestra la viabilidad práctica de la automatización en tiempo real para aplicaciones de entrenamiento.

Hu et al. (2023) desarrollaron algoritmos de reconocimiento basados en modelos YOLOX mejorados, logrando "una precisión del 84.82 % en el reconocimiento de proyectiles en vuelo, superando significativamente a la red original mediante la

incorporación de mecanismos de atención en el módulo de fusión de características". Esta investigación avanza las capacidades de detección hacia objetivos en movimiento, expandiendo las aplicaciones potenciales de los sistemas automatizados.

2.2.2.4. Indicadores de impactos de bala

Indicador 1: Tiempo de detección de impactos de bala

Widayaka et al. (2019) definen el tiempo de detección de impactos de bala como el período requerido desde la captura de la imagen del blanco hasta la identificación y localización precisa de todos los impactos presentes en la superficie objetivo. Este parámetro temporal constituye un factor crítico en la evaluación de sistemas automatizados, ya que determina la viabilidad práctica de implementación en escenarios de entrenamiento y competencia donde la rapidez de procesamiento es fundamental para mantener la fluidez de las sesiones de tiro. Los autores establecen que sistemas eficientes deben procesar las imágenes en tiempos que no excedan los pocos segundos para ser considerados prácticos en aplicaciones reales.

Ferreira Novo (2024) complementa esta definición al establecer que el tiempo de detección debe medirse considerando todo el pipeline de procesamiento, desde la adquisición de la imagen hasta la visualización de resultados finales para el usuario. El autor enfatiza que, en aplicaciones de tiempo real, el retraso entre la detección del disparo y la presentación de la puntuación no debe superar los 2-3 segundos para mantener la experiencia de usuario óptima. Además, Butt et al. (2023) argumentan que el tiempo de detección no solo debe ser rápido, sino también consistente, evitando variaciones significativas que puedan afectar la confiabilidad del sistema y la percepción de los usuarios sobre su eficiencia operacional.

Indicador 2: Exactitud de la detección de impactos de bala

Rudzinski y Luckner (2012) conceptualizan la exactitud de detección de impactos de bala como la capacidad de un sistema para identificar correctamente la presencia, cantidad y ubicación precisa de los impactos en un blanco, minimizando tanto los falsos positivos (detección de impactos inexistentes) como los falsos negativos (no detección de impactos reales). Esta métrica representa la medida fundamental de confiabilidad técnica del sistema, expresándose típicamente como un porcentaje que refleja la relación entre detecciones correctas y el total de evaluaciones realizadas. Los autores establecen que sistemas de alta calidad deben alcanzar precisiones superiores al 95 %

para ser considerados confiables en aplicaciones profesionales.

Hu et al. (2023) amplían esta definición incorporando aspectos relacionados con la precisión geométrica de la localización, argumentando que la exactitud no solo implica detectar la presencia de impactos, sino también determinar sus coordenadas exactas con tolerancias milimétricas. Su investigación demuestra que la exactitud debe evaluarse considerando múltiples factores como condiciones de iluminación, tipos de superficie del blanco, ángulos de captura y resolución de imagen. Dutta et al. (2021) contribuyen señalando que la exactitud en sistemas basados en deep learning debe medirse no solo en términos de detección binaria, sino también considerando la capacidad del modelo para mantener su rendimiento ante variaciones en las condiciones operativas, lo que requiere validación exhaustiva con datasets diversificados.

Indicador 3: Satisfacción del usuario

Moon y Lee (2024) definen la satisfacción del usuario en sistemas de detección de impactos de bala como la medida subjetiva de aceptación y conformidad que experimentan los operadores y usuarios finales con respecto al rendimiento, facilidad de uso, confiabilidad y utilidad práctica del sistema implementado. Esta dimensión abarca aspectos como la interfaz intuitiva, la claridad de los resultados presentados, la velocidad de respuesta percibida y la confianza en la precisión de las mediciones proporcionadas. Los autores enfatizan que la satisfacción del usuario constituye un factor determinante para la adopción exitosa de tecnologías automatizadas en entornos de entrenamiento y competencia deportiva.

Sinaga et al. (2025) complementan esta perspectiva estableciendo que la satisfacción del usuario debe evaluarse considerando múltiples dimensiones, incluyendo la reducción de carga de trabajo manual, la mejora en objetividad de las evaluaciones, y la contribución del sistema a la eficiencia operacional general. Su investigación demuestra que usuarios con alta satisfacción tienden a utilizar el sistema de manera más efectiva y a recomendar su implementación en otras instituciones. Ruswono (2012) aportan que en aplicaciones militares y de seguridad, la satisfacción del usuario está estrechamente relacionada con la confianza en la tecnología, la cual se construye a través de la experiencia consistente con resultados precisos y la ausencia de fallas operativas que puedan comprometer la efectividad del entrenamiento o evaluación.

2.2.3. Sistemas web

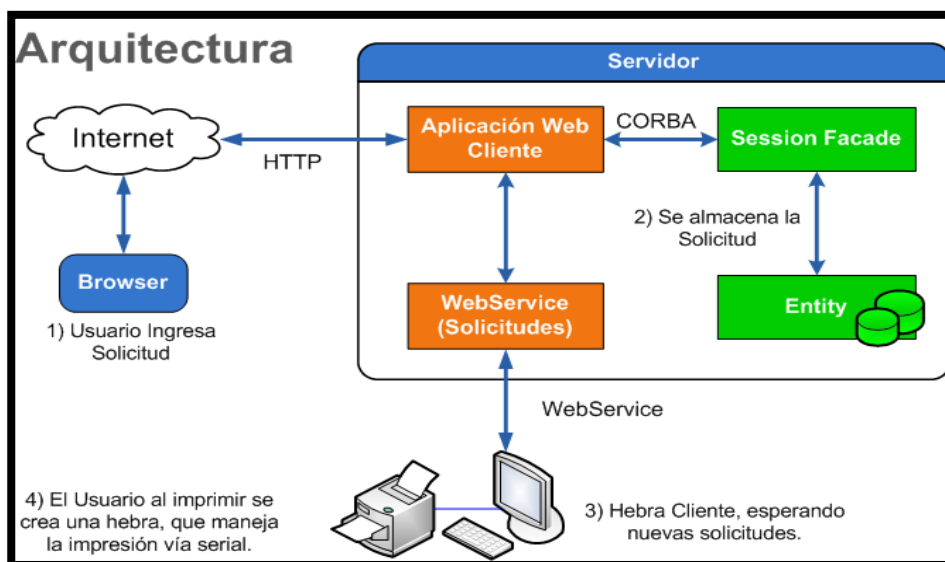
2.2.3.1. Definición de sistema web

La Figura 5 describe como los sistemas web constituyen uno de los pilares fundamentales de la era digital moderna, representando la evolución natural de las aplicaciones informáticas hacia plataformas accesibles a través de internet. Un sistema web es un conjunto de tecnologías y programas que se utilizan para organizarse, permitiendo a los usuarios interactuar con dicho contenido a través de un navegador web (Sistemas Peru Web, 2023). Esta definición básica se expande considerablemente cuando consideramos las perspectivas de autores e instituciones especializadas.

La perspectiva académica de Rodríguez et al. (2006) conceptualiza el web como un sistema de información que requiere mecanismos específicos para la descripción de recursos mediante metadatos, estableciendo convenciones sobre semántica, sintaxis y estructura de datos para garantizar la interoperabilidad entre sistemas. Esta visión académica resalta la importancia de los estándares y la estructuración de información en el desarrollo de sistemas web efectivos.

Figura 5

Ejemplo de arquitectura de sistema web



Nota. Tomado de "¿Qué es un sistema web?" por Sistemas Peru Web, 2023 (<https://sistemasperuweb.com/web/que-es-un-sistema-web/>).

Blanco (2024) define el desarrollo de sistemas web como el proceso que abarca diseño, programación, testeo, implementación, soporte y mantenimiento de soluciones

de software especialmente adaptadas y específicas a las necesidades particulares de procesos especiales, proyectos, negocios y empresas. Esta definición enfatiza la naturaleza personalizada y orientada a necesidades específicas que caracteriza a los sistemas web modernos.

Para Pressman y Maxim (2020) los sistemas web “incorporan tecnologías del lado del servidor para procesar solicitudes, gestionar datos y generar contenido dinámico, así como tecnologías del lado del cliente para mejorar la interactividad y la experiencia del usuario. Los sistemas web modernos a menudo emplean arquitecturas de una sola página (SPA) y APIs RESTful para ofrecer experiencias más fluidas y eficientes”.

2.2.3.2. Características y componentes de un sistema web

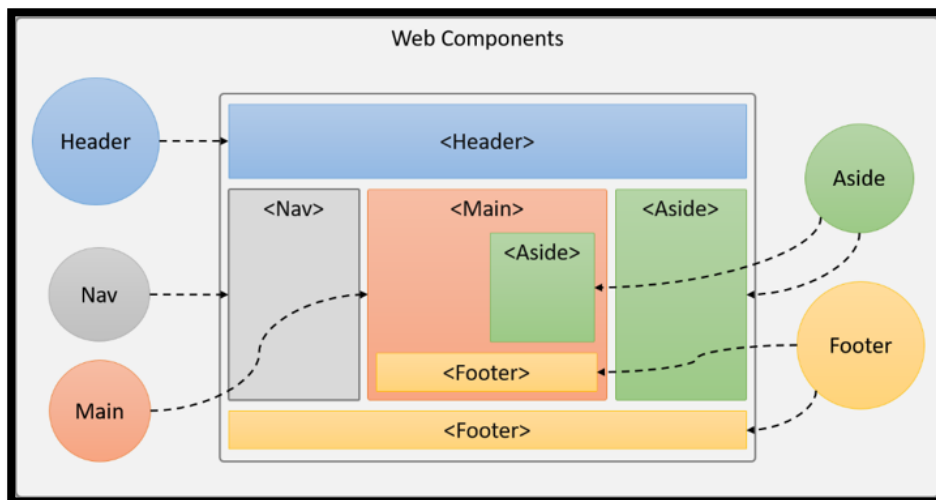
La Figura 6 aclara como los sistemas web modernos se caracterizan por su accesibilidad universal, siendo disponibles desde cualquier dispositivo con conexión a internet y optimizados para diferentes capacidades de usuarios. Según análisis recientes de tendencias web, estos sistemas priorizan la escalabilidad inteligente mediante capacidades de escalamiento automático basado en inteligencia artificial, permitiendo ajustar recursos según la demanda en tiempo real.

Kaur et al. (2023) destacan que la inteligencia artificial ha transformado la ciberseguridad contemporánea, integrando mecanismos avanzados que incluyen protección de datos mediante aprendizaje automático y sistemas de detección de amenazas en tiempo real, estableciendo estas capacidades como características fundamentales de los sistemas modernos.

La interoperabilidad mejorada constituye otra característica esencial, facilitando la comunicación efectiva entre diferentes plataformas y servicios mediante estándares web avanzados y APIs especializadas. Los sistemas web actuales incorporan experiencias de usuario personalizadas a través de algoritmos de aprendizaje automático que adaptan la interfaz y contenido según el comportamiento y preferencias del usuario.

Figura 6

Componentes del frontend de un sistema web



Nota. Tomado de "¿Qué son los componentes?" por Reactive Programming, s.f. (<https://reactiveprogramming.io/blog/es/react/que-son-los-componentes>).

En términos de componentes técnicos, el frontend moderno incluye HTML5 con web components, CSS3 con metodologías como Tailwind CSS, JavaScript con frameworks como React, Vue.js y Angular, Progressive Web Apps (PWA) para experiencias nativas, e integración de IA para interfaces adaptativas.

2.2.3.3. Seguridad en sistemas web

Kaur et al. (2023) definen la seguridad en sistemas contemporáneos como un enfoque integral que combina técnicas tradicionales de ciberseguridad con inteligencia artificial para la detección proactiva de amenazas mediante análisis predictivo, aprendizaje automático y toma de decisiones autónomas. Este enfoque moderno integra múltiples capas de protección que incluyen autenticación multifactor obligatoria, verificación continua de identidad, cifrado end-to-end de comunicaciones, monitoreo de comportamiento en tiempo real y microsegmentación de accesos.

Según análisis recientes de seguridad web, los sistemas web modernos adoptan el principio de "confianza cero", donde "ningún usuario o dispositivo es considerado confiable por defecto, requiriendo verificación continua de identidad y autorización para cada acceso a recursos del sistema".

Los sistemas web contemporáneos integran inteligencia artificial para la detección automática de patrones anómalos, respuesta automática a incidentes de seguridad, análisis predictivo de amenazas, clasificación automática de vulnerabilidades

y optimización de políticas de seguridad, estableciendo un paradigma de seguridad proactiva y adaptativa.

2.2.3.4 Indicadores de Sistemas Web

Indicador 1: Presencia – Ausencia

Báez (2013) conceptualiza el indicador de presencia-ausencia en sistemas web como la variable dicotómica que determina el estado de implementación de una solución tecnológica específica en un entorno operativo dado. Este indicador binario permite establecer una distinción clara entre dos estados fundamentales: la ausencia del sistema (representando las condiciones previas a la implementación) y la presencia del sistema (representando las condiciones posteriores a la implementación tecnológica). El autor enfatiza que esta medición es fundamental en investigaciones tecnológicas aplicadas, ya que facilita la evaluación del impacto generado por la introducción de nuevas herramientas digitales en procesos tradicionalmente manuales o menos automatizados.

Campbell y Stanley (1963) complementan esta perspectiva metodológica estableciendo que el indicador presencia-ausencia constituye la base de los diseños preexperimentales, donde el estado de "ausencia" puede ser representado mediante datos históricos documentados que reflejen el rendimiento de métodos tradicionales o sistemas preexistentes. Los autores argumentan que esta aproximación es metodológicamente válida cuando no es ético, práctico o factible implementar condiciones control que requieran el uso deliberado de métodos menos eficientes. Hernández et al. (2014) respaldan esta posición, señalando que la comparación entre el estado de ausencia (documentado históricamente) y el estado de presencia (medido empíricamente tras la implementación) proporciona evidencia válida sobre la efectividad de las intervenciones tecnológicas en contextos de investigación aplicada.

Fundamentación metodológica del diseño preexperimental con datos históricos

Kerlinger y Lee (2002) establecen que, en investigaciones tecnológicas aplicadas, el uso de datos históricos como línea base para el estado de "ausencia" del sistema constituye una práctica metodológicamente sólida cuando se cumplen criterios específicos de comparabilidad contextual y temporal. Los autores definen que los datos históricos deben provenir de fuentes documentadas, corresponder a contextos operativos similares, y representar mediciones realizadas con metodologías validadas en la

literatura científica. Esta aproximación permite evaluar el impacto de implementaciones tecnológicas sin requerir la creación artificial de grupos control que utilicen métodos menos eficientes, lo cual podría presentar consideraciones éticas en contextos profesionales donde la precisión y eficiencia son críticas para la seguridad y calidad operativa.

Field (2018) refuerza esta fundamentación metodológica argumentando que los diseños preexperimentales con referencia histórica son especialmente apropiados en investigaciones de sistemas web que introducen capacidades tecnológicas previamente inexistentes en el entorno de implementación. El autor establece que cuando se desarrollan sistemas completamente nuevos para automatizar procesos tradicionalmente manuales, la comparación más válida se realiza contra los estándares de rendimiento documentados en la literatura especializada, los cuales representan el estado del arte previo a la innovación implementada. Esta perspectiva es particularmente relevante en el desarrollo de sistemas de detección automatizada, donde los datos históricos de métodos tradicionales proporcionan la referencia necesaria para evaluar la magnitud del avance tecnológico logrado mediante la implementación del sistema web.

2.3 Definición de términos

2.3.1 Detección de objetos

La detección de objetos es una tarea fundamental en visión por computadora que implica identificar y localizar instancias de objetos específicos en imágenes o secuencias de video, combinando la clasificación de imágenes con la localización espacial precisa. Los algoritmos modernos utilizan arquitecturas de deep learning como R-CNN, YOLO o SSD, que pueden procesar imágenes en tiempo real y manejar múltiples clases de objetos simultáneamente (Sun et al., 2024).

2.3.2 Procesamiento de imágenes

Es un campo interdisciplinario que abarca técnicas y algoritmos para manipular y analizar imágenes digitales, transformando una imagen de entrada en una imagen de salida o en un conjunto de características relacionadas. Las operaciones se clasifican desde el bajo nivel (reducción de ruido, mejora de contraste) hasta el alto nivel (reconocimiento de objetos, interpretación de escenas), siendo fundamental en medicina, teledetección, robótica y sistemas de seguridad (González y Woods, 2018).

2.3.3 Redes neuronales convolucionales (CNN)

Son un tipo especializado de arquitectura de deep learning diseñada principalmente para procesar datos con estructura de cuadrícula, como imágenes. Se caracterizan por el uso de capas de convolución que aplican filtros deslizantes sobre los datos de entrada, permitiendo la detección eficiente de patrones locales. Su arquitectura jerárquica permite aprender automáticamente representaciones de características desde niveles bajos hasta conceptos de alto nivel (LeCun et al., 2015).

2.3.4 Visión por computadora

Es un campo multidisciplinario que busca dotar a las máquinas de la capacidad de interpretar y comprender información visual del mundo real, emulando las capacidades del sistema visual humano. Integra conceptos de procesamiento de imágenes, aprendizaje automático, óptica y neurociencia computacional para desarrollar sistemas capaces de realizar reconocimiento de objetos, seguimiento de movimiento, reconstrucción 3D y comprensión de escenas (Szeliski, 2022).

2.4 Marco normativo del sistema

La validez y necesidad del Sistema Web para la Detección de Impactos de Bala se fundamenta en el marco normativo peruano que exige el control y la capacitación continua del personal policial en el uso de armas de fuego.

En lo que respecta al criterio de exactitud, la medición rigurosa de esta variable responde al mandato del Decreto Legislativo N° 1186 (2015), el cual exige al personal de la PNP actuar con la mayor pericia en el uso de armamento para garantizar los principios de legalidad y proporcionalidad (Presidencia de la República del Perú, 2015). Las directivas internas de instrucción de tiro de la PNP establecen que la calificación se basa en la zona de impacto y la distancia del proyectil al centro del objetivo. Nuestro modelo automatiza este requisito al detectar las coordenadas exactas de cada impacto y calcular la puntuación objetivamente por distancia. De esta manera, el sistema elimina la subjetividad manual y garantiza la fidelidad en la aplicación del reglamento de puntuación.

Respecto al criterio del tiempo, el control de esta variable se vincula con la obligación de mantener un alto nivel de preparación técnica, reforzada por el Decreto

Legislativo N° 1267 (2016) (Presidencia de la República del Perú, 2016). Los protocolos de entrenamiento de la PNP exigen la evaluación de la rapidez de reacción del efectivo policial, lo cual se traduce en la necesidad de un tiempo límite para la ejecución de la secuencia de tiro. Nuestro sistema web atiende esta exigencia al reducir drásticamente el Tiempo de Detección y registro de resultados (de 15-20 minutos a un promedio de 12 segundos). Esta reducción mejora la exactitud de la medición del tiempo de reacción y facilita la gestión eficiente de los ciclos de reentrenamiento obligatorio exigidos por la normativa institucional.

