



Esta obra está bajo una
[Licencia Creative Commons
Atribución - 4.0 Internacional \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)

Vea una copia de esta licencia en
<https://creativecommons.org/licenses/by/4.0/deed.es>





FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

Tesis

Detección no invasiva de la anemia ferropénica mediante reconocimiento de imágenes de la palma de la mano

Para optar el título profesional de Ingeniero de Sistemas e Informática

Autor:

Pool Antony Valles Saavedra
<https://orcid.org/0009-0000-9466-4489>

Asesor:

Ing. Dr. Miguel Ángel Valles Coral
<https://orcid.org/0000-0002-8806-2892>

Co-asesor:

Ing. Lloy Pool Pinedo Tuanama
<https://orcid.org/0000-0002-5569-8739>

Tarapoto, Perú

2025



FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

Tesis




Detección no invasiva de la anemia ferropénica mediante reconocimiento de imágenes de la palma de la mano

Para optar el grado académico de Ingeniero de Sistemas e Informática

Presentado por

Pool Antony Valles Saavedra

Sustentado y aprobado el 21 de marzo del 2025, por los siguientes jurados:

 Presidente de Jurado Lic. Dr. Wilson Torres Delgado	 Secretario de Jurado Ing. Mg. Juan Orlando Riascos Armas
 Vocal de Jurado Ing. Mg. Richard Enrique Injante Oré	
 Asesor Ing. Dr. Miguel Ángel Valles Coral	 Coasesor Ing. Lloy Pool Pinedo Tuanama
Tarapoto, Perú	
2025	



Universidad Nacional de San Martín
Facultad de Ingeniería de Sistema e Informática
Ciudad Universitaria - Jr. Amorarca # 315 - Morales



**ACTA DE SUSTENTACIÓN
PARA OPTAR EL TÍTULO DE INGENIERO DE SISTEMAS E INFORMÁTICA**

Resolución N° 010-2025-UNSM/FISI-D (19.03.2025)

FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA – ESCUELA PROFESIONAL DE
INGENIERÍA DE SISTEMAS E INFORMÁTICA

A las 11:00 horas del día Viernes, 21 de marzo del año 2025, se inició el acto público de sustentación de la tesis titulada DETECCIÓN NO INVASIVA DE LA ANEMIA FERROPÉNICA MEDIANTE RECONOCIMIENTO DE IMÁGENES DE LA PALMA DE LA MAN.; presentado por POOL ANTONY VALLES SAAVEDRA, con el Asesor: Ing. Dr. Miguel Ángel Valles Coral y el Coasesor: Ing. Lloy Pool Pinedo Tuanama.

Instalado los miembros de jurado calificador conformado por:

Presidente : Lic. Dr. WILSON TORRES DELGADO
Secretario : Ing. Dr. JUAN ORLANDO RIASCOS ARMAS
Vocal : Ing. Mg. RICHARD ENRIQUE INJANTE ORÉ

El presidente del jurado dirigió brevemente unas palabras y a continuación el secretario dio lectura a la Resolución N° 010-2024-UNSM/FISI-D.

Seguidamente el autor expuso el trabajo de investigación y el jurado realizó las preguntas pertinentes, respondidas por el sustentante y eventualmente por el asesor, con la venia del jurado.

Una vez terminada la ronda de preguntas el jurado procedió a deliberar para determinar la calificación final, para lo cual dispuso un receso de quince (15) minutos, con participación del asesor con voz, pero sin voto y sin la presencia del sustentante y otros participantes del acto público.

Luego de aplicar los criterios de calificación con estricta observancia del principio de objetividad y de acuerdo con los puntajes en escala vigesimal (de 0 a 20), según el Anexo 4.2. del RG-CTI, la nota de sustentación otorgada resultante del promedio aritmético de los calificativos emitidos por cada uno de los miembros del jurado fue *Dieciocho..... (18)*.

De acuerdo con el Artículo 40° del RG – CTI, la nota obtenida es *..... Aprobado.....* y correspondiente a la calificación de *... Muy buena...;* leído este resultado en presencia de todos los participantes del acto de sustentación, el secretario dio lectura a las observaciones subsanables al informe final que el autor deberá corregir y alcanzar al jurado en un plazo máximo de treinta (30) días calendario.



Universidad Nacional de San Martín
Facultad de Ingeniería de Sistema e Informática
Ciudad Universitaria - Jr. Amorarca # 315 - Morales



Firman los integrantes del jurado calificador, asesor y el autor de la tesis en señal de conformidad, dando por concluido el acto a las 12:00 horas, el mismo día 21 de marzo del 2025.