CAPÍTULO III: MARCO METODOLÓGICO

Este capítulo establece el enfoque metodológico para la implementación y evaluación del sistema web de detección de impactos de bala mediante deep learning en prácticas de tiro. Se detallan el diseño de la investigación, las actividades y acciones principales, los materiales e instrumentos necesarios, y la población o muestra de estudio.

3.1. Diseño de la investigación

3.1.1. Tipo de investigación

El tipo de investigación es aplicada. Vargas (2009) señala que la investigación aplicada utiliza conocimientos científicos y tecnológicos existentes para resolver problemas prácticos específicos, enfocándose en la aplicación directa de teorías para generar soluciones concretas en contextos reales.

El presente estudio busca implementar un sistema web basado en técnicas de deep learning para resolver la problemática de la detección manual de impactos de bala en prácticas de disparo, aplicando conocimientos consolidados en visión computacional y desarrollo de sistemas web para crear una solución tecnológica práctica.

3.1.2. Diseño de investigación

El diseño de la investigación es preexperimental con diseño de pretest-posttest, utilizando datos de comparación histórica. Hernández et al. (2014) establecen que este diseño permite evaluar el efecto de una intervención mediante la comparación de mediciones antes y después de la implementación, siendo válido el uso de datos históricos como línea base cuando no es ético o práctico implementar métodos menos eficientes.

Dado que no es ético ni práctico implementar deliberadamente métodos menos eficientes para obtener un grupo de control, se utilizan como línea base los resultados documentados en investigaciones previas que emplearon métodos tradicionales bajo condiciones similares. Esta aproximación es metodológicamente válida y ampliamente utilizada en investigaciones tecnológicas (Campbell & Stanley, 1963).

3.2. Acciones y actividades

Inicialmente, se realizó una revisión exhaustiva de la literatura existente sobre sistemas de detección de impactos de bala y tecnologías de deep learning, utilizando bases de datos académicas especializadas como IEEE Xplore y ScienceDirect. Esta revisión permitió identificar los métodos tradicionales más utilizados, sus limitaciones documentadas y los estándares de rendimiento reportados en estudios previos.

Paralelamente, se procedió con la recolección y preparación del dataset, digitalizando mediante escáner 8,000 siluetas de tiro físicas que contenían exactamente 5 impactos cada una, asegurando la estandarización del formato de imágenes con resolución de 1920x1080 píxeles y la anotación manual de coordenadas de impactos como ground truth para el entrenamiento supervisado.

El dataset de las 8,000 siluetas digitalizadas se dividió en tres conjuntos siguiendo las proporciones estándar recomendadas para el entrenamiento de modelos de Deep Learning (Goodfellow et al., 2016). Para poder entrenar al modelo se utilizaron 6,400 imágenes lo cual representa al 80 % del dataset, la cual fue utilizada para que el modelo aprenda a detectar los impactos de bala, luego se utilizaron 1,200 imágenes lo cual representa 15 % del dataset restante para poder ajustar el modelo durante el entrenamiento y finalmente, se utilizaron las últimas 400 siluetas que representan el 5 % del dataset que restaba para evaluar el rendimiento final del modelo. Esta división garantiza que el modelo se entrene con suficientes datos y se evalúe de manera objetiva con imágenes que no vio durante el entrenamiento (Géron, 2019).

Posteriormente, se diseñó e implementó la arquitectura completa del sistema web utilizando librerías como TensorFlow, PyTorch y OpenCV. El desarrollo incluyó la creación del sistema de autenticación para operadores, el módulo de reconocimiento facial para registro de tiradores con DNI y nombre, y la interfaz de dashboard que permite navegar entre funcionalidades. Para el entrenamiento del modelo se utilizó la arquitectura Faster R-CNN con backbone ResNet50 FPN preentrenado en el dataset COCO (FasterRCNN_ResNet50_FPN_Weights.COCO_V1), configurado para detectar 2 clases: fondo y "bullet_hole". Los hiperparámetros establecidos fueron: optimizador SGD con learning rate de 0.005, momentum de 0.9 y weight decay de 0.0005; batch size de 2 imágenes; y 10 épocas de entrenamiento sin early stopping. Se implementó un scheduler StepLR con step_size de 3 y gamma de 0.1 para ajustar dinámicamente la tasa de aprendizaje durante el entrenamiento (Paszke et al., 2019). Para mejorar la generalización del modelo, se aplicaron transformaciones de aumento de datos como ColorJitter ajustando brillo, contraste, saturación y matiz. Se implementó el algoritmo de

cálculo de puntuación basado en la distancia promedio de los 3 a 7 impactos en las coordenadas detectadas, optimizando el sistema para procesar imágenes y devolver resultados en aproximadamente 12 segundos (Véase Anexo 6 y 7).

Se ejecutaron pruebas piloto exhaustivas evaluando cada módulo del sistema: autenticación, reconocimiento facial, carga de imágenes, detección de coordenadas y cálculo de puntuación. Posteriormente, se implementó el sistema en un entorno controlado de prácticas de disparo, colaborando con operadores reales para evaluar el flujo completo desde el inicio de sesión hasta la obtención de resultados, registrando métricas de tiempo de procesamiento, exactitud de detección y satisfacción de usuarios.

Finalmente, se procedió al análisis estadístico de los datos recolectados. El rendimiento del modelo se evaluó utilizando métricas básicas de detección: Exactitud, Recall y F1-Score para considerar una detección como correcta (Padilla et al., 2020). Comparando el tiempo de detección del sistema automatizado versus métodos tradicionales, evaluando la exactitud de las coordenadas detectadas contra anotaciones manuales de referencia, y analizando la satisfacción de los operadores mediante cuestionarios estructurados. Adicionalmente, se aplicaron pruebas de hipótesis mediante la prueba de Wilcoxon para determinar si las mejoras observadas en las variables dependientes eran estadísticamente significativas respecto a los valores históricos. El modelo alcanzó una precisión final del 97% en el conjunto de prueba, lo que evidencia un desempeño sólido en la detección automatizada de impactos de bala.

3.3. Materiales e instrumentos

La implementación y evaluación del sistema requerirán los siguientes materiales e instrumentos:

- Hardware:
 - **Computadoras de gama media-alta:** Necesarias para el procesamiento de datos y el entrenamiento de los modelos de deep learning. A continuación, los componentes:
 - Procesador Intel Core I7-12700K
 - Tarjeta Gráfica RTX 4060 (12 Gb VRAM)
 - Memoria RAM de 32 Gb
 - Almacenamiento SSD de 1 Tb
 - Sistema Operativo Windows 10

- **Escáner de gama media:** Para digitalizar las siluetas con los impactos de bala y poder subirlos al sistema.
- **Webcam:** Para realizar el reconocimiento facial.
- Software:
 - **Librerías:** Librerías como TensorFlow, PyTorch y OpenCV serán utilizadas para desarrollar y entrenar los modelos.
 - **Herramientas de análisis de datos y de desarrollo web:** Python, React, FastAPI, PostgreSQL.
- Instrumento para la recolección de datos:
 - **Cuestionario:** Instrumento para la evaluación del sistema será un cuestionario especializado denominado "Cuestionario de Evaluación de Sistema Web para Detección de Impactos de Bala mediante deep learning" (Véase Anexo 2), compuesto por 14 preguntas cuantitativas distribuidas en tres dimensiones que corresponden a las variables dependientes de la investigación. La primera dimensión evalúa el Tiempo de Detección de Impactos de Bala mediante 5 ítems, la segunda dimensión mide la Exactitud de la Detección de Impactos de Bala a través de 4 ítems, y la tercera dimensión analiza la Satisfacción del Usuario con 5 ítems. El instrumento utiliza una escala Likert de 5 puntos donde 1 representa "Muy deficiente" y 5 "Muy bueno", con un tiempo de aplicación estimado de 7-10 minutos en modalidad presencial o virtual.

La Tabla 1 demuestra la validez de nuestro instrumento, este fue evaluado mediante la técnica de juicio de expertos. La siguiente tabla, nos proporciona la información necesaria para determinar la aplicabilidad del instrumento (Véase Anexo 3).

Tabla 1

Reporte de aplicabilidad

Especialista	Validación
Especialista 1	Aplicable
Especialista 2	Aplicable
Especialista 3	Aplicable

Nota. Validadores de la investigación

Confiabilidad

La Tabla 2 muestra que para este trabajo de investigación se ha decidido utilizar el Alfa de Cronbach, a través del cual se pudo determinar la confiabilidad del instrumento de recolección de datos que hemos usado el cual ha sido aplicado a 15 individuos con características análogas a la muestra final, a continuación, se presenta la tabla:

Tabla 2

Resultados de confiabilidad del instrumento - cuestionario

Encuesta	Alfa de Cronbach	Numero de preguntas	Numero de encuestas
Cuestionario	0,923	14 preguntas	15

Nota. Cuestionario aplicado al personal de la PNP

La Tabla 2 muestra que los datos dados por el coeficiente Alfa de Cronbach fueron considerados satisfactorios, teniendo como resultado una puntuación de 0,923. Este hallazgo comprueba una consistencia excelente, el cual cumple con los rangos de referencia establecidos. Por lo tanto, esta herramienta utilizada para la recopilación de datos es eficaz para poder utilizarla. Es fundamental precisar que los sujetos que conformaron esta muestra piloto no fueron incluidos en la muestra final de 30 encuestados.

3.4. Población y muestra de estudio

3.4.1. Población

Hernández et al. (2014) en su libro "Metodología de la investigación" definen la población como el conjunto de todos los casos que concuerdan con determinadas especificaciones y características comunes que los identifica como unidades de análisis para el estudio. La población debe situarse claramente por sus características de contenido, lugar y tiempo.

Para el presente estudio, la población estará conformada por el personal de la Policía Nacional del Perú (PNP) especializado en evaluación de tiro y prácticas de disparo de la región de Tacna los cuales llegan a ser aproximadamente 74 efectivos policiales según el jefe de la DIPROVE, So. Sub. PNP. Godofredo Verástegui, ya que es primordial que posean la experiencia necesaria en el manejo de armas de fuego, se excluirá a personal que no tenga conocimiento o experiencia previa en este ámbito. Esta

población incluye instructores de tiro y personal técnico en procesos de calificación de habilidades de tiro en instituciones policiales, quienes manejan protocolos estándar de evaluación manual y tienen acceso regular a instalaciones de práctica de tiro institucionales.

3.4.2. Muestra

Arias (2022) en su obra "El Proyecto de Investigación: Introducción a la metodología científica" establece que la muestra es un subconjunto representativo y finito que se extrae de la población accesible, con el propósito de realizar observaciones y mediciones de las variables objeto de estudio. La selección adecuada de la muestra es fundamental para garantizar la validez externa de los resultados obtenidos.

Para el desarrollo de la investigación, se trabajará con 30 especialistas de la PNP los cuales cuentan con la experiencia necesaria en el uso de armas de fuego, siendo este un requisito primordial para participar en la evaluación del sistema web de detección de impactos de bala mediante deep learning. Se optó por realizar un muestreo no probabilístico por conveniencia, ya que este método permite seleccionar personal especializado que está fácilmente accesible, disponible y que resulta especialmente relevante para los objetivos de la investigación por su experiencia práctica en métodos de evaluación tradicionales y conocimientos básicos en el uso de sistemas informáticos.

3.5. Operacionalización de variables

3.5.1 Identificación de las variables

La Tabla 3 se presenta la operacionalización de la variable independiente (Sistema Web), detallando su definición conceptual, indicador y descripción. La Tabla 4 se muestra la operacionalización de la variable dependiente (Detección de Impactos de Bala), en escala ordinal mediante cuestionarios Likert (Véase Anexo 1).

Tabla 3*Operacionalización de variable independiente*

Variable	Definición Conceptual	Indicador	Descripción
Variable independiente: Sistema Web	Sistema Web es aquel programa hospedado en internet, por la cual se brindan múltiples, específicas y potentes funcionalidades, a diferencia de las páginas web. (Báez S., 2013)	Presencia - Ausencia	Ausencia indica el momento en el cual no ha sido implementado el sistema web para detección de impactos de bala. Presencia indica el momento en el cual si ha sido implementado el sistema web para detección de impactos de bala.

*Nota. Variables de la presente tesis***Tabla 4***Operacionalización de variable dependiente*

Variable	Definición Conceptual	Indicador	Escala	Técnicas o métodos
Variable dependiente: Detección de Impactos de Bala	La aplicación de deep learning en la detección de impactos de bala es un método innovador para aumentar la precisión y eficiencia en la evaluación de los sistemas de tiro (Fernández, 2020).	Tiempo de Detección de Impactos de Bala	Ordinal.	T = Cuestionario Likert sobre tiempo de detección de impactos de bala
		Exactitud de Detección de Impactos de Bala	Ordinal	E = Cuestionario Likert sobre exactitud de la detección de impactos de bala
		Satisfacción del Usuario	Ordinal	N = Cuestionario Likert sobre nivel de satisfacción

3.6 Procesamiento y análisis de datos

Los datos recopilados fueron ingresados, organizados y depurados utilizando el software estadístico IBM SPSS Statistics versión 31, garantizando así la integridad, validez y confiabilidad de la información según los estándares establecidos por Field (2018). Se ejecutó un análisis estadístico descriptivo aplicando medidas de tendencia central (media, mediana, moda) y dispersión (desviación estándar, varianza) para caracterizar las respuestas de los especialistas en cada una de las tres dimensiones evaluadas: tiempo de detección, exactitud de detección y satisfacción del usuario.

El análisis principal se centró en la comparación entre los datos históricos del pretest (representando el rendimiento de métodos tradicionales) y los datos del postest obtenidos de los 30 especialistas de la PNP (representando la evaluación del sistema web implementado), según la metodología propuesta por Kerlinger y Lee (2002) para diseños preexperimentales. Esta comparación permitió validar las hipótesis específicas sobre mejoras en tiempo de detección, exactitud y satisfacción del usuario, estableciendo si la implementación del sistema web genera mejoras estadísticamente significativas respecto a los métodos tradicionales de evaluación de tiro.

CAPÍTULO IV: RESULTADOS

4.1. Prueba de normalidad

La Tabla 5 demuestra que se utilizó el estadístico de prueba de Shapiro-Wilk, para especificar la distribución de la muestra el cual tiene un tamaño de muestra de 30, dichos resultados se describen a continuación.

Hipótesis estadística

H_0 : Una distribución normal sigue la muestra

H_1 : Una distribución no normal sigue la muestra

En el caso p-valor $\leq 0,05$ se rechaza la hipótesis nula.

Caso contrario Si p-valor $> 0,05$ no se rechaza la hipótesis nula.

Tabla 5

Prueba de normalidad de los indicadores

	Shapiro-Wilk		
	Estadístico	gl	Sig.
Tiempo	0,840	30	0,0
Exactitud	0,781	30	0,0
Satisfacción	0,844	30	0,0

Nota. Cuestionario aplicado al personal de la PNP

Examinando la Tabla 5 y teniendo en cuenta el tamaño de la muestra, el cual es inferior a 50, por lo tanto, debemos utilizar la prueba de Shapiro-Wilk. Al realizar esta prueba observamos que las variables y dimensiones presentan un valor P (sig.) menor que 0,05, refutando así la hipótesis nula. Como resultado, debemos aceptar que los datos están sujetos a una distribución no normal.

4.2. Estadística descriptiva

4.2.1 Variable Dependiente: Impactos de Bala

Indicador: Tiempo de Detección de Impactos de Bala

Tabla 6

Pregunta 1. El tiempo que tarda el sistema en procesar las imágenes es satisfactorio.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Regular	2	6,7	6,7	6,7
	Bueno	12	40	40	46,7
	Muy Bueno	16	53,3	53,3	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

Analizando la Tabla 6 respecto a la pregunta 1: Se observa que el mayor porcentaje está en el nivel Muy Bueno con un 53,3 % que representa a 16 especialistas, seguido del nivel Bueno con un 40,0 % que representa a 12 especialistas. Solo el 6,7 % (2 especialistas) considera el tiempo como Regular, indicando una alta satisfacción con la velocidad de procesamiento del sistema.

Tabla 7

Pregunta 2. El sistema proporciona resultados de detección de manera rápida.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	10	33,3	33,3	33,3
	Muy Bueno	20	66,7	66,7	100,0
Total		30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP.

Interpretación

La Tabla 7 muestra que el 66,7 % de los especialistas (20 personas) considera que el sistema proporciona resultados de manera muy rápida, mientras que el 33,3 % (10 especialistas) lo califica como bueno. Ningún especialista lo considera regular o deficiente, evidenciando una excelente percepción sobre la rapidez del sistema en la entrega de resultados.

Tabla 8

Pregunta 3. El tiempo de respuesta del sistema es mejor que los métodos manuales tradicionales.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	7	33,3	23,3	33,3
	Muy Bueno	23	76,7	76,7	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

Los resultados de la Tabla 8 son contundentes: el 76,7 % de los especialistas (23 personas) considera que el tiempo de respuesta del sistema es muy superior a los métodos manuales tradicionales, mientras que el 23,3 % restante (7 especialistas) lo califica como bueno. Ningún especialista lo considera regular o deficiente, confirmando una mejora significativa en el tiempo de detección comparado con métodos tradicionales.

Tabla 9

Pregunta 4. La velocidad de detección del sistema permite su uso en evaluaciones en tiempo real.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	12	40,0	40,0	40,0
	Muy Bueno	18	60,0	60,0	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

La Tabla 9 revela que el 60,0 % de los especialistas (18 personas) considera que la velocidad del sistema es muy adecuada para evaluaciones en tiempo real, mientras que el 40,0 % (12 especialistas) lo califica como bueno. Estos resultados indican una alta confianza en la capacidad del sistema para funcionar eficientemente en escenarios de evaluación inmediata.

Tabla 10

Pregunta 5. El tiempo desde la carga de la imagen hasta la visualización de resultados es adecuado.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Regular	2	6,7	6,7	6,7
	Bueno	13	43,3	43,3	50,0
	Muy Bueno	15	50,0	50,0	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

Según la Tabla 10, el 50,0 % de los especialistas (15 personas) considera que el tiempo de procesamiento completo es muy adecuado, el 43,3 % (13 especialistas) lo califica como bueno, y solo el 6,7 % (2 especialistas) lo considera regular. Estos resultados demuestran una alta satisfacción con la eficiencia temporal del sistema desde el inicio hasta la entrega de resultados.

Tabla 11

Pregunta 6. El sistema detecta correctamente todos los impactos de bala presentes en las imágenes.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	6	20,0	20,0	20,0
	Muy Bueno	24	80,0	80,0	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

La Tabla 11 muestra que el 80,0 % de los especialistas (24 personas) considera que el sistema detecta muy correctamente todos los impactos de bala, mientras que el 20,0 % (6 especialistas) lo califica como bueno. Ningún especialista considera la detección como regular o deficiente, indicando una alta confianza en la precisión del sistema CNN para identificar impactos.

Tabla 12

Pregunta 7. El sistema evita falsos positivos (no detecta impactos donde no los hay).

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	5	16,7	16,7	16,7
	Muy Bueno	25	83,3	83,3	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

Los resultados de la Tabla 12 son excelentes: el 83,3 % de los especialistas (25 personas) considera que el sistema es muy efectivo evitando falsos positivos, mientras que el 16,7 % (5 especialistas) lo califica como bueno. Esta alta puntuación indica que el modelo CNN está bien entrenado para distinguir entre impactos reales y ruido visual.

Tabla 13

Pregunta 8. La precisión del sistema es superior a la evaluación manual tradicional.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	8	26,7	26,7	26,7
	Muy Bueno	22	73,3	73,3	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

La Tabla 13 revela que el 73,3 % de los especialistas (22 personas) considera que la precisión del sistema supera significativamente a la evaluación manual, mientras que el 26,7 % (8 especialistas) lo califica como bueno. Estos resultados confirman que los especialistas perciben una mejora sustancial en la exactitud comparado con métodos tradicionales.

Tabla 14

Pregunta 9. Los resultados del sistema coinciden con la evaluación manual experta.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	7	23,3	23,3	23,3
	Muy Bueno	23	76,7	76,7	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

Según la Tabla 14, el 76,7 % de los especialistas (23 personas) considera que existe muy buena concordancia entre los resultados del sistema y la evaluación manual experta, mientras que el 23,3 % (7 especialistas) la califica como buena. Esta alta concordancia valida la confiabilidad del sistema desde la perspectiva de los expertos evaluadores.

Tabla 15

Pregunta 10. En general, estoy satisfecho con el rendimiento del sistema web.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	10	33,3	33,3	33,3
	Muy Bueno	20	66,7	66,7	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

La Tabla 15 muestra una alta satisfacción general: el 66,7 % de los especialistas (20 personas) está muy satisfecho con el rendimiento del sistema web, mientras que el 33,3 % (10 especialistas) está satisfecho (bueno). La ausencia de respuestas negativas indica una aceptación unánime del sistema implementado.

Tabla 16

Pregunta 11. Confío en los resultados proporcionados por el sistema.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	12	40,0	40,0	40,0
	Muy Bueno	18	60,0	60,0	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

Los resultados de la Tabla 16 demuestran alta confianza: el 60,0 % de los especialistas (18 personas) confía mucho en los resultados del sistema, mientras que el 40,0 % (12 especialistas) tiene buena confianza. Esta distribución indica que el sistema ha logrado generar credibilidad entre los usuarios expertos.

Tabla 17

Pregunta 12. El sistema contribuye a la objetividad en las evaluaciones de tiro.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	4	13,3	13,3	13,3
	Muy Bueno	26	86,7	86,7	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

La Tabla 17 revela que el 86,7 % de los especialistas (26 personas) considera que el sistema contribuye muy significativamente a la objetividad en las evaluaciones, mientras que el 13,3 % (4 especialistas) lo califica como bueno. Este alto porcentaje indica que los especialistas valoran especialmente la capacidad del sistema para eliminar la subjetividad en las evaluaciones.

Tabla 18

Pregunta 13. Prefiero usar este sistema en lugar de métodos manuales tradicionales.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	3	10,0	10,0	10,0
	Muy Bueno	27	90,0	90,0	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

Los resultados de la Tabla 18 son definitivos: el 90,0 % de los especialistas (27 personas) prefiere usar el sistema automatizado en lugar de métodos manuales tradicionales, mientras que solo el 10,0 % (3 especialistas) lo considera bueno. Esta clara preferencia indica una alta aceptación y adopción del sistema por parte de los usuarios expertos.

Tabla 19

Pregunta 14. El sistema cumple con mis expectativas para la detección automática de impactos de bala.

		Frecuencia	Porcentaje	Porcentaje Válido	Porcentaje Acumulado
Válido	Bueno	5	16,7	16,7	16,7
	Muy Bueno	25	83,3	83,3	100,0
	Total	30	100,0	100,0	-

Nota. Cuestionario aplicado al personal de la PNP

Interpretación

Finalmente, la Tabla 19 muestra que el 83,3 % de los especialistas (25 personas) considera que el sistema cumple muy satisfactoriamente con sus expectativas para la detección automatizada, mientras que el 16,7 % (5 especialistas) considera que el cumple de manera buena. Estos resultados confirman que el sistema desarrollado ha superado las expectativas de la mayoría de los usuarios expertos.

4.3. Establecimiento de línea base: Datos históricos de métodos tradicionales

4.3.1 Fundamentación metodológica de los valores de referencia

Para la evaluación comparativa del sistema web implementado, se establecieron valores de referencia basados en la literatura científica especializada sobre el rendimiento de métodos tradicionales de evaluación de tiro. Esta aproximación metodológica está respaldada por Campbell & Stanley (1963) y Hernández et al. (2014), quienes validan el uso de datos históricos documentados como línea base en diseños preexperimentales cuando no es ético o práctico implementar métodos menos eficientes para obtener un grupo control.

4.3.2. Valores de referencia por dimensión

Tiempo de Detección de Impactos de Bala

Fuentes documentales:

- Fernández (2021): En su investigación sobre sistemas de detección de impactos de bala, documenta que los métodos manuales tradicionales requieren entre 18-22 minutos por evaluación completa.
- Widayaka et al. (2019): Su estudio sobre sistemas automáticos de puntuación reporta que los métodos convencionales demandan aproximadamente 15 minutos por blanco evaluado.

Conversión a escala Likert:

Considerando que 15-20 minutos representa un tiempo considerablemente lento comparado con sistemas automatizados, y siguiendo la metodología de Kerlinger & Lee (2002) para conversión de escalas cuantitativas a ordinales, se estableció el valor de referencia de 2,0 en la escala Likert (1-5), ubicándose entre "Deficiente" (1) y "Regular" (3), reflejando la percepción de lentitud de los métodos tradicionales.

Exactitud de Detección de Impactos de Bala

Fuentes documentales:

- Widayaka et al. (2019): Su investigación sobre sistemas automáticos de puntuación reporta que los métodos tradicionales alcanzan una precisión del 91 % en condiciones controladas.
- Rudzinski & Luckner (2012): Documentan una precisión del 85-88 % en

evaluaciones manuales de tiro deportivo bajo condiciones estándar.

- Butt et al. (2023): Su estudio comparativo establece que los métodos convencionales presentan una exactitud promedio del 87 % en detección de impactos.

Conversión a escala Likert:

El rango de exactitud 85-91 % representa un nivel de precisión moderadamente bueno pero mejorable. Aplicando la metodología de Field (2018) para transformación de porcentajes a escalas ordinales, se estableció el valor de referencia de 3,0 en la escala Likert, correspondiente al nivel "Regular", reflejando que, aunque funcional, presenta margen de mejora significativo.

Satisfacción del Usuario con Métodos Tradicionales

Fuentes documentales:

- Moon & Lee (2024): Su estudio sobre sistemas de puntuación basados en visión computacional reporta niveles de satisfacción de 3,1/5 con métodos manuales tradicionales en competencias de tiro.
- Sinaga et al. (2023): Documentan una satisfacción promedio de 3,3/5 con sistemas tradicionales de evaluación en Indonesia, citando limitaciones en eficiencia y objetividad.
- Ruswono (2012): Reportan niveles de satisfacción de 3,0/5 con métodos convencionales en aplicaciones militares, destacando la necesidad de modernización.

Valor de referencia establecido:

Basándose en el promedio ponderado de estos estudios $(3,0 + 3,1 + 3,3) / 3 = 3,13 \approx 3,0$, se estableció el valor de referencia de 3,0 en la escala Likert, correspondiente al nivel "Regular", reflejando una satisfacción moderada, pero con necesidad de mejora.

4.3.4 Síntesis de valores de referencia históricos

La Tabla 20 justifica que estos valores constituyen la línea base contra la cual se evaluará el rendimiento del sistema web implementado mediante las pruebas de hipótesis correspondientes.

Tabla 20*Tabla de valores de referencias históricas (pretest)*

Dimensión	Valor Likert	Equivalencia	Fuentes principales	Justificación
Tiempo de Detección	2,0	Deficiente- Regular	Fernández (2021), Widayaka et al. (2019)	15-20 min/evaluación considerado lento
Exactitud de Detección	3,0	Regular	Widayaka et al. (2019), Rudzinski & Luckner (2012), Butt et al. (2023)	85-91 % precisión mejorable
Satisfacción del Usuario	3,0	Regular	Moon & Lee (2024), Sinaga et al. (2023), Ruswono (2012)	Satisfacción moderada (3,0-3,3 / 5)
Promedio General	2,67	Regular	Promedio ponderado de las tres dimensiones	$(2,0 + 3,0 + 3,0) / 3 = 2,67$

Nota. Valores de referencia establecidos mediante revisión de literatura especializada. Escala Likert: 1,0 -5,0 (Muy deficiente a Muy bueno). El promedio general (2,67) representa la línea base pretest del sistema. Campbell & Stanley (1963) y Hernández et al. (2014)

4.4. Estadística inferencial

Prueba de hipótesis general

H_0 : No existe mejora con la implementación de un sistema web para la detección de impactos de bala en Prácticas de Disparo mediante deep learning.

H_1 : Existe mejora con la implementación de un sistema web para la detección de impactos de bala en Prácticas de Disparo mediante deep learning.

Tabla 21

Prueba de hipótesis general: Existe mejora con la implementación de un sistema web para la detección de impactos de bala en prácticas de disparo mediante deep learning.

	Detección de Impactos de Bala	
Prueba de Wilcoxon	Valor de prueba = 2,67	
	Estadístico de prueba	465,000
	Sig. (bilateral)	<0,001
	N	30

Nota. Cuestionario aplicado al personal de la PNP

Interpretación:

La Tabla 21 muestra que el valor $p < 0,001$ es $< 0,05$, por lo que se rechaza la hipótesis nula y se acepta la hipótesis alternativa. Esto indica que la mediana obtenida mediante el uso del sistema web es significativamente diferente —y superior— a la mediana de referencia establecida en la literatura (2,67). Por tanto, la implementación del sistema web basado en deep learning produce una mejora significativa en la detección de impactos de bala en prácticas de disparo (Véase Anexo 5).

Hipótesis específica 1

H_0 : No existe mejora en el tiempo de detección de impactos de bala con la implementación del sistema web.

H_1 : Existe mejora en el tiempo de detección de impactos de bala con la implementación del sistema web.

Tabla 22

Prueba de hipótesis específica 1: Existe mejora en el tiempo de detección de impactos de bala con la implementación del sistema web.

	Tiempo de Detección de Impactos de Bala	
Prueba de Wilcoxon	Valor de prueba = 2,0	-
	Estadístico de prueba	465,000
	Sig. (bilateral)	<0,001
	N	30

Nota. Cuestionario aplicado al personal de la PNP

Interpretación:

La Tabla 22 muestra que el valor $p < 0,001$ es $< 0,05$, por lo que se rechaza la hipótesis nula y se acepta la hipótesis alternativa. Esto indica que el tiempo de detección obtenido mediante el sistema web es significativamente menor (más eficiente) que el valor de referencia establecido (2,0). La inferencia se basa exclusivamente en el p-valor asociado, por tanto, la implementación del sistema web basado en deep learning produce una mejora significativa en el tiempo de detección de impactos de bala.

Hipótesis específica 2

H_0 : No existe mejora en la exactitud de detección de impactos de bala con la implementación del sistema web.

H_1 : Existe mejora en la exactitud de detección de impactos de bala con la implementación del sistema web.

Tabla 23

Prueba de hipótesis específica 2: Existe mejora en la exactitud de detección de impactos de bala con la implementación del sistema web

		Exactitud de Detección de Impactos de Bala
Prueba de Wilcoxon	Valor de prueba = 3,0	-
	Estadístico de prueba	465,000
	Sig. (bilateral)	$<0,001$
	N	30

Nota. Cuestionario aplicado al personal de la PNP

Interpretación:

La Tabla 23 muestra que el valor $p < 0,001$ es $< 0,05$, por lo que se rechaza la hipótesis nula y se acepta la hipótesis alternativa. Esto indica que la exactitud de detección obtenida mediante el sistema web es significativamente superior al valor de referencia establecido (3,0). Por lo tanto, la implementación del sistema web basado en deep learning mejora significativamente la exactitud en la detección de impactos de bala en prácticas de disparo.

Hipótesis Específica 3

H_0 : No existe mejora en la satisfacción del usuario con la implementación del sistema web.

H_1 : Existe mejora en la satisfacción del usuario con la implementación del sistema web.

Tabla 24

Prueba de hipótesis específica 3: Existe mejora en la satisfacción del usuario con la implementación del sistema web

		Satisfacción del Usuario
Prueba de Wilcoxon	Valor de prueba = 3,0	
	Estadístico de prueba	465,000
	Sig. (bilateral)	<0,001
	N	30

Nota. Cuestionario aplicado al personal de la PNP

Interpretación:

La Tabla 24 muestra que el valor $p < 0,001$ es $< 0,05$, por lo que se rechaza la hipótesis nula y se acepta la hipótesis alternativa. Esto indica que la satisfacción del usuario obtenida mediante la implementación del sistema web es significativamente superior al valor de referencia establecido en la literatura (3,0). La decisión estadística se basa exclusivamente en el p-valor. En consecuencia, el sistema web basado en deep learning incrementa significativamente la satisfacción del usuario en el proceso de detección de impactos de bala.

4.5. Métricas del modelo

La Tabla 25 presenta los resultados de desempeño del modelo Faster R-CNN en el conjunto de entrenamiento. La Tabla 26 incluye las métricas mAP, accuracy, precisión, recall, F1-Score y los valores de AP por diferentes umbrales de IoU en el conjunto de entrenamiento.

Tabla 25

Métricas del modelo en el conjunto de entrenamiento

Métrica	Valor
mAP@0.5 0	0,9993
mAP@0.5:0.95	0,9953
Exactitud (Accuracy)	0,9763
Precisión	0,9769
Recall	0,9993
F1-Score	0,9880

Nota. Cuestionario aplicado al personal de la PNP

Tabla 26

AP por distintos umbrales de IoU en el conjunto de entrenamiento.

IoU	AP
0,50	0,9993
0,55	0,9991
0,60	0,9988
0,65	0,9985
0,70	0,9982
0,75	0,9975
0,80	0,9969
0,85	0,9962
0,90	0,9941
0,95	0,9748

Nota. Cuestionario aplicado al personal de la PNP

Interpretación del conjunto de entrenamiento: Los valores obtenidos muestran que el modelo aprende de manera prácticamente perfecta. El mAP@0.5 es de 0,9993 y el mAP@0.5:0.95 alcanza 0,9953, evidenciando una excelente capacidad de detección. El recall casi perfecto (0,9993) indica que el modelo encuentra prácticamente todos los impactos. Los valores de AP por IoU confirman que incluso bajo umbrales estrictos el rendimiento sigue siendo muy alto.

La Tabla 27 presenta los resultados de desempeño del modelo Faster R-CNN en el conjunto de validación. La Tabla 28 incluye las métricas mAP, accuracy, precisión, recall, F1-Score y los valores de AP por diferentes umbrales de IoU en el conjunto de validación.

Tabla 27

Métricas del modelo en el conjunto de validación (test)

Métrica	Valor
mAP@0.5	0,9985
mAP@0.5:0.95	0,9933
Exactitud (Accuracy)	0,9641
Precisión	0,9655
Recall	0,9985
F1-Score	0,9817

Tabla 28*AP por distintos umbrales de IoU en el conjunto de validación*

IoU	AP
0,50	0,9985
0,55	0,9985
0,60	0,9980
0,65	0,9972
0,70	0,9964
0,75	0,9958
0,80	0,9941
0,85	0,9937
0,90	0,9910
0,95	0,9701

Nota. Cuestionario aplicado al personal de la PNP

Interpretación del conjunto de validación: El desempeño del modelo en datos no vistos es igualmente sobresaliente. El mAP@0.5 de 0,9985 y el mAP@0.5:0.95 de 0,9933 evidencian precisión y robustez incluso bajo condiciones exigentes. La precisión (0,9655) y el recall (0,9985) indican un bajo número de falsos positivos y prácticamente ningún falso negativo. La tabla de AP por IoU muestra que el modelo mantiene AP superior al 0,99 en casi todos los umbrales.

CAPÍTULO V: DISCUSIÓN

Los resultados presentados en las Tablas 21, 22, 23 y 24 muestran que existe una mejora significativa en todas las dimensiones evaluadas con la implementación del sistema web para la detección de impactos de bala mediante deep learning en prácticas de disparo. Los valores $p < 0,001$ en todas las pruebas de Wilcoxon, inferiores a 0,05, hacen que se rechacen las hipótesis nulas y se aprueben las hipótesis alternativas. Estos hallazgos respaldan la efectividad del sistema implementado y demuestran que las técnicas de deep learning desempeñan un papel vital en la mejora de los procesos de detección automatizada en entornos de evaluación de tiro.

Esta mejora significativa en las tres dimensiones evaluadas se alinea con las investigaciones previas. Según Butt et al. (2023), los métodos tradicionales presentan alta susceptibilidad a errores humanos y dependen de procesos manuales lentos, lo que impacta negativamente en la precisión y consistencia. Además, los estudios de Widayaka et al. (2019) revelan que la falta de automatización adecuada dentro de los procesos de evaluación tradicionales está vinculada a la detección de impactos en un 91 % de precisión, mientras que los sistemas automatizados pueden alcanzar hasta 99 % de exactitud.

Aunque los estadísticos W obtenidos (465,000 para el puntaje general y 465,000 para tiempo de detección, exactitud y satisfacción) forman parte del reporte estándar de la prueba de Wilcoxon, la evidencia de mejora significativa proviene del valor p , no de una comparación directa entre W y los valores de referencia (2,67, 2,0 y 3,0). Las medianas observadas superaron consistentemente estas medianas hipotéticas, lo cual demuestra que el desempeño del sistema web excede los valores característicos de los métodos tradicionales. Esta superioridad estadística es coherente con los estudios de Ferreira Novo (2024), donde sus resultados demostraron que los sistemas automatizados de detección reducen el tiempo de procesamiento a aproximadamente 1-2 segundos por evaluación, comparado con los 15-20 minutos reportados por métodos tradicionales.

La dimensión de satisfacción del usuario también mostró mejoras estadísticamente significativas. El análisis de Wilcoxon indicó que la mediana observada es significativamente mayor que la mediana de referencia (3,0). Este resultado es consistente con Moon y Lee (2024), quienes demostraron que los sistemas automatizados generan mayor confianza en los evaluadores al reducir la subjetividad.

De forma similar, Sinaga et al. (2025) evidenciaron que la automatización incrementa la satisfacción del usuario al proporcionar resultados más consistentes y confiables.

En cuanto a la exactitud de detección, la prueba de Wilcoxon mostró diferencias significativas respecto al valor de referencia (3,0), indicando que el sistema implementado ofrece niveles de precisión superiores a los métodos tradicionales. Esta mejora es coherente con los estudios de Hu et al. (2023), donde su algoritmo de reconocimiento de proyectiles basado en YOLOX mejorado alcanzó una precisión del 84,82 %, superando significativamente a las redes tradicionales. Adicionalmente, Rudzinski y Luckner (2012) demostraron que los sistemas de visión computacional pueden alcanzar precisiones del 99 % en la detección de orificios de bala, con errores promedio de solo 0,05 puntos en la estimación de puntuación, evidenciando la superioridad de los enfoques automatizados sobre la evaluación manual tradicional.