Lic. Dr. **WILSON TORRES DELGADO**
Presidente

Ing. Dr. **JUAN ORLANDO RIASCOS**
ARMAS
Secretario

Ing. Mg. **RICHARD ENRIQUE INJANTE**
ORÉ
Vocal

Ing. Dr. **MIGUEL ÁNGEL VALLES**
CORAL
Asesor

Ing. **LLOY POOL PINEDO TUANAMA**
Co asesor

POOL ANTONY VALLES SAAVEDRA
Autor

Declaratoria de autenticidad

Pool Antony Valles Saavedra, con DNI N° **76432472**, egresado de la Escuela Profesional de Ingeniería de Sistemas e Informática, Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de San Martín, autor de la tesis titulada: **Detección no invasiva de la anemia ferropénica mediante reconocimiento de imágenes de la palma de la mano.**

Declarajo bajo juramento que:

1. La tesis presentada es de nuestra autoría.
2. La redacción fue realizada respetando las citas y referencia de las fuentes bibliográficas consultadas
3. Toda información que contiene la tesis no ha sido plagiada;
4. Los datos presentados en los resultados son reales, no han sido alterados ni copiados, por tanto, la información de esta investigación debe considerarse como aporte a la realidad investigada.

Por lo antes mencionado, asumimos bajo responsabilidad las consecuencias que deriven de mi accionar, someténdome a las leyes de nuestro país y normas vigentes de la Universidad Nacional de San Martín.

Tarapoto, 21 de marzo del 2025



Pool Antony Valles Saavedra
DNI N° 76432472

Ficha de identificación

Título del proyecto Detección no invasiva de la anemia ferropénica mediante reconocimiento de imágenes de la palma de la mano	Área de investigación: Línea de investigación: Estrategia de tecnología de información y comunicación (TIC) Sublínea de investigación: Inteligencia Artificial y recuperación de información Grupo de investigación (indicar resolución): Tipo de investigación: Básica <input type="checkbox"/> , Aplicada <input checked="" type="checkbox"/> , Desarrollo experimental <input type="checkbox"/>
Autor: Pool Antony Valles Saavedra	Facultad de Ingeniería de Sistemas e Informática Escuela Profesional de Ingeniería de Sistemas e Informática https://orcid.org/0009-0000-9466-4489
Asesor: Ing. Dr. Miguel Ángel Coral Valles	Dependencia local de soporte: Facultad de Ingeniería de Sistemas e Informática Escuela Profesional de Ingeniería de Sistemas e Informática Unidad o Laboratorio Ingeniería de Sistemas e Informática https://orcid.org/0000-0002-8806-2892
Coasesor: Ing. Lloy Pool Pinedo Tuanama	Contraparte científica: Facultad o Institución: RENACYT Unidad o Laboratorio: País: Perú https://orcid.org/0000-0002-5569-8739

Dedicatoria

A Dios, quien ha sido mi guía y fortaleza en cada paso de este camino.

A mi madre, Mabel Saavedra Rojas, una mujer fuerte, valiente y luchadora, cuya entrega y amor incondicional han sido la base de mi vida. Gracias, mamá, por enseñarme con tu ejemplo y ser siempre el pilar firme en los momentos difíciles.

A mi padre, Jack Tello, tu presencia constante, cuidado y apoyo desde mi infancia me han demostrado el valioso ser humano que Dios puso en mi camino. No puedo estar más agradecido de poder llamarte papá con tanto orgullo.

Agradecimientos

Esta investigación es una prueba de que lo que alguna vez fue imposible ahora es alcanzable. Como diría Alan Turing: “Los que pueden imaginar cualquier cosa, pueden crear lo imposible.”

A la ciencia, que constantemente desafía los límites de lo conocido, y a mi familia, que ha sido mi pilar de apoyo e inspiración en cada paso de este camino.

A mi asesor, Miguel Ángel Valles Coral, cuyas enseñanzas, motivación y orientación han sido fundamentales en la realización de esta tesis. También agradezco al increíble equipo que me acompañó durante la recolección de datos; su apoyo ha sido invaluable.

Índice general

Ficha de identificación.....	6
Dedicatoria	7
Agradecimientos	8
Índice general.....	9
Índice de tablas	11
Índice de figuras.....	12
RESUMEN	13
ABSTRACT	14
CAPÍTULO I INTRODUCCIÓN A LA INVESTIGACIÓN	15
CAPÍTULO II MARCO TEÓRICO	18
2.1. Antecedentes de la investigación.....	18
2.2. Fundamentos teóricos.....	19
CAPÍTULO III MATERIALES Y MÉTODOS	24
3.1. Ámbito y condiciones de la investigación	24
3.1.1. Contexto de la investigación.....	24
3.1.2. Periodo de ejecución	24
3.1.3. Autorizaciones y permisos.....	24
3.1.4. Control ambiental y protocolos de bioseguridad.....	24
3.1.5. Aplicación de principios éticos internacionales	24
3.2. Sistema de variables	25
3.3. Procedimientos de la investigación.....	25
3.3.1. Actividades del objetivo específico 1.....	25
3.3.2. Actividades del objetivo específico 2.....	30
3.3.3. Actividades del objetivo específico 3.....	31
CAPÍTULO IV RESULTADOS Y DISCUSIÓN	34
4.1. Resultados del Objetivo específico 1	34
4.2. Resultados del Objetivo específico 2.....	34