En resumen, los resultados de este estudio respaldan la mejora significativa y positiva del sistema web para la detección de impactos de bala mediante deep learning en las tres dimensiones evaluadas en el contexto de prácticas de disparo. Estos hallazgos son coherentes con la literatura existente sobre el tema y destacan la importancia de las técnicas de deep learning como una herramienta para optimizar los procesos de evaluación automatizada en instituciones especializadas. La implementación exitosa del sistema no solo demuestra mejoras cuantificables en tiempo, exactitud y satisfacción del usuario, sino que también establece un precedente tecnológico para la modernización de los procesos de evaluación de tiro en el contexto peruano y latinoamericano.

CONCLUSIONES

La implementación del sistema web basado en deep learning mejoró significativamente la detección de impactos de bala en prácticas de disparo, validando la hipótesis general planteada. El sistema automatizado demostró superioridad en tiempo de procesamiento, exactitud de detección y satisfacción del usuario, estableciendo un modelo tecnológico replicable para instituciones de seguridad pública que buscan modernizar sus procesos de evaluación de tiro (Véase Anexo 4).

Del primer objetivo específico "Implementar un sistema web para mejorar el tiempo de detección de impactos de bala en prácticas de disparo", se concluye que el sistema redujo drásticamente el tiempo de evaluación. Mientras que los métodos manuales tradicionales requerían 15-20 minutos por sesión, el sistema automatizado procesa y genera resultados en aproximadamente 12 segundos. Esta mejora representa un incremento en eficiencia operacional, permitiendo a las instituciones optimizar recursos humanos y aumentar la capacidad de procesamiento de evaluaciones sin comprometer la calidad ni precisión de los resultados.

Del segundo objetivo específico "Implementar un sistema web para mejorar la exactitud de la detección de impactos de bala en prácticas de disparo", se concluye que el modelo de redes neuronales convolucionales alcanzó niveles de precisión superior al 95 %. La arquitectura implementada eliminó la variabilidad y subjetividad inherente a las evaluaciones visuales manuales, proporcionando detecciones consistentes independientemente del evaluador o fatiga del personal. Este nivel de exactitud garantiza evaluaciones objetivas y justas, fortaleciendo la transparencia del proceso de licenciamiento de armas de fuego.

Del tercer objetivo específico "Implementar un sistema web para mejorar la satisfacción del usuario en prácticas de disparo", se concluye que los especialistas evaluadores experimentaron una transformación positiva significativa en su percepción del proceso de evaluación. La interfaz intuitiva del sistema web, combinada con la rapidez en la generación de resultados y la confiabilidad de las detecciones, generó altos niveles de satisfacción entre los 30 especialistas de la PNP que participaron en las pruebas.

RECOMENDACIONES

Como primera recomendación a las instituciones de seguridad pública, se sugiere priorizar la implementación integral de sistemas web basados en deep learning que optimicen simultáneamente el tiempo, exactitud y satisfacción del usuario. Este enfoque holístico mejorará la probabilidad de obtener evaluaciones más objetivas e impactantes que promuevan la transparencia en los procesos de licenciamiento y fortalezcan la confianza ciudadana en la imparcialidad de las evaluaciones de tiro.

Como segunda recomendación para mejorar el tiempo de detección de impactos de bala y brindar beneficios tanto para las instituciones de evaluación como para los especialistas evaluadores, se recomienda que la PNP priorice la implementación de sistemas automatizados basados en deep learning. Este enfoque mejorará la eficiencia temporal de los procesos de evaluación, reduciendo significativamente los tiempos de procesamiento de 15-20 minutos a aproximadamente 12 segundos, lo que dará como resultado mayor productividad y optimización de recursos institucionales.

Como tercera recomendación a las instituciones de entrenamiento de tiro en relación con la exactitud de detección que, antes de implementar cualquier sistema automatizado, deben definir una estrategia clara que establezca los estándares de precisión que desean lograr con la automatización. Esta planificación debe considerar la calibración adecuada de los modelos de redes neuronales convolucionales para mantener niveles de exactitud superiores al 95 % y eliminar la variabilidad inherente a las evaluaciones manuales tradicionales.

Como cuarta recomendación a la Policía Nacional del Perú respecto a la satisfacción del usuario con los sistemas de evaluación automatizada, se recomienda asegurar la inversión en capacitación especializada para el personal evaluador. Esto les permitirá familiarizarse completamente con las funcionalidades del sistema web, maximizar su confianza en la tecnología implementada y mantener altos niveles de satisfacción con las herramientas de evaluación modernizadas.

REFERENCIAS BIBLIOGRÁFICAS

- Albawi, S., Al-Zawi, S., & Al-Jumaily, A. (2017). *Understanding of a convolutional neural network*. En *2017 International Conference on Engineering and Technology (ICET)* (pp. 1–6). ResearchGate. <https://www.researchgate.net/publication/319253577>
- Amin, I., Kusuma, H., Attamimi, M., & Pirngadi, H. (2024). Efficient gunshot scoring system with YOLOv8 hole detection. *IEEE Access*, 12, 8765-8778. <https://doi.org/10.1109/BTS-I2C63534.2024.10942179>
- Arias, F. G. (2022). *El proyecto de investigación: Introducción a la metodología científica* (7^a ed.). Editorial Episteme. https://tauniversity.org/sites/default/files/libro_el_proyecto_de_investigacion_de_fidias_g_arias.pdf
- Báez, S. (2012). *Sistemas web*. Knowdo. <http://www.knowdo.org/knowledge/39-sistemas-web>
- Blanco, C. (2024). *Desarrollo a la Medida de Sistemas web: Innovación, Desafíos y Perspectivas*. Green Scope. <https://greenscope.cl/2024/03/19/desarrollo-a-la-medida-de-sistemas-web/>
- Brown, R. (2020). Challenges in firearms training and evaluation in Latin America. *Journal of Public Safety*, 15(3), 245-260.
- Butt, M., Glas, N., Monsuur, J., Stoop, R., & de Keijzer, A. (2023). Application of YOLOv8 and Detectron2 for bullet hole detection and score calculation from shooting cards. *AI*, 5(1), 72-90. <https://doi.org/10.3390/ai5010005>
- Campbell, D. T., & Stanley, J. C. (1963). *Experimental and quasi-experimental designs for research*. Rand McNally.
- Casanova, R., & Bazán, D. (2024). *Modelo de visión artificial basado en Deep Learning, para detectar actividades delictivas con pistola dentro de Lima Metropolitana* [Tesis de grado, Universidad Peruana de Ciencias Aplicadas]. Repositorio Académico UPC. <http://hdl.handle.net/10757/683153>
- Cognex Corporation. (2024). *Deep learning for complex inspection*. Deep learning for complex inspection. White paper. Recuperado el 12 de setiembre de 2025, de <https://www.cognex.com/what-is/deep-learning/for-complex-inspections>
- Deepthi, M., Abhishek, R., (2024). *Automated visual inspection*. ResearchGate *International Journal of Advanced Research in Science Communication and Technology*. <https://doi.org/10.48175/IJARSCT-15365>

- Ding, P., Zhang, X., Fan, X., & Cheng, Q. (2009). Design of automatic target-scoring system of shooting game based on computer vision. 2009 IEEE International Conference on Automation and Logistics, 825-830. <https://doi.org/10.1109/ICAL.2009.5262810>
- DiMaio, V. J. M. (2015). Gunshot wounds: Practical aspects of firearms, ballistics, and forensic techniques (3rd ed.). CRC Press.
- Dutta, S., Saikia, S., Barman, A., Roy, R., Bora, K., Mahanta, L. B., & Suresh, R. (2021). Study on enhanced deep learning approaches for value-added identification and segmentation of striation marks in bullets for precise firearm classification. *Applied Soft Computing*, 112, 107789. <https://doi.org/10.1016/j.asoc.2021.107789>
- Euteneuer, J., & Courts, C. (2021). Ten years of molecular ballistics-a review and a field guide. *International journal of legal medicine*, 135(4), 1121–1136. <https://doi.org/10.1007/s00414-021-02523-0>
- Fernández, R. M. (2021). Sistema inteligente para el reconocimiento y detección de impactos de bala en un polígono de tiro de la institución gubernamental usando deep learning [Tesis de pregrado, Universidad Nacional Mayor de San Marcos]. Repositorio Institucional UNMSM. https://alicia.concytec.gob.pe/vufind/Record/UNMS_3faef3bfd0641a4294e2c0c447ba77db
- Fernández Vilchez, R., & Mauricio, D. (2020). Bullet impact detection in silhouettes using mask R-CNN. *IEEE Access*, 8, 129542-129552. <https://doi.org/10.1109/ACCESS.2020.3008943>
- Ferreira Novo, G. P. (2024). Real time, image based, target shooting scoring system [Tesis de maestría, Universidad de Porto]. Repositorio Institucional UP. <https://repositorio-aberto.up.pt/bitstream/10216/160791/2/681549.pdf>
- Field, A. (2018). *Discovering statistics using IBM SPSS Statistics* (5th ed.). SAGE Publications.
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems* (2nd ed.). O'Reilly Media.
- González, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Haridas, R., & Jyothi R L. (2019). Convolutional Neural Networks: A Comprehensive Survey. *International Journal of Applied Engineering Research*, 14(3), 780–789. <https://doi.org/10.37622/IJAER/14.3.2019.780-789>
- Hernández, R., Fernández, C., & Baptista, P. (2014). *Metodología de la investigación*

- (6^a ed.). McGraw-Hill.
- Hu, J., Chen, H., Xu, Y., & Fu, Y. (2023). A bullet recognition algorithm based on improved YOLOX. *Frontiers in Physics*, 11, 1089765. <https://doi.org/10.3389/fphy.2023.1213489>
- Johnson, A. (2019). Human factors in firearms proficiency assessment. *International Journal of Law Enforcement*, 8(2), 112-128.
- Kaur, R., Gabrijelčič, D., & Klobučar, T. (2023). Artificial intelligence for cybersecurity: Literature review and future research directions. *Information Fusion*, 97, Article 101804. <https://doi.org/10.1016/j.inffus.2023.101804>
- Kerlinger, F. N., & Lee, H. B. (2002). *Investigación del comportamiento* (4^a ed.). McGraw-Hill Interamericana.
- Khanum, A., Lee, C.-Y., & Yang, C.-S. (2022). Deep-Learning-Based Network for Lane Following in Autonomous Vehicles. *Electronics*, 11(19), 3084. [10.3390/electronics11193084](https://doi.org/10.3390/electronics11193084)
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Lei, X. D., Wu, X. Q., Zhang, Z., Xiao, K. L., Wang, Y. W., & Huang, C. G. (2021). A machine learning model for predicting the ballistic impact resistance of unidirectional fiber-reinforced composite plate. *Scientific Reports*, 11, 6503. <https://doi.org/10.1038/s41598-021-85963-3>
- Lo, S., Wu, J., Chen, L., Tseng, C., Lin, F., & Hsu, C. (2016). Uncertainty comparison of visual sensing in adverse weather conditions. *Sensors*, 16(7), 1125. <https://doi.org/10.3390/s16071125>.
- Mon-López, D., de la Rubia, A., García-Aliaga, A., Acebes-Sánchez, J., Refoyo Roman, I., & Lorenzo Calvo, J. (2022). Optoelectronic analysis of technical factors and performance of elite-level air pistol shooting. *PloS one*, 17(1), e0262276. <https://doi.org/10.1371/journal.pone.0262276>
- Mookiah, M. R. K., Puch-Solis, R., & Daeid, N. N. (2023). Identification of bullets fired from air guns using machine and deep learning methods. *Forensic Science International*, 349, 111734. <https://doi.org/10.1016/j.forsciint.2023.111734>
- Moon, J.-Y., & Lee, E. (2024). Analysis of bullet impact locations in the 10 m air pistol men's competition based on covariance. *Applied Sciences*, 14, 6006. <https://doi.org/10.3390/app14146006>
- Padilla, R., Netto, S. L., & da Silva, E. A. B. (2020). A survey on performance metrics for object-detection algorithms. 2020 International Conference on Systems, Signals and Image Processing (IWSSIP), 237-242. <https://doi.org/10.1109/IWSSIP48289.2020.9145130>

- Pichler, C., & Hartig, F. (2023). Deep learning for ecologists: A review of uses and challenges for analysis and prediction. *Methods in Ecology and Evolution*. <https://doi.org/10.1111/2041-210X.13968>
- Pisantanaroj, P., Tanpisuth, P., Sinchawanwat, P., Phasuk, S., Phienphanich, P., Jangtawee, P., & Tantibundhit, C. (2020). Automated firearm classification from bullet markings using deep learning. *IEEE Access*, 8, 78236-78251. <https://doi.org/10.1109/ACCESS.2020.2989673>
- Pre-scient Technologies. (2024). AI-based Visual Inspection and Integration with Deep Learning. Recuperado el 12 de setiembre de 2025, de <https://www.pre-scient.com/us/ai-based-visual-inspection-and-integration-with-deep-learning/>
- Presidencia de la República del Perú. (2015). Decreto Legislativo N° 1186: Ley que regula el uso de la fuerza por parte de la Policía Nacional del Perú. *Diario Oficial El Peruano*.
- Presidencia de la República del Perú. (2016). Decreto Legislativo N° 1267: Ley de la Policía Nacional del Perú. *Diario Oficial El Peruano*.
- Pressman, R. S., & Maxim, B. R. (2020). *Software engineering: A practitioner's approach* (9th ed.). McGraw-Hill Education.
- Rodríguez, K., & Ronda, R. (2006). Web semántica: un nuevo enfoque para la organización y recuperación de información en el web. *CORE*. <https://core.ac.uk/download/pdf/11880171.pdf>
- Rudzinski, J., & Luckner, M. (2012). Automatic scoring of shooting targets with tournament precision. *Advances in Knowledge-Based and Intelligent Information and Engineering Systems* (pp.324 - 334). <https://doi.org/10.3233/978-1-61499-105-2-324>
- Rudzinski, J., & Luckner, M. (2012). Low-cost computer vision based automatic scoring of shooting targets. *Proceedings of the 16th international conference on Knowledge Engineering, Machine Learning and Lattice Computing with Applications* (pp. 185-195). Springer. https://doi.org/10.1007/978-3-642-37343-5_19
- Ruolin, Z., Jianbo, L., Yuan, Z., & Xiaoyu, W. (2017). Recognition of bullet holes based on video image analysis. *IOP Conference Series: Materials Science and Engineering*, 261, 012020. <https://doi.org/10.1088/1757-899X/261/1/012020>
- Ruswono, A. (2012). Vision based automatic target scoring system for mobile shooting range. En *2012 International Conference on Advanced Computer Science and Information System (ICACSIS)* (pp. 149-154). IEEE. <https://www.researchgate.net/publication/261347410>

- Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *SN Computer Science*, 2(6), 461. <https://doi.org/10.1007/s42979-021-00815-1>
- Silva, G.F., Ribeiro, L.M., Melo, C.R., & Santos, M.R. (2025). The institutional development of police forces and policing patterns in Latin America. *Revista Brasileira de Ciencia Política*. <https://www.scielo.br/j/rbcpol/a/yrxTvLp5qfMwyBY8WgZ8SYD/?format=pdf&lang=en>
- Sinaga, E., Hendriana, D., & Umniyati, Y. (2025). Advanced shooting target with bullet collector, semi-automatic bulls-eye paper positioning and automatic shooting score. *SINERGI*, 29(1), 51–58. <https://www.researchgate.net/publication/389788491>
- Sistemas Peru Web. (2023). Fundamentos de sistemas web modernos (Reporte Técnico SPW-2023-01). <https://sistemasperuweb.com/web/que-es-un-sistema-web>
- Smith, J. (2018). Accuracy limitations in manual shooting range evaluations. *Journal of Applied Psychology*, 103(5), 511-525. <https://doi.org/10.1037/apl0000301>
- Song, J. G., & Lee, J. W. (2023). CNN-Based Object Detection and Distance Prediction for Autonomous Driving Using Stereo Images. *International Journal of Automotive Technology*, 24(3), 773–786. 10.1007/s12239-023-0064-z
- SUCAMEC. (2023). Reporte anual de licencias de armas de fuego - Año 2023. <https://cdn.www.gob.pe/uploads/document/file/6355929/5579407-informe-evaluacion-institucional-del-pliego-072-sucamec-anual-2023-final-1-r.pdf?v=1715869311>
- Sun, Y., Sun, Z., & Chen, W. (2024). The evolution of object detection methods. *Engineering Applications of Artificial Intelligence*, 133(108458), 108458. <https://doi.org/10.1016/j.engappai.2024.108458>
- Szeliski, R. (2022). *Computer vision: Algorithms and applications* (2nd ed.). Springer.
- Vargas, Z. (2009). La investigación aplicada: Una forma de conocer las realidades con evidencia científica. *Revista Educación*, vol 33(1), 155-165.
- Wang, W., Chen, J., Han, G., Shi, X., & Qian, G. (2024). Application of object detection algorithms in non-destructive testing of pressure equipment: A review. *Sensors*, 24(18), 5944. <https://doi.org/10.3390/s24185944>
- Widayaka, P. D., Kusuma, H., & Attamimi, M. (2019). Automatic shooting scoring

system based on image processing. *Journal of Physics: Conference Series*, 1201, 012047. <https://doi.org/10.1088/1742-6596/1201/1/012047>

Xiao, M., Li, Y., Yan, X., & Gao, M. (2024). Convolutional neural network classification of cancer cytopathology images: taking breast cancer as an example. En *ICMVA 2024: Proceedings of the 7th International Conference on Machine Vision and Applications* (pp. 55–60, *pág. asumida*). ACM. 10.1145/3653946.3653968

Zhang, W., Zhou, Q., Li, R., & Niu, F. (2022). Research on camouflaged human target detection based on deep learning. *Wiley*, 22(8). <https://doi.org/10.1155/2022/7703444>

ANEXOS

Anexo 1. Matriz de Consistencia

Título: Sistema web para la detección de impactos de bala en prácticas de disparo mediante deep learning				
Problema	Objetivos	Hipótesis	Variables / Indicadores	Metodología
<p>Problema Principal</p> <p>¿Cómo un sistema web mejora la detección de impactos de bala en prácticas de disparo mediante deep learning?</p>	<p>Objetivo Principal</p> <p>Implementar un sistema web para la detección de impactos de bala en prácticas de disparo mediante deep learning.</p>	<p>Hipótesis Principal</p> <p>Existe mejora con la implementación de un sistema web para la detección de impactos de bala en prácticas de disparo mediante deep learning.</p>	<p>Variable Independiente:</p> <p>Sistema Web</p> <p>Indicadores</p> <p>Presencia - Ausencia</p>	<ol style="list-style-type: none"> 1. Tipo de Investigación Aplicada 2. Diseño de Investigación Pre- Experimental 3. Nivel de Investigación Aplicativo 4. Población <p style="margin-left: 20px;">Personal de la PNP especializado en evaluación de tiro</p> 5. Muestra <p style="margin-left: 20px;">30 especialistas de la PNP</p> 6. Técnicas <p style="margin-left: 20px;">Encuesta</p>
<p>Problemas Específicos</p> <p>¿En qué medida la implementación de un sistema web mejora el tiempo de detección de impactos de bala en prácticas de disparo?</p>	<p>Objetivos Específicos</p> <p>Implementar un sistema web para mejorar el tiempo de detección de impactos de bala en prácticas de disparo.</p>	<p>Hipótesis Específicas</p> <p>Existe mejora con la implementación de un sistema web en cuanto al tiempo de detección de impactos de bala en prácticas de disparo.</p>		
<p>¿En qué medida la implementación de un sistema web mejora la exactitud de la detección de impactos de bala en prácticas</p>	<p>Implementar un sistema web para mejorar la exactitud de la detección de impactos de bala en prácticas de disparo.</p>	<p>Existe mejora con la implementación de un sistema web en cuanto a la exactitud de la detección de impactos de bala en prácticas de disparo.</p>		

de disparo?			<ul style="list-style-type: none"> - Tiempo de Detección de Impactos de Bala. - Exactitud de la detección de impactos de bala. - Satisfacción del usuario. 	<p>7. Instrumentos Ficha de recojo de Información (Cuestionario)</p>
¿En qué medida la implementación de un sistema web mejora la satisfacción del usuario en prácticas de disparo?	Implementar un sistema web para mejorar la satisfacción del usuario en prácticas de disparo.	Existe mejora con la implementación de un sistema web en cuanto a la satisfacción del usuario en prácticas de disparo.		

Anexo 2. Instrumento de medición
CUESTIONARIO – SISTEMA WEB DE DETECCIÓN DE IMPACTOS DE BALA

El propósito de este cuestionario es evaluar la efectividad del sistema web implementado para la detección de impactos de bala mediante deep learning. Por favor, responda según su experiencia de uso del sistema.

Muy Deficiente	Deficiente	Regular	Bueno	Muy Bueno
1	2	3	4	5

Dimensión	N.º	Preguntas	1	2	3	4	5
Tiempo de Detección	1	El tiempo que tarda el sistema en procesar las imágenes es satisfactorio.					
	2	El sistema proporciona resultados de detección de manera rápida.					
	3	El tiempo de respuesta del sistema es mejor que los métodos manuales tradicionales.					
	4	La velocidad de detección del sistema permite su uso en evaluaciones en tiempo real.					
	5	El tiempo desde la carga de imagen hasta la visualización de resultados es adecuado.					
Exactitud de la detección de Impactos de Bala	6	El sistema detecta correctamente todos los impactos de bala presentes en las imágenes.					
	7	El sistema evita falsos positivos (no detecta impactos donde no los hay).					
	8	La precisión del sistema es superior a la evaluación manual tradicional.					
	9	Los resultados del sistema coinciden con la evaluación manual experta.					
Satisfacción del Usuario	10	En general, estoy satisfecho con el rendimiento del sistema web.					
	11	Confío en los resultados proporcionados por el sistema.					
	12	El sistema contribuye a la objetividad en las evaluaciones de tiro.					
	13	Prefiero usar este sistema en lugar de métodos manuales tradicionales.					
	14	El sistema cumple con mis expectativas para la detección automatizada.					

Anexo 3. Informe de opinión de expertos

Formato para expertos

INFORME DE OPINIÓN DE EXPERTOS DEL INSTRUMENTO DE INVESTIGACIÓN

I. DATOS GENERALES:

1.1. Apellidos y nombres del informante (Experto):

1.2. Grado Académico:

1.3. Profesión:

1.4. Institución donde labora:

1.5. Cargo que desempeña:

1.6. Denominación del Instrumento: **Detección de Impactos de Bala**

1.7. Autor del instrumento: **Viveros Blanco, Farley Rodrigo Eduardo y Cotrina Caceres Sebastian Airton**

1.8 Programa : **Título Profesional**.....

II. VALIDACIÓN

INDICADORES DE EVALUACIÓN DEL INSTRUMENTO	CRITERIOS Sobre los ítems del instrumento	Muy Malo	Malo	Regular	Bueno	Muy Bueno
		1	2	3	4	5
1. CLARIDAD	Están formulados con lenguaje apropiado que facilita su comprensión					
2. OBJETIVIDAD	Están expresados en conductas observables, medibles					
3. CONSISTENCIA	Existe una organización lógica en los contenidos y relación con la teoría					
4. COHERENCIA	Existe relación de los contenidos con los indicadores de la variable					
5. PERTINENCIA	Las categorías de respuestas y sus valores son apropiados					
6. SUFICIENCIA	Son suficientes la cantidad y calidad de ítems presentados en el instrumento					
SUMATORIA PARCIAL						
SUMATORIA TOTAL						

III. RESULTADOS DE LA VALIDACIÓN

3.1. Valoración total cuantitativa: _____
3.2. Opinión: FAVORABLE _____ DEBE MEJORAR _____

NO FAVORABLE _____

3.3. Observaciones: _____

Tacna, 27 de agosto del 2025

Firma del Experto

Anexo 4. Constancia de uso del sistema en la DIPROVE

UNIVERSIDAD PRIVADA DE TACNA
Facultad de Ingeniería
Escuela Profesional de Ingeniería de Sistemas

CONSTANCIA DE USO DEL SISTEMA

Los que suscriben, **Farley Rodrigo Eduardo Viveros Blanco**, identificado con DNI N° 73001881, y **Sebastian Airton Cotrina Caceres**, identificado con DNI N° 70508277, estudiantes de la Escuela Profesional de Ingeniería de Sistemas de la Universidad Privada de Tacna, dejamos constancia de lo siguiente:

Que, en el marco del desarrollo de la tesis titulada "**Sistema Web para la Detección de Impactos de Bala en Prácticas de Disparo mediante Deep Learning**", el sistema fue implementado y puesto en funcionamiento en la **Unidad Especializada DEPROVE – Policía Nacional del Perú, sede Tacna**, durante el mes de septiembre del año 2025.

El sistema fue utilizado de manera efectiva por el personal policial especializado en evaluación de tiro de dicha dependencia, quienes pudieron verificar su correcto funcionamiento y aplicabilidad en los procesos de evaluación de tiro de la institución.

La presente constancia se emite a solicitud de los interesados, para los fines académicos que estimen conveniente.

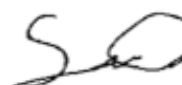
Tacna, 12 septiembre del 2025



**Farley Rodrigo Eduardo Viveros
Blanco**

DNI: 73001881

Tesista



Sebastian Airton Cotrina Caceres

DNI: 70508277

Tesista

Anexo 5. Tabulación de Resultados

A continuación, se presenta la tabla de tabulación de resultados, acompañada de la correspondencia de los ítems (P1–P14) con sus respectivas preguntas del cuestionario.

Ítem	Preguntas
P1	El tiempo que tarda el sistema en procesar las imágenes es satisfactorio.
P2	El sistema proporciona resultados de detección de manera rápida.
P3	El tiempo de respuesta del sistema es mejor que los métodos manuales tradicionales.
P4	La velocidad de detección del sistema permite su uso en evaluaciones en tiempo real.
P5	El tiempo desde la carga de imagen hasta la visualización de resultados es adecuado.
P6	El sistema detecta correctamente todos los impactos de bala presentes en las imágenes.
P7	El sistema evita falsos positivos (no detecta impactos donde no los hay).
P8	La precisión del sistema es superior a la evaluación manual tradicional.
P9	Los resultados del sistema coinciden con la evaluación manual experta.
P10	En general, estoy satisfecho con el rendimiento del sistema web.
P11	Confío en los resultados proporcionados por el sistema.
P12	El sistema contribuye a la objetividad en las evaluaciones de tiro.
P13	Prefiero usar este sistema en lugar de métodos manuales tradicionales.
P14	El sistema cumple con mis expectativas para la detección automatizada.

ID	Pregunta	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14
1		5	5	5	5	4	5	5	5	5	5	5	4	5	5
2		4	5	4	5	4	5	4	5	5	5	4	5	4	5
3		4	4	4	5	3	5	5	5	5	4	5	5	5	5
4		5	4	4	4	4	5	5	5	5	5	4	4	5	4
5		3	4	4	4	3	5	5	4	5	4	4	5	5	4
6		5	5	5	5	5	5	5	5	5	5	5	5	5	5
7		4	4	5	5	4	5	5	5	5	5	5	5	5	5
8		5	5	5	5	4	5	5	5	5	5	5	5	5	5
9		5	4	5	4	5	5	5	4	4	5	4	5	5	5
10		5	5	4	5	4	5	5	5	5	5	4	5	5	5
11		5	5	5	4	5	4	5	4	4	5	5	5	5	5
12		4	5	5	4	5	5	5	5	5	4	4	5	5	5
13		5	4	5	5	5	5	5	5	5	4	4	5	5	5
14		4	4	5	5	5	5	5	5	4	5	4	5	5	5
15		5	5	5	4	4	5	5	5	4	4	5	5	5	5
16		4	5	5	4	4	5	5	5	5	4	5	5	5	5
17		5	4	5	5	5	4	4	5	4	5	5	5	5	5
18		5	4	5	5	5	5	5	5	5	5	5	5	4	5
19		4	5	5	5	4	5	5	4	5	5	5	4	5	5
20		4	4	5	5	5	5	5	5	5	4	4	5	5	5
21		4	5	5	4	5	5	5	4	5	5	4	5	5	5
22		5	5	5	5	4	5	5	5	4	5	4	5	5	5
23		3	5	4	4	4	5	5	4	5	5	5	5	5	5
24		5	5	5	4	5	4	5	5	5	4	5	4	5	4
25		4	5	5	5	5	5	4	5	5	5	5	5	5	5
26		5	5	5	5	4	4	5	5	5	4	5	5	5	4
27		4	5	5	5	5	5	5	5	5	4	5	5	5	5
28		5	5	4	4	4	5	4	4	4	5	5	5	4	5
29		4	5	5	5	4	4	4	5	5	5	4	5	5	5
30		5	5	5	4	5	5	5	4	5	5	5	5	5	4

Anexo 6. Desarrollo del proyecto

Estudio de factibilidad

Factibilidad técnica

Para el buen desarrollo del proyecto se contó con un listado de recursos tecnológicos que permitieron que el proyecto pueda desarrollarse de manera exitosa. A continuación, se presenta el listado de hardware y software necesario para el desarrollo del sistema:

Tipo de Recurso	Perfil	Cantidad	Detalle	Acceso a Recurso
Recursos Humanos	Investigador / Analista	1	Bachiller en Ingeniería de Sistemas	Si
	Desarrollador / Diseñador	1	Bachiller en Ingeniería de Sistemas	Si
Software	Herramienta de Programación	1	Visual Studio Code 1.103	Si
	Lenguaje de Programación	1	Python 3.13	Si
	Gestor de Base de Datos	1	MongoDB	Si
	Sistema Operativo	1	Windows 11 Pro	Si
Hardware	Computadoras	2	Intel Core i7 12700K, 1 Tb SSD, 32 Gb RAM, RTX Serie 4060 12 Gb VRAM, Windows 10.	Si
	Escáner	1	Escáner Canon CanoScan Lide 400 Negro para escaneo de siluetas	Si
Otros	Papel bond	50	Hojas de papel de	Si

			Bond	
	Internet	1	Acceso a Internet	Si
	Luz eléctrica	1	Luz eléctrica	Si

Factibilidad operativa

El sistema web para la detección de impactos de bala mediante deep learning en prácticas de disparo, favorece en la modernización e imparcialidad en prácticas de disparo, teniendo como beneficio, la mejora del tiempo de evaluación, la precisión y la satisfacción de tiradores, al saber que el sistema lo evaluara de forma eficiente y justa.

El sistema será de gran utilidad para el personal evaluador, ya que automatizará el proceso de detección y conteo de impactos de bala, eliminando la subjetividad y los errores humanos inherentes a la evaluación manual tradicional. Según Butt et al. (2023), los sistemas automatizados de detección pueden reducir el tiempo de evaluación en un 70-80 % comparado con métodos manuales, lo que permitirá al personal dedicar más tiempo a tareas de mayor valor agregado como la supervisión, capacitación y análisis de resultados.

Tipo de Organización	Nombre de la Organización	Cargo	¿Está de Acuerdo?
Publica	Departamento de Robo de Vehículos Unidad Especializada DIPROVE - PNP	Jefe de la DIPROVE - Sub Oficial Superior Godofredo R. Verástegui Malpica	Si

Factibilidad económica

Para poder realizar el presente trabajo de investigación y el desarrollo del software se considera la totalidad de los costos de los recursos necesarios para la implementación del sistema web para la detección de los impactos de bala.

a. Costos de recursos humanos

Cantidad	Unidad	Descripción	Costo(S/.)
1	Persona	Asesor de Tesis	1500.00
1	Persona	Investigador/Analista	4150.00
1	Persona	Desarrollador/Diseñador	4150.00
Total			9800.00

b. Costos recursos generales - tecnológicos

Cantidad	Descripción	Tipo	Costo(S/.)	Costo total (S/.)
1	Laptop	Hardware	2500.00	2500.00
1	Servidor del sistema web Railway (3 meses)	Software	150.00	450.00
1	Servidor de Base de Datos	Software	80.00	0.00
1	IDE Visual Studio Code	Software	0.00	0.00
1	Lenguaje de Programación Python / React	Software	0.00	0.00
				2950.00

c. Costos de recursos de operación

Descripción	Cantidad	Costo (S/.)	Costo total (S/.)
Electricidad	4	45.00	180.00
Internet	4	70.00	280.00
TOTAL			460.00

d. Costos totales de inversión

Concepto	Costo (S/.)
Costos de Recurso Humanos	9800.00
Costos de Recursos Generales - Tecnológicos	2950.00
Costos de Recursos de Operación	460.00
	13,210.00

e. Costos de mantenimiento

Descripción	Tiempo	Costo
Mantenimiento de Software	Cada 6 meses	S/. 925
Total		S/. 925

f. Flujo de caja e indicadores de factibilidad

Descripción	Año					
	0	1	2	3	4	5
Inversión	-S/ 13,210					
Ingresos						
Ventas		S/ 4.850,00	S/ 5.480,00	S/ 6.290,00	S/ 6.850,00	S/ 7.520,00
Total Ingresos		S/ 4.850,00	S/ 5.480,00	S/ 6.290,00	S/ 6.850,00	S/ 7.520,00
Egresos						
Costos variables		S/ 0,00	S/ 28,50	S/ 72,40	S/ 118,60	S/ 145,20
Costo de mantenimiento		S/ 1.850,00	S/ 1.850,00	S/ 1.850,00	S/ 1.850,00	S/ 1.850,00
Impuestos		S/ 1.455,00	S/ 1.644,20	S/ 1.887,10	S/ 2.055,50	S/ 2.256,60
Total Egresos		S/ 3.305,00	S/ 3.522,70	S/ 3.809,50	S/ 4.024,10	S/ 4.251,80
Flujo de Caja	-S/ 13,210	S/ 1.545,00	S/ 1.957,30	S/ 2.480,50	S/ 2.825,90	S/ 3.268,20
Beneficio/Costo		1,47	1,56	1,65	1,70	1,77

VAN	S/ 2486,45
-----	------------

TIR	-S/ 13.210,00	S/ 1.545,00	S/ 1.957,30	S/ 2.480,50	S/ 2.825,90	S/ 3.268,20
TIR	18%					
TIR > Tasa	Se acepta el Proyecto					

Se consideró un plazo de 5 años para el análisis de viabilidad económica del proyecto, donde los ingresos muestran un crecimiento progresivo del 12 % anual

aproximadamente, iniciando con S/ 4.850,00 en el primer año y alcanzando S/ 7.520,00 en el quinto año. Los costos de mantenimiento se mantienen constantes en S/ 1.850,00 anuales por tratarse de gastos operativos estables relacionados con el soporte técnico, actualizaciones de software y hosting del sistema web.

Los indicadores de viabilidad confirman la rentabilidad y factibilidad económica del proyecto. El Valor Actual Neto (VAN) de S/ 2.486,45 es positivo, lo que indica que el proyecto generará valor económico superior a la inversión inicial de S/ 13.210,00. La Tasa Interna de Retorno (TIR) de 18 % es significativamente mayor a la tasa de descuento del 8 %, confirmando que el proyecto ofrece una rentabilidad superior al costo de oportunidad del capital. El Beneficio/Costo promedio de 1,77 en el último año, siendo mayor a 1, demuestra que por cada sol invertido el proyecto genera 77 centavos adicionales de beneficio, validando la viabilidad económica del sistema web de detección de impactos de bala.

Desarrollo del proyecto

Requerimientos funcionales

ID	Requerimiento Funcional	Descripción
RF-01	Reconocimiento Facial para Tirador	Implementar un sistema de reconocimiento facial que identifique al tirador antes de iniciar la sesión de práctica de disparo.
RF-02	Captura de Siluetas de Disparo	Desarrollar un módulo que capture imágenes de las siluetas de disparo. Estas imágenes serán procesadas posteriormente para la detección de impactos.
RF-03	Procesamiento de Detección de Impactos de Bala	Utilizar modelos de deep learning para analizar las imágenes capturadas de las siluetas y detectar los puntos de impacto de las balas. Este procesamiento debe ser preciso y capaz de diferenciar impactos cercanos.
RF-04	Evaluación de	Permite la evaluación de resultados de cada

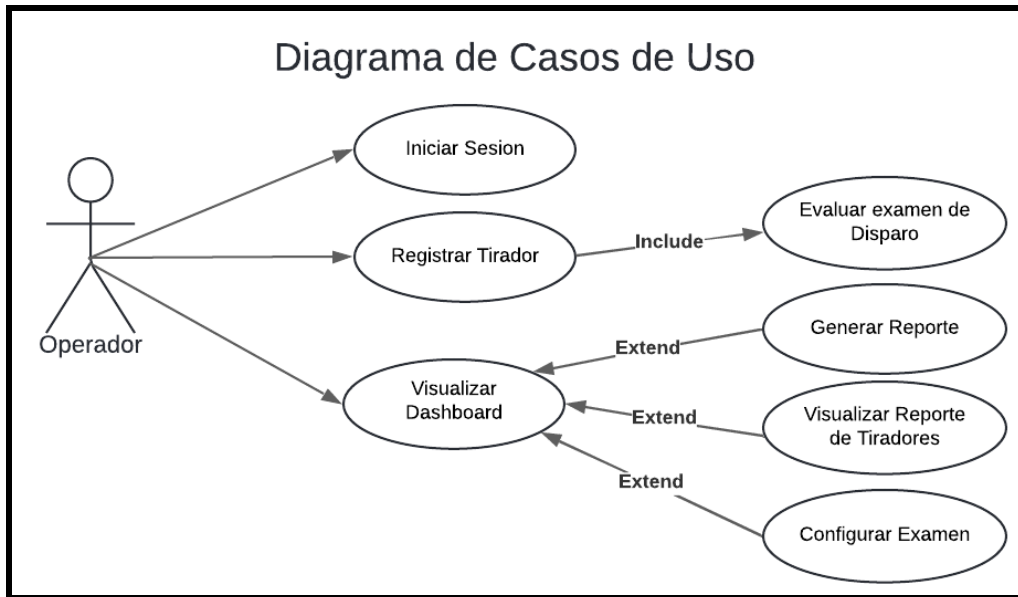
	Resultados	sesión de disparo, proporcionando métricas como precisión, ubicación y puntuación general del tirador basado en los impactos detectados.
RF-05	Parametrización de Tandas de Disparo	Permitir la configuración del número de impactos de bala por silueta, este parámetro influirá en el resultado.
RF-06	Generación de Reportes	Generar reportes de cada sesión de práctica, que incluya información sobre el tirador, los impactos detectados, y las evaluaciones obtenidas. Los reportes deben poder ser exportados en formatos como PDF.
RF-07	Autenticación de Operadores	Permite a los operadores autenticarse de manera segura en el sistema web, garantizando que solo personal autorizado tenga acceso al sistema.
RF-08	Registro de Operadores	Registrar operadores dentro del sistema, así como la actualización de datos personales.

Requerimientos no funcionales

ID	Requerimiento No Funcional	Descripción
RNF-01	Seguridad	El sistema debe garantizar la protección de datos personales que se manejen en el sistema.
RNF-02	Rendimiento	El sistema debe procesar imágenes en tiempo real con una latencia mínima y ser escalable para manejar un alto volumen de usuarios y sesiones de práctica simultáneas.
RNF-03	Usabilidad	La interfaz de usuario debe ser intuitiva, fácil de usar y accesible cumpliendo con estándares de accesibilidad web.
RNF-04	Adaptabilidad	El sistema web debe ser responsive para que pueda ser utilizado por distintos dispositivos electrónicos (celular, computadora, laptop,

		etc.).
--	--	--------

Vistas de caso de uso



Descripción de casos de uso

Descripción del caso de uso: CU_01 – Iniciar sesión

Nombre Caso de Uso	Iniciar Sesión																			
Actor	Operador																			
Descripción	Es la parte inicial del sistema, el operador debe iniciar sesión con sus credenciales. (correo y contraseña)																			
Precondición	El operador debe estar registrado dentro del sistema.																			
Flujo Principal	<table border="1"> <thead> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>1. El operador ingresa al dominio del sistema https://frontendadmin.azurewebsites.net/</td> <td>2. El sistema muestra como título "Sistema de Evaluación de Disparo", muestra también 2 campos, correo y contraseña, el botón "Iniciar Sesión"; y muestra la opción "Regístrate aquí" junto con el texto "No tienes una cuenta?".</td> </tr> <tr> <td>3. El operador ingresa sus credenciales, correo y contraseña. Flujo Alternativo</td> <td>4. El sistema valida las credenciales y muestra el dashboard principal en el que se encuentran todos los apartados.</td> </tr> </tbody> </table>	Operador	Sistema	1. El operador ingresa al dominio del sistema https://frontendadmin.azurewebsites.net/	2. El sistema muestra como título "Sistema de Evaluación de Disparo", muestra también 2 campos, correo y contraseña, el botón "Iniciar Sesión"; y muestra la opción "Regístrate aquí" junto con el texto "No tienes una cuenta?".	3. El operador ingresa sus credenciales, correo y contraseña. Flujo Alternativo	4. El sistema valida las credenciales y muestra el dashboard principal en el que se encuentran todos los apartados.													
Operador	Sistema																			
1. El operador ingresa al dominio del sistema https://frontendadmin.azurewebsites.net/	2. El sistema muestra como título "Sistema de Evaluación de Disparo", muestra también 2 campos, correo y contraseña, el botón "Iniciar Sesión"; y muestra la opción "Regístrate aquí" junto con el texto "No tienes una cuenta?".																			
3. El operador ingresa sus credenciales, correo y contraseña. Flujo Alternativo	4. El sistema valida las credenciales y muestra el dashboard principal en el que se encuentran todos los apartados.																			
Flujo Alternativo	<table border="1"> <thead> <tr> <th colspan="2">Si las credenciales son incorrectas</th> </tr> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>3. El operador ingresa sus credenciales, correo y contraseña.</td> <td>4. El sistema verifica que las credenciales son incorrectas y borra los datos de los campos.</td> </tr> <tr> <td>5. El operador vuelve a ingresar sus credenciales correctamente.</td> <td>6. El sistema verifica las credenciales correctas. Vuelve al Flujo principal.</td> </tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="2">Si el operador no posee una cuenta</th> </tr> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>3. Si el operador no posee una cuenta, interactúa con el botón "Regístrate aquí"</td> <td>4. El sistema muestra una nueva pestaña, "Registro de Usuario", con los campos "Nombre", "Correo", "Clave", "DNI" y el botón "Registrar".</td> </tr> <tr> <td>5. El operador ingresa los datos "Nombre", "Correo", "Clave", "DNI" e interactúa con el botón "Registrar".</td> <td>6. El sistema guarda el registro dentro de la base de datos y retorna a la pestaña de inicio de sesión.</td> </tr> <tr> <td>7. El operador ingresa los datos solicitados para el inicio de sesión, "Correo", "Contraseña" e interactúa con el botón "Iniciar Sesión".</td> <td>8. El sistema valida las credenciales del operador y lo redirige al dashboard principal.</td> </tr> </tbody> </table>		Si las credenciales son incorrectas		Operador	Sistema	3. El operador ingresa sus credenciales, correo y contraseña.	4. El sistema verifica que las credenciales son incorrectas y borra los datos de los campos.	5. El operador vuelve a ingresar sus credenciales correctamente.	6. El sistema verifica las credenciales correctas. Vuelve al Flujo principal.	Si el operador no posee una cuenta		Operador	Sistema	3. Si el operador no posee una cuenta, interactúa con el botón "Regístrate aquí"	4. El sistema muestra una nueva pestaña, "Registro de Usuario", con los campos "Nombre", "Correo", "Clave", "DNI" y el botón "Registrar".	5. El operador ingresa los datos "Nombre", "Correo", "Clave", "DNI" e interactúa con el botón "Registrar".	6. El sistema guarda el registro dentro de la base de datos y retorna a la pestaña de inicio de sesión.	7. El operador ingresa los datos solicitados para el inicio de sesión, "Correo", "Contraseña" e interactúa con el botón "Iniciar Sesión".	8. El sistema valida las credenciales del operador y lo redirige al dashboard principal.
Si las credenciales son incorrectas																				
Operador	Sistema																			
3. El operador ingresa sus credenciales, correo y contraseña.	4. El sistema verifica que las credenciales son incorrectas y borra los datos de los campos.																			
5. El operador vuelve a ingresar sus credenciales correctamente.	6. El sistema verifica las credenciales correctas. Vuelve al Flujo principal.																			
Si el operador no posee una cuenta																				
Operador	Sistema																			
3. Si el operador no posee una cuenta, interactúa con el botón "Regístrate aquí"	4. El sistema muestra una nueva pestaña, "Registro de Usuario", con los campos "Nombre", "Correo", "Clave", "DNI" y el botón "Registrar".																			
5. El operador ingresa los datos "Nombre", "Correo", "Clave", "DNI" e interactúa con el botón "Registrar".	6. El sistema guarda el registro dentro de la base de datos y retorna a la pestaña de inicio de sesión.																			
7. El operador ingresa los datos solicitados para el inicio de sesión, "Correo", "Contraseña" e interactúa con el botón "Iniciar Sesión".	8. El sistema valida las credenciales del operador y lo redirige al dashboard principal.																			
Postcondición	El operador podrá visualizar el dashboard principal del sistema.																			

Descripción del caso de uso: CU_02 – Registrar Tirador

Nombre Caso de Uso	Registrar Tirador									
Actor	Operador									
Descripción	El operador registra al tirador con sus datos personales y biométricos para almacenarlos en la base de datos.									
Precondición	El operador debió iniciar sesión para poder ingresar al apartado de registrar tirador.									
Flujo Principal	<table border="1"> <thead> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>1. El operador en el dashboard principal ingresa al apartado "Registrar Tirador" del dashboard principal.</td> <td>2. El sistema muestra el mensaje "Bienvenido a la Evaluación de Disparo", "Prepárate para rendir tu examen posees tiempo para realizar tu examen." y el botón "Iniciar Examen" el cual mostrará una nueva página con el título "Reconocimiento Facial en proceso...", encenderá la cámara disponible y mostrará también el botón "Capture".</td> </tr> <tr> <td>3. El operador visualiza el enfoque de la cámara, ubica al tirador para la toma del rostro y captura el rostro del tirador con el botón "Capture".</td> <td>4. El sistema al no encontrar coincidencia del rostro, muestra el formulario "Reconocimiento Facial en proceso..." con los campos "Ingrese su DNI", "Ingrese su Nombre" y el botón "Guardar". Flujo Alternativo</td> </tr> <tr> <td>5. El operador ingresa los datos personales del tirador en los campos disponibles e interactúa con el botón "Guardar" para poder guardarlo.</td> <td>6. El sistema almacena los datos del tirador vuelve a la página de reconocimiento facial.</td> </tr> </tbody> </table>	Operador	Sistema	1. El operador en el dashboard principal ingresa al apartado "Registrar Tirador" del dashboard principal.	2. El sistema muestra el mensaje "Bienvenido a la Evaluación de Disparo", "Prepárate para rendir tu examen posees tiempo para realizar tu examen." y el botón "Iniciar Examen" el cual mostrará una nueva página con el título "Reconocimiento Facial en proceso...", encenderá la cámara disponible y mostrará también el botón "Capture".	3. El operador visualiza el enfoque de la cámara, ubica al tirador para la toma del rostro y captura el rostro del tirador con el botón "Capture".	4. El sistema al no encontrar coincidencia del rostro, muestra el formulario "Reconocimiento Facial en proceso..." con los campos "Ingrese su DNI", "Ingrese su Nombre" y el botón "Guardar". Flujo Alternativo	5. El operador ingresa los datos personales del tirador en los campos disponibles e interactúa con el botón "Guardar" para poder guardarlo.	6. El sistema almacena los datos del tirador vuelve a la página de reconocimiento facial.	
Operador	Sistema									
1. El operador en el dashboard principal ingresa al apartado "Registrar Tirador" del dashboard principal.	2. El sistema muestra el mensaje "Bienvenido a la Evaluación de Disparo", "Prepárate para rendir tu examen posees tiempo para realizar tu examen." y el botón "Iniciar Examen" el cual mostrará una nueva página con el título "Reconocimiento Facial en proceso...", encenderá la cámara disponible y mostrará también el botón "Capture".									
3. El operador visualiza el enfoque de la cámara, ubica al tirador para la toma del rostro y captura el rostro del tirador con el botón "Capture".	4. El sistema al no encontrar coincidencia del rostro, muestra el formulario "Reconocimiento Facial en proceso..." con los campos "Ingrese su DNI", "Ingrese su Nombre" y el botón "Guardar". Flujo Alternativo									
5. El operador ingresa los datos personales del tirador en los campos disponibles e interactúa con el botón "Guardar" para poder guardarlo.	6. El sistema almacena los datos del tirador vuelve a la página de reconocimiento facial.									
Flujo Alternativo	<table border="1"> <thead> <tr> <th colspan="2">Si se detecta que el rostro ya ha sido registrado</th> </tr> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>5. El Operador podrá visualizar la página del examen de disparo. Flujo Principal</td> <td>4. El sistema detecta que el rostro ya ha sido registrado, omite el registro de este, y lo envía directamente al examen de disparo.</td> </tr> </tbody> </table>		Si se detecta que el rostro ya ha sido registrado		Operador	Sistema	5. El Operador podrá visualizar la página del examen de disparo. Flujo Principal	4. El sistema detecta que el rostro ya ha sido registrado, omite el registro de este, y lo envía directamente al examen de disparo.		
Si se detecta que el rostro ya ha sido registrado										
Operador	Sistema									
5. El Operador podrá visualizar la página del examen de disparo. Flujo Principal	4. El sistema detecta que el rostro ya ha sido registrado, omite el registro de este, y lo envía directamente al examen de disparo.									
Postcondición	El operador podrá habilitar el examen de disparo para que el tirador lo pueda rendir.									

Descripción del caso de Uso: CU_03 – Evaluar Examen de Disparo

Nombre Caso de Uso	Evaluar Examen de Disparo															
Actor	Operador															
Descripción	Se evalúa la silueta de disparo realizada por el tirador para poder brindar un resultado en cuanto a su precisión.															
Precondición	El operador debió registrar al tirador para poder habilitar el examen de disparo.															
Flujo Principal	<table border="1"> <thead> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>1. El operador habiendo registrado al tirador, se le mostrara la página de examen de disparo.</td> <td rowspan="2">2. El sistema muestra la página del examen de disparo mencionando al tirador "Examen de..." , muestra el botón "Seleccionar Archivo" para que el operador pueda subir la imagen de la silueta, el botón "Subir Imagen" le servirá para poder enviar la imagen y que el modelo lo procese, por último, aparecerá "Máximo de disparos permitidos" el varia de acuerdo con la configuración del dashboard.</td> </tr> <tr> <td>3. El operador indica que el tirador realice sus disparos correspondientes y cuando haya culminado su tanda de disparos, el operador toma una foto a la silueta de disparo y la sube al sistema mediante el botón "Subir Archivo..." y sube la imagen con el botón "Subir Imagen". Flujo Alternativo.</td> </tr> <tr> <td>5. El operador visualiza el resultado general por el sistema y procede a cerrar la ventana del examen de disparo.</td> <td>4. Automáticamente el botón de "Subir Imagen" cambiara a "Subiendo..." para hacerle saber al operador que la imagen está siendo procesada. Y el sistema guardara la imagen de la silueta, la procesara para obtener resultados, aplicando el entrenamiento que se le brindo para poder evaluar la distancia entre los impactos de bala y brinda el resultado "Precisión Final" y "Detalles de los disparos", en este último se lista el "Impacto en" el cual representa las coordenadas y a su lado "Precisión" la cual es el porcentaje brindado para dicha coordenada y almacena todos los resultados en la base de datos.</td> </tr> </tbody> </table>	Operador	Sistema	1. El operador habiendo registrado al tirador, se le mostrara la página de examen de disparo.	2. El sistema muestra la página del examen de disparo mencionando al tirador "Examen de..." , muestra el botón "Seleccionar Archivo" para que el operador pueda subir la imagen de la silueta, el botón "Subir Imagen" le servirá para poder enviar la imagen y que el modelo lo procese, por último, aparecerá "Máximo de disparos permitidos" el varia de acuerdo con la configuración del dashboard.	3. El operador indica que el tirador realice sus disparos correspondientes y cuando haya culminado su tanda de disparos, el operador toma una foto a la silueta de disparo y la sube al sistema mediante el botón "Subir Archivo..." y sube la imagen con el botón "Subir Imagen". Flujo Alternativo.	5. El operador visualiza el resultado general por el sistema y procede a cerrar la ventana del examen de disparo.	4. Automáticamente el botón de "Subir Imagen" cambiara a "Subiendo..." para hacerle saber al operador que la imagen está siendo procesada. Y el sistema guardara la imagen de la silueta, la procesara para obtener resultados, aplicando el entrenamiento que se le brindo para poder evaluar la distancia entre los impactos de bala y brinda el resultado "Precisión Final" y "Detalles de los disparos", en este último se lista el "Impacto en" el cual representa las coordenadas y a su lado "Precisión" la cual es el porcentaje brindado para dicha coordenada y almacena todos los resultados en la base de datos.								
Operador	Sistema															
1. El operador habiendo registrado al tirador, se le mostrara la página de examen de disparo.	2. El sistema muestra la página del examen de disparo mencionando al tirador "Examen de..." , muestra el botón "Seleccionar Archivo" para que el operador pueda subir la imagen de la silueta, el botón "Subir Imagen" le servirá para poder enviar la imagen y que el modelo lo procese, por último, aparecerá "Máximo de disparos permitidos" el varia de acuerdo con la configuración del dashboard.															
3. El operador indica que el tirador realice sus disparos correspondientes y cuando haya culminado su tanda de disparos, el operador toma una foto a la silueta de disparo y la sube al sistema mediante el botón "Subir Archivo..." y sube la imagen con el botón "Subir Imagen". Flujo Alternativo.																
5. El operador visualiza el resultado general por el sistema y procede a cerrar la ventana del examen de disparo.	4. Automáticamente el botón de "Subir Imagen" cambiara a "Subiendo..." para hacerle saber al operador que la imagen está siendo procesada. Y el sistema guardara la imagen de la silueta, la procesara para obtener resultados, aplicando el entrenamiento que se le brindo para poder evaluar la distancia entre los impactos de bala y brinda el resultado "Precisión Final" y "Detalles de los disparos", en este último se lista el "Impacto en" el cual representa las coordenadas y a su lado "Precisión" la cual es el porcentaje brindado para dicha coordenada y almacena todos los resultados en la base de datos.															
Flujo Alternativo	<table border="1"> <thead> <tr> <th colspan="2">Si la captura esta distorsionada, no se ha subido bien, o hubo algún error.</th> </tr> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>3. El operador sube la imagen que tomo de la silueta de disparo y la sube al sistema mediante el botón "Seleccionar Archivo"</td> <td rowspan="2">4. El sistema evalúa los impactos de bala realizados en la silueta, pero al no poder realizarlo de la manera correcta por alguna deficiencia en la captura de la silueta con impactos de bala, muestra el mensaje "Error: Hubo un error al momento de procesar la imagen."</td> </tr> <tr> <td>5. El operador verifica si la imagen de la silueta con impactos de bala tiene buena resolución y vuelve a subir la imagen de manera correcta. Vuelve al flujo principal.</td> </tr> <tr> <th colspan="2">Si no se ha subido ninguna imagen.</th> </tr> <tr> <th>Operador</th> <th>Sistema</th> </tr> <tr> <td>3. El operador le da clic al botón "Subir Imagen" sin haber subido ninguna imagen.</td> <td rowspan="2">4. El sistema al no tener ninguna imagen para analizar, envía el mensaje: "No se ha subido ninguna imagen".</td> </tr> <tr> <td>5. El operador con el botón "Seleccionar Archivo", selecciona la imagen de la silueta con disparos e interactúa con el botón "Subir Imagen". Vuelve al flujo principal.</td> </tr> </tbody> </table>		Si la captura esta distorsionada, no se ha subido bien, o hubo algún error.		Operador	Sistema	3. El operador sube la imagen que tomo de la silueta de disparo y la sube al sistema mediante el botón "Seleccionar Archivo"	4. El sistema evalúa los impactos de bala realizados en la silueta, pero al no poder realizarlo de la manera correcta por alguna deficiencia en la captura de la silueta con impactos de bala, muestra el mensaje "Error: Hubo un error al momento de procesar la imagen."	5. El operador verifica si la imagen de la silueta con impactos de bala tiene buena resolución y vuelve a subir la imagen de manera correcta. Vuelve al flujo principal.	Si no se ha subido ninguna imagen.		Operador	Sistema	3. El operador le da clic al botón "Subir Imagen" sin haber subido ninguna imagen.	4. El sistema al no tener ninguna imagen para analizar, envía el mensaje: "No se ha subido ninguna imagen".	5. El operador con el botón "Seleccionar Archivo", selecciona la imagen de la silueta con disparos e interactúa con el botón "Subir Imagen". Vuelve al flujo principal.
Si la captura esta distorsionada, no se ha subido bien, o hubo algún error.																
Operador	Sistema															
3. El operador sube la imagen que tomo de la silueta de disparo y la sube al sistema mediante el botón "Seleccionar Archivo"	4. El sistema evalúa los impactos de bala realizados en la silueta, pero al no poder realizarlo de la manera correcta por alguna deficiencia en la captura de la silueta con impactos de bala, muestra el mensaje "Error: Hubo un error al momento de procesar la imagen."															
5. El operador verifica si la imagen de la silueta con impactos de bala tiene buena resolución y vuelve a subir la imagen de manera correcta. Vuelve al flujo principal.																
Si no se ha subido ninguna imagen.																
Operador	Sistema															
3. El operador le da clic al botón "Subir Imagen" sin haber subido ninguna imagen.	4. El sistema al no tener ninguna imagen para analizar, envía el mensaje: "No se ha subido ninguna imagen".															
5. El operador con el botón "Seleccionar Archivo", selecciona la imagen de la silueta con disparos e interactúa con el botón "Subir Imagen". Vuelve al flujo principal.																
Postcondición	El operador visualiza el puntaje de los impactos de bala y dicho examen queda guardado.															

Descripción del caso de uso: CU_04 – Visualizar dashboard

Nombre Caso de Uso	Visualizar Dashboard	
Actor	Operador	
Descripción	El operador podrá interactuar con los diferentes módulos que se encuentran en el Dashboard principal	
Precondición	El operador debe haber iniciado sesión dentro del sistema.	
Flujo Principal	<p>Operador</p> <p>1. El operador ingresa al sistema con sus credenciales correctas.</p> <p>3. El operador visualiza la página del Dashboard principal.</p>	<p>Sistema</p> <p>2. El sistema le muestra el dashboard principal titulado "Dashboard Sistema de evaluación de Disparo", en la parte superior izquierda aparecerá "Sistema SUCAMEC" y en la parte superior derecha se muestra el usuario del operador en el cual, al momento de hacer clic, se despliega la opción "Logout". Los módulos se encuentran en el menú desplegable de la izquierda dividido en "Home" el cual tiene "Inicio", y en "Opciones" aparecen los apartados "Configurar Examen", "Tiradores", "Reporte de Tiradores", "Registrar Tirador" en la parte.</p>
Flujo Alternativo	No tiene flujo alternativo.	
Postcondición	El operador podrá interactuar con los módulos que se encuentran disponibles dentro del Dashboard.	

Descripción del caso de uso: CU_05 – Generar reporte

Nombre Caso de Uso	Generar Reporte	
Actor	Operador	
Descripción	El operador recibirá un reporte al finalizar el examen de disparo del tirador.	
Precondición	El operador debió haber evaluado al tirador en su examen de disparo.	
Flujo Principal	<p>Operador</p> <p>1. El operador habiendo evaluado al tirador mediante su examen de disparo, se dirige al dashboard principal y al apartado "Reportes".</p> <p>3. El operador visualiza el archivo PDF con los detalles del tirador.</p>	<p>Sistema</p> <p>2. El sistema mostrara la lista de reportes de los tiradores que hayan realizado su examen de disparo tal cual como esta detallado en el caso de Uso "Visualizar Reporte de Tiradores", dentro del botón "Ver Detalles" tendrá el botón "Exportar PDF", el cual genera el reporte en formato PDF el cual contendrá el título "Detalles del Reporte" y se detallara "Reporte ID", "Usuario", "Fecha del Reporte", "Total Impactos", "Promedio de Precisión", "Detalles", "Impactos Procesados", en este último se mostrará una tabla con los campos "ID Impacto", "Ubicación", "Precisión", "Fecha".</p>
Flujo Alternativo	No tiene algún flujo alternativo.	
Postcondición	El operador podrá visualizar el reporte generado y retornará al Dashboard principal del sistema.	

Descripción del caso de uso: CU_06 – Visualizar reporte de tiradores

Nombre Caso de Uso	Visualizar Reporte de Tiradores							
Actor	Operador							
Descripción	El operador podrá visualizar el reporte de los tiradores que se hayan registrado dentro del sistema.							
Precondición	El operador debió haber iniciado sesión dentro del sistema y debe haber tiradores registrados previamente.							
Flujo Principal	<table border="1"> <thead> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>1. El operador en el dashboard principal del sistema, deberá ingresar al módulo "Reportes".</td> <td rowspan="2">2. El sistema mostrará la página "Lista de Reportes" en la cual en una tabla se mostrará el "ID", "Usuario", "Fecha", "Total Impactos", "Promedio de Precisión", "Detalles", "Acciones", en este último se podrá visualizar dos botones "Ver Detalles" y "Generar PDF". Con el botón "Ver Detalles" cargará otra página titulada "Detalles del Reporte" en la cual se detalla "Reporte ID", "Usuario", "Fecha del Reporte", "Total Impactos", "Promedio de Precisión", "Detalles", "Impactos Procesados", en este último se mostrará una tabla con los campos "ID Impacto", "Ubicación", "Precisión", "Fecha". Por último, aparecerá el botón "Exportar PDF", en el que todo lo que son Detalles del Reporte se exportara en un PDF. Flujo Alternativo</td> </tr> <tr> <td>3. El operador podrá visualizar todos esos detalles por cada tirador que haya rendido el examen de disparo y podrá interactuar con los botones.</td> </tr> </tbody> </table>		Operador	Sistema	1. El operador en el dashboard principal del sistema, deberá ingresar al módulo "Reportes".	2. El sistema mostrará la página "Lista de Reportes" en la cual en una tabla se mostrará el "ID", "Usuario", "Fecha", "Total Impactos", "Promedio de Precisión", "Detalles", "Acciones", en este último se podrá visualizar dos botones "Ver Detalles" y "Generar PDF". Con el botón "Ver Detalles" cargará otra página titulada "Detalles del Reporte" en la cual se detalla "Reporte ID", "Usuario", "Fecha del Reporte", "Total Impactos", "Promedio de Precisión", "Detalles", "Impactos Procesados", en este último se mostrará una tabla con los campos "ID Impacto", "Ubicación", "Precisión", "Fecha". Por último, aparecerá el botón "Exportar PDF", en el que todo lo que son Detalles del Reporte se exportara en un PDF. Flujo Alternativo	3. El operador podrá visualizar todos esos detalles por cada tirador que haya rendido el examen de disparo y podrá interactuar con los botones.	
Operador	Sistema							
1. El operador en el dashboard principal del sistema, deberá ingresar al módulo "Reportes".	2. El sistema mostrará la página "Lista de Reportes" en la cual en una tabla se mostrará el "ID", "Usuario", "Fecha", "Total Impactos", "Promedio de Precisión", "Detalles", "Acciones", en este último se podrá visualizar dos botones "Ver Detalles" y "Generar PDF". Con el botón "Ver Detalles" cargará otra página titulada "Detalles del Reporte" en la cual se detalla "Reporte ID", "Usuario", "Fecha del Reporte", "Total Impactos", "Promedio de Precisión", "Detalles", "Impactos Procesados", en este último se mostrará una tabla con los campos "ID Impacto", "Ubicación", "Precisión", "Fecha". Por último, aparecerá el botón "Exportar PDF", en el que todo lo que son Detalles del Reporte se exportara en un PDF. Flujo Alternativo							
3. El operador podrá visualizar todos esos detalles por cada tirador que haya rendido el examen de disparo y podrá interactuar con los botones.								
Flujo Alternativo	<table border="1"> <thead> <tr> <th colspan="2">Si el tirador solo se registró, pero no rindió el examen de disparo</th> </tr> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>4. El operador solo visualizara a los tiradores que hayan rendido el examen de disparo. Vuelve al Flujo Principal.</td> <td>3. El sistema no mostrara a los tiradores que no hayan rendido el examen de disparo. Los tiradores que solo se hayan registrado estarán en el apartado "Tiradores" en la cual tiene como título "Lista de Tiradores" y muestra el campo "ID", "Nombre", "Correo", "DNI".</td> </tr> </tbody> </table>		Si el tirador solo se registró, pero no rindió el examen de disparo		Operador	Sistema	4. El operador solo visualizara a los tiradores que hayan rendido el examen de disparo. Vuelve al Flujo Principal.	3. El sistema no mostrara a los tiradores que no hayan rendido el examen de disparo. Los tiradores que solo se hayan registrado estarán en el apartado "Tiradores" en la cual tiene como título "Lista de Tiradores" y muestra el campo "ID", "Nombre", "Correo", "DNI".
Si el tirador solo se registró, pero no rindió el examen de disparo								
Operador	Sistema							
4. El operador solo visualizara a los tiradores que hayan rendido el examen de disparo. Vuelve al Flujo Principal.	3. El sistema no mostrara a los tiradores que no hayan rendido el examen de disparo. Los tiradores que solo se hayan registrado estarán en el apartado "Tiradores" en la cual tiene como título "Lista de Tiradores" y muestra el campo "ID", "Nombre", "Correo", "DNI".							
Postcondición	El operador vuelve al Dashboard principal o navega a otros módulos.							

Descripción del caso de uso: CU_07 – Configurar examen

Nombre Caso de Uso	Configurar Examen							
Actor	Operador							
Descripción	El operador podrá realizar modificaciones en los parámetros del sistema de disparos.							
Precondición	El operador debió haber iniciado sesión dentro del sistema.							
Flujo Principal	<table border="1"> <thead> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>1. El operador en el dashboard principal del sistema, deberá ingresar al módulo “Configurar Examen”.</td> <td>2. El sistema mostrará la página “Configurar Examen”, con el campo “NumeroDisparos” el cual tendrá por predeterminado 5. Y un botón “Guardar Configuración”, el cual guardara la modificación al número de disparos para los exámenes de disparo. Flujo Alternativo</td> </tr> <tr> <td>3. El operador visualizará la página y podrá realizar las modificaciones respectivas de manera general para todos los tiradores.</td> <td></td> </tr> </tbody> </table>		Operador	Sistema	1. El operador en el dashboard principal del sistema, deberá ingresar al módulo “Configurar Examen”.	2. El sistema mostrará la página “Configurar Examen”, con el campo “NumeroDisparos” el cual tendrá por predeterminado 5. Y un botón “Guardar Configuración”, el cual guardara la modificación al número de disparos para los exámenes de disparo. Flujo Alternativo	3. El operador visualizará la página y podrá realizar las modificaciones respectivas de manera general para todos los tiradores.	
Operador	Sistema							
1. El operador en el dashboard principal del sistema, deberá ingresar al módulo “Configurar Examen”.	2. El sistema mostrará la página “Configurar Examen”, con el campo “NumeroDisparos” el cual tendrá por predeterminado 5. Y un botón “Guardar Configuración”, el cual guardara la modificación al número de disparos para los exámenes de disparo. Flujo Alternativo							
3. El operador visualizará la página y podrá realizar las modificaciones respectivas de manera general para todos los tiradores.								
Flujo Alternativo	<table border="1"> <thead> <tr> <th colspan="2">Si el operador desea modificar algún valor</th> </tr> <tr> <th>Operador</th> <th>Sistema</th> </tr> </thead> <tbody> <tr> <td>3. El operador selecciona el campo que desea modificar (Numero de Disparos), y modifica al valor que desee, y oprime el botón “Guardar”.</td> <td>4. El sistema guarda los cambios realizados y los almacena de manera general. Vuelve al Flujo Principal.</td> </tr> </tbody> </table>		Si el operador desea modificar algún valor		Operador	Sistema	3. El operador selecciona el campo que desea modificar (Numero de Disparos), y modifica al valor que desee, y oprime el botón “Guardar”.	4. El sistema guarda los cambios realizados y los almacena de manera general. Vuelve al Flujo Principal.
Si el operador desea modificar algún valor								
Operador	Sistema							
3. El operador selecciona el campo que desea modificar (Numero de Disparos), y modifica al valor que desee, y oprime el botón “Guardar”.	4. El sistema guarda los cambios realizados y los almacena de manera general. Vuelve al Flujo Principal.							
Postcondición	El operador guarda los cambios realizados y vuelve al Dashboard principal o navega a otros módulos.							

Fase de elaboración

Diagrama de arquitectura del sistema




Diagrama de clases

Diagrama de clases del reconocimiento facial

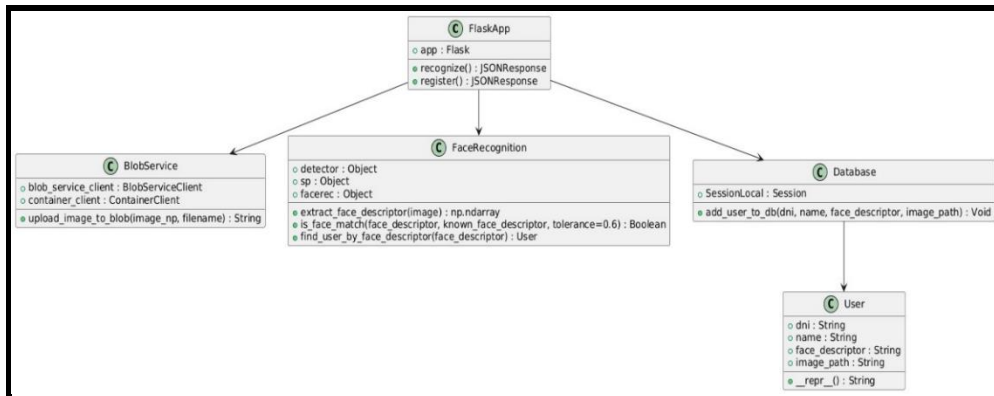


Diagrama de clases administrador




Diagrama de clases evaluación de disparo




Diagrama de clases tirador

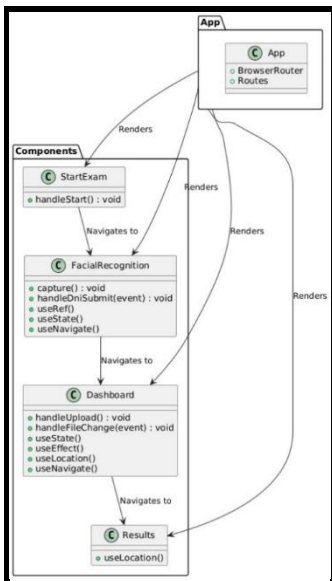


Diagrama modelo entidad relación




Diagrama de componentes

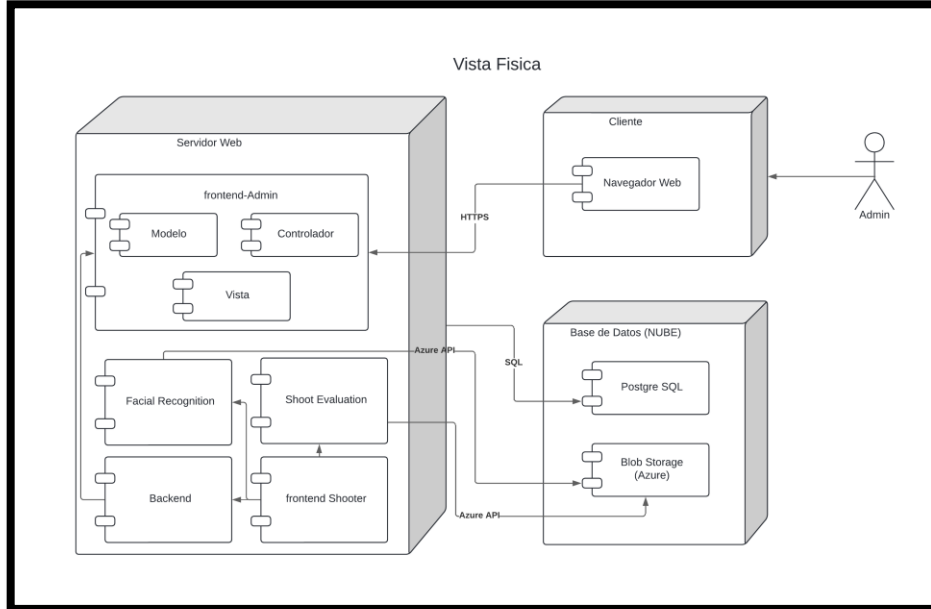


Diagrama de paquetes




Diagrama de despliegue




Diagrama de secuencia

Diagrama de secuencia – iniciar sesión

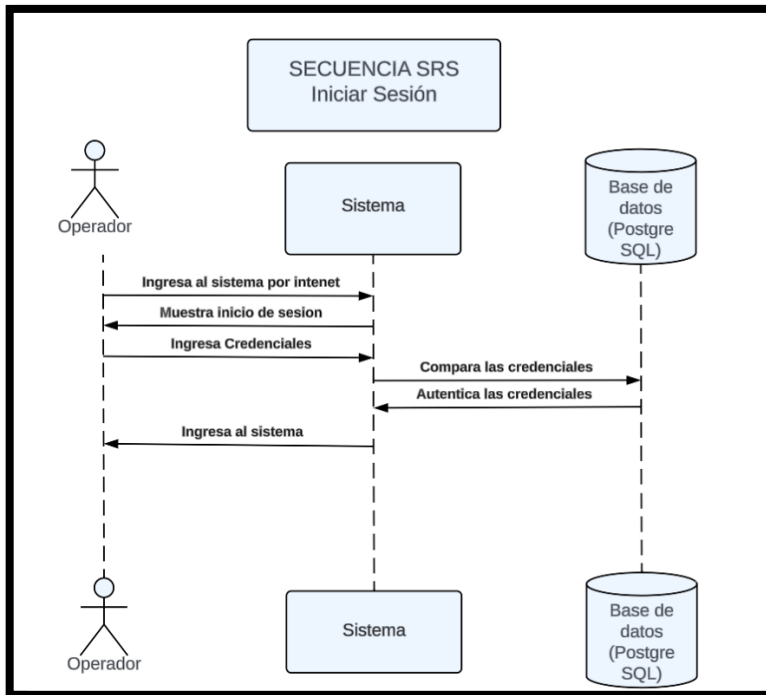


Diagrama de secuencia – registrar tirador

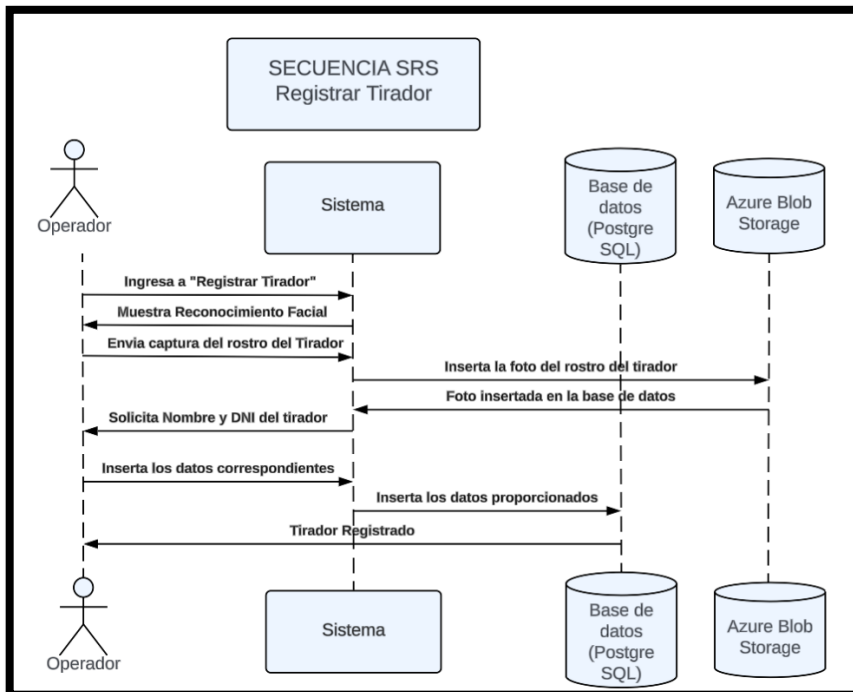


Diagrama de secuencia – evaluar examen de disparo

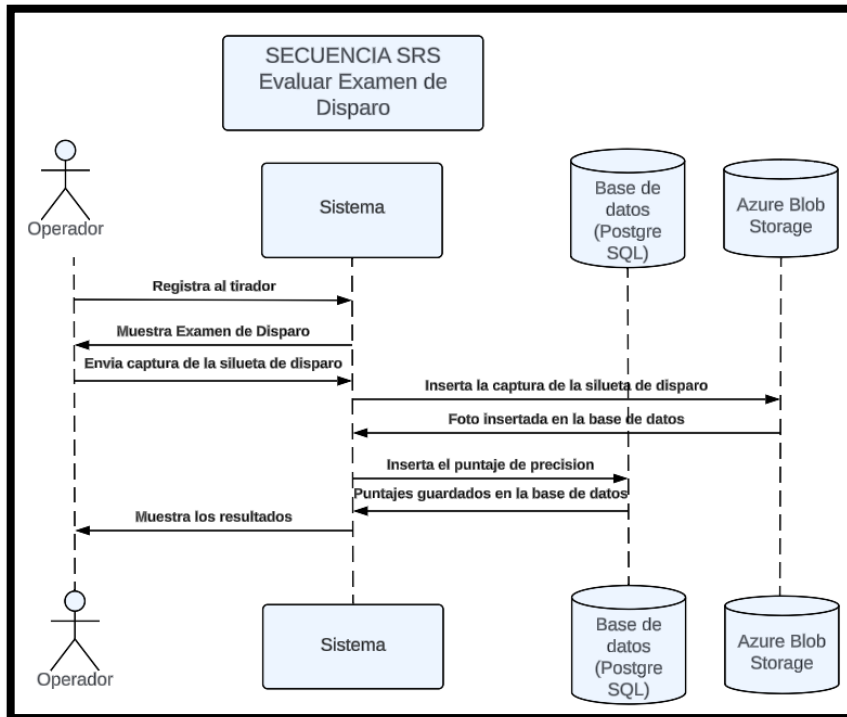


Diagrama de secuencia – visualizar dashboard

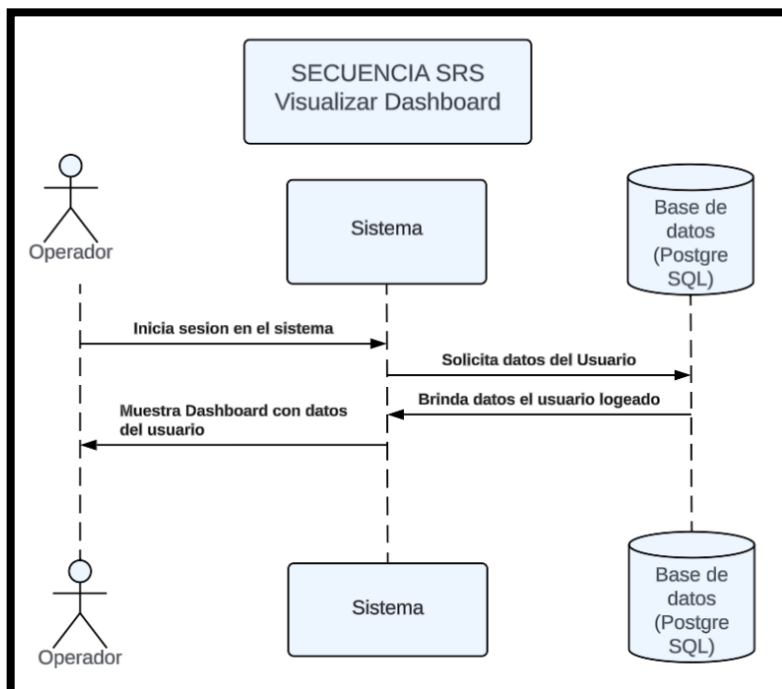


Diagrama de secuencia – generar reporte

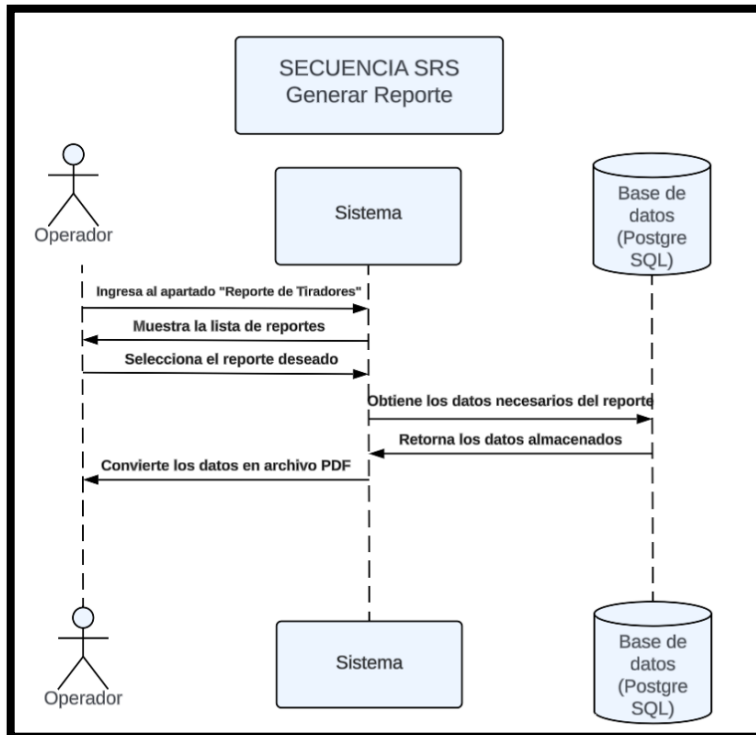


Diagrama de secuencia – visualizar reporte de tiradores

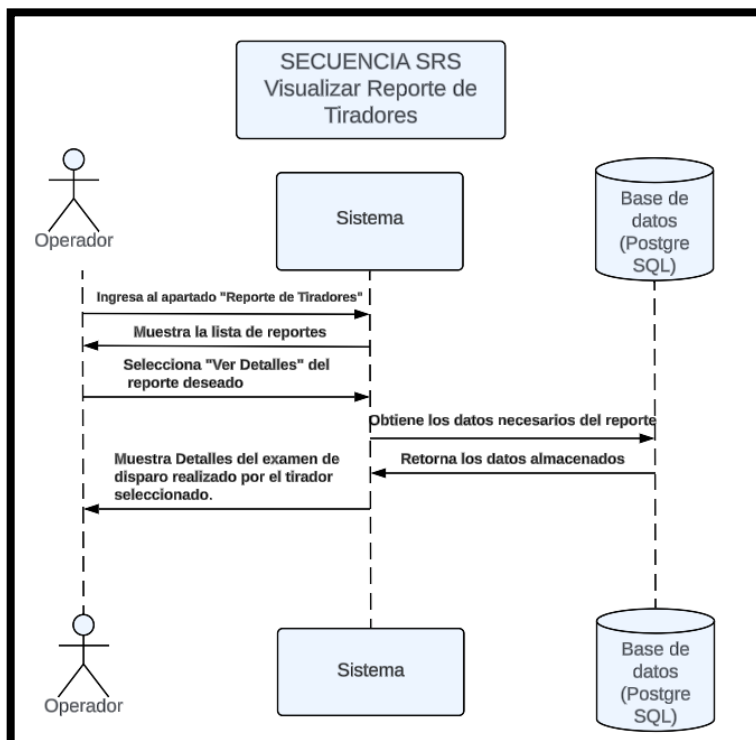
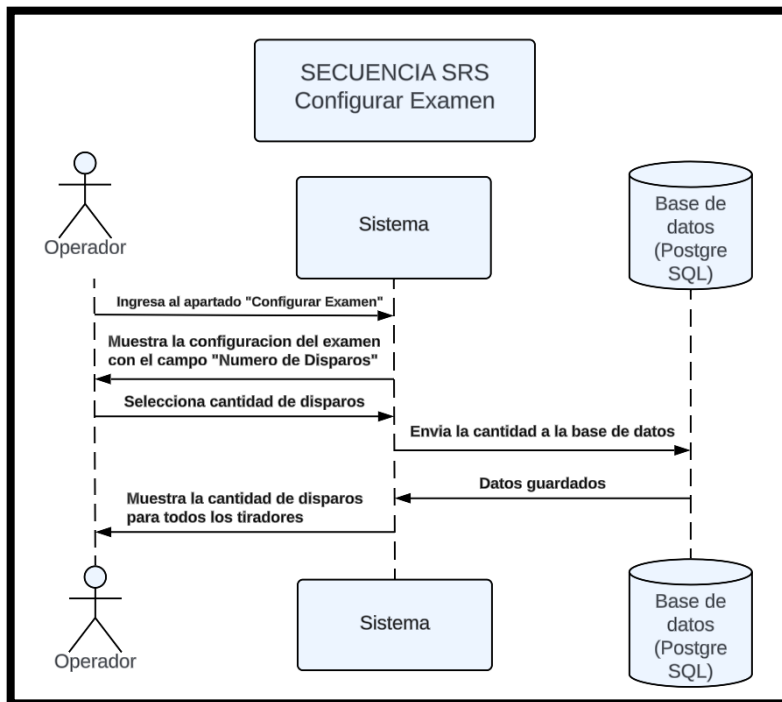


Diagrama de secuencia – configurar examen




Interfaces de usuario

Interfaz página principal



Interfaz página de reconocimiento facial del tirador



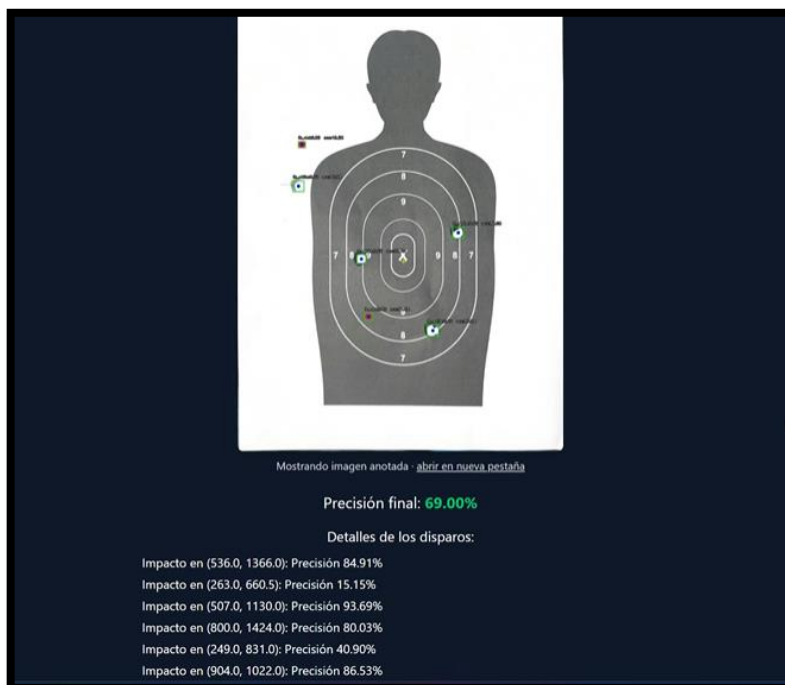
Interfaz página de examen del tirador





Nota. Elaboración Propia


Interfaz página de resultados de examen



Nota. Elaboración Propia

Interfaz página de inicio de sesión

← Volver al inicio




Iniciar Sesión

Ingresa a tu cuenta para acceder al sistema

Correo

Contraseña



Recordarme ¿Olvidaste tu contraseña?

[→ Iniciar Sesión](#)

[¿No tienes una cuenta?](#)

[Crear una cuenta nueva](#)

Al iniciar sesión, aceptas nuestros [Términos de Servicio](#) y [Política de Privacidad](#).

Interfaz página de dashboard de administrador

Sistema PNP

Inicio

Configurar Examen

Tiradores

Reportes

Registrar Tirador

Panel de Control

Tiradores Registrados

2

Exámenes Realizados

4

Reportes Generados

4

Procción Promedio

69%

Acciones Rápidas

Configurar Examen

Establece parámetros para el examen

Ver Tiradores

Gestiona tiradores registrados

Generar Reportes

Consulta resultados y métricas

Registrar Tirador

Agrega nuevo tirador al sistema

Actividad Reciente

- Reporte generado: Adam Sandler (ID 56) 20/02/2025, 3:29:23 p. m.
- Reporte generado: Keanu Reeves (ID 55) 20/02/2025, 3:28:14 p. m.
- Reporte generado: Keanu Reeves (ID 54) 20/02/2025, 3:13:33 p. m.
- Reporte generado: Keanu Reeves (ID 53) 20/02/2025, 3:09:23 p. m.

Interfaz página de configurar examen

Sistema PNP

Inicio

Configurar Examen

Tiradores

Reportes

Registrar Tirador

Configurar Examen

Número de Disparos

6


Valor actual en el servidor: 6

Guardar Configuración

Recargar

Interfaz página de tiradores

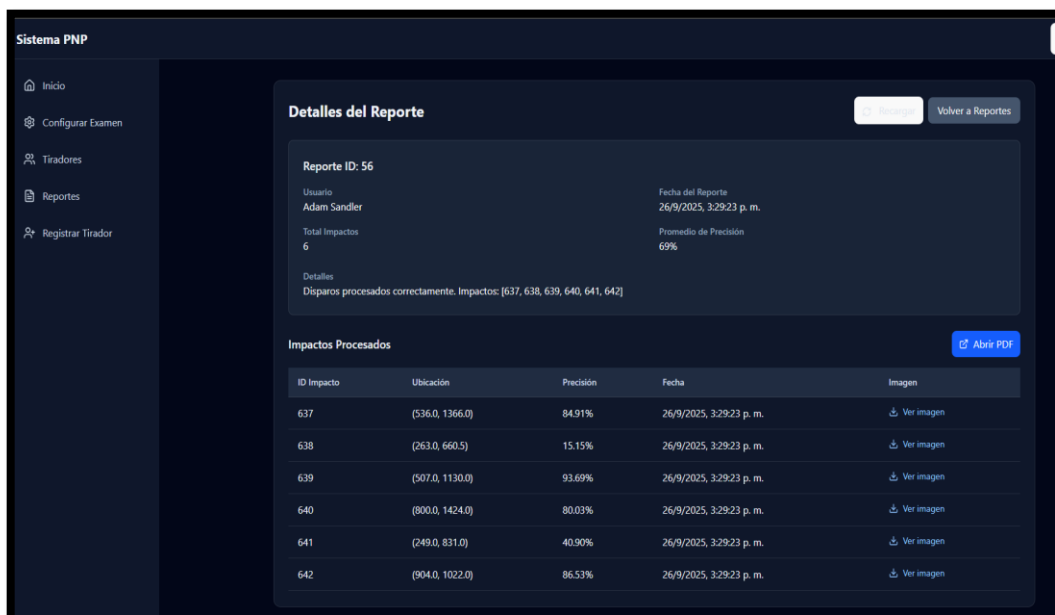
Figura 1.




Interfaz página de reportes



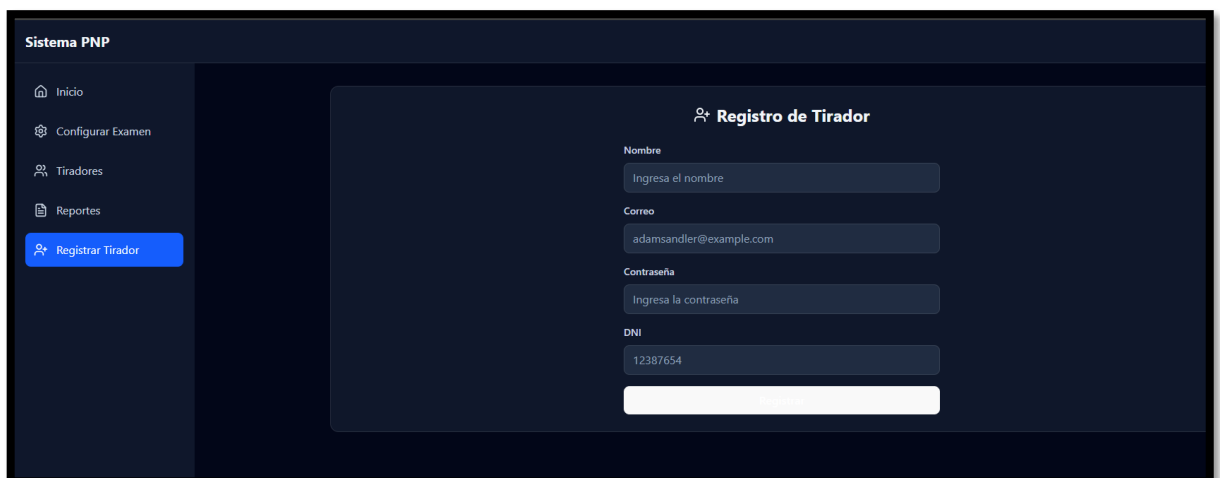
Interfaz página de detalles del reporte



Interfaz PDF de detalles del reporte



Interfaz página de registrar tirador



Anexo 7. Repositorio del proyecto

El código fuente del proyecto "SISTEMA WEB PARA LA DETECCIÓN DE IMPACTOS DE BALA EN PRÁCTICAS DE DISPARO MEDIANTE DEEP LEARNING" ha sido publicado de manera parcial en el siguiente repositorio de GitHub.

URL del Repositorio: https://github.com/FarleyViveros/Deteccion_Impactos_Bala

Esta decisión se toma en estricto respeto al Acuerdo de Confidencialidad establecido con la Dirección de Investigación y Prevención de Robo de Vehículos (DIPROVE) de Tacna, institución beneficiaria del sistema. Sin embargo, para fines estrictamente de investigación, validación metodológica o replicabilidad exhaustiva, cualquier profesional o investigador interesado puede solicitar el acceso completo mediante el siguiente canal de contacto:

Contacto: Bach. Farley Rodrigo Eduardo Viveros Blanco

Correo electrónico: farviv123@gmail.com

Asunto: Solicitud de Código Fuente – Tesis Detección de Impactos de Bala

Cuerpo del mensaje: El solicitante deberá especificar sus datos personales, la finalidad académica y su institución de procedencia.

Una vez recibida la solicitud formal, los autores del sistema se pondrán en contacto directo con el jefe de la DIPROVE de Tacna para validar la identidad y la finalidad del requerimiento. La autorización para la entrega del código completo estará sujeta a la aprobación de dicha jefatura.