4.3. Resultados del Objetivo específico 3.....	41
CONCLUSIONES	54
RECOMENDACIONES	55
REFERENCIAS BIBLIOGRÁFICAS	56
ANEXOS.....	61

Índice de tablas

Tabla 1 Métricas de rendimiento organizados por modelo.	46
Tabla 2 Resultados de la prueba ANOVA de un factor.....	48
Tabla 3 Resultados de la prueba de Tukey (Post hoc)	48
Tabla 4 Estadísticos descriptivos de los datos comparados	52

Índice de figuras

Figura 1 Maquetas	27
Figura 2 Reunión con especialistas.....	27
Figura 3 Dispositivo no invasivo para detección de la anemia	28
Figura 4 Recolección de imágenes palmares	28
Figura 5 Recolección de información clínica.....	29
Figura 6 Espacio de recolección.....	29
Figura 7 Grupo encargado de recolección	30
Figura 8 Gráfico de distribución de participantes según el grado de anemia.....	36
Figura 9 Matriz de correlación entre dimensiones del set de datos	37
Figura 10 Gráfico de distribución de participantes según el grado de anemia ajustado al índice participante – archivo	38
Figura 11 Gráficos de la evolución del entrenamiento según métrica de rendimiento .	40
Figura 12 Gráfica de la evolución en el entrenamiento del modelo ResNet50	44
Figura 13 Gráfica de la evolución en el entrenamiento del modelo EfficientNetB0	44
Figura 14 Gráfica de la evolución en el entrenamiento del modelo InceptionV3	44
Figura 15 Resultado de la prueba de validación rápida al modelo YOLO11.....	45

RESUMEN

Detección no invasiva de la anemia ferropénica mediante reconocimiento de imágenes de la palma de la mano

La detección de la anemia ferropénica tiene muchas complicaciones tanto por lo procesos que se llevan a cabo para determinar su nivel en sangre, esto con respecto a los métodos tradicionales invasivos que se utilizan para que esta enfermedad sea detectada, haciendo uso de jeringas, agujas y sofisticados laboratorios, dicho análisis tiene distintos tipos de complicaciones ya que pueden presentarse riesgos de infección, dolor y alergia. Por tanto, esta investigación propone desarrollar un modelo de Deep Learning con imágenes de la palma de la mano para medir los niveles Hb en sangre proporcionando un método no-invasivo. Para ello, se realizará un estudio de aplicativo, nivel experimental-factorial. La muestra corresponderá a 930 estudiantes de la Universidad Nacional de San Martín de las cuales el 80% será para el entrenamiento y 20% para las pruebas del modelo. Así mismo, se realizará una campaña para realizar el testeo del modelo y su proximidad optima frente a los resultados obtenidos por un dispositivo no invasivo que se utilizará para saber los niveles de Hb de los estudiantes y poder realizar un etiquetado de las muestras. Para responder la hipótesis y los objetivos de la investigación, se empleará estadística descriptiva e inferencial, de donde se espera conocer la precisión del modelo frente al dispositivo no invasivo. Por otro lado, el desarrollo del modelo será bajo la metodología scrum, para garantizar la mayor efectividad durante del preprocesamiento. Finalmente, esta investigación busca contribuir en la salud de la sociedad frente a métodos invasivos que también suelen ser costosos para una cierta parte de la población.

Palabras clave: Anemia ferropénica, Detección, No invasiva, Reconocimiento de imágenes

ABSTRACT

Noninvasive detection of iron deficiency anemia using palm image recognition

The detection of iron deficiency anemia has many complications due to the procedures that are carried out to determine its level in blood, this regarding the traditional invasive methods that are used for this disease to be detected, using syringes, needles and sophisticated laboratories, such analysis has different types of complications as there may be risks of infection, pain and allergy. Therefore, this research proposes to develop a Deep Learning model with images of the palm of the hand to measure Hb levels in blood by providing a non-invasive method. For this purpose, an applicative, experimental-factorial study was carried out. The sample included 930 students from the Universidad Nacional de San Martín, of which 80% were for training and 20% for testing the model. Likewise, a campaign was carried out to test the model and its optimal proximity to the results obtained by a non-invasive device used to determine the Hb levels of the students and to label the samples. To answer the hypothesis and objectives of the research, descriptive and inferential statistics were used, from which it is expected to identify the accuracy of the model against the non-invasive device. On the other hand, the development of the model was carried out under the scrum methodology, in order to guarantee the highest effectiveness during the preprocessing. Finally, this research aims to contribute to the health of society in the face of invasive methods that are also usually expensive for a certain part of the population.

Keywords: Iron deficiency anemia, detection, noninvasive, image recognition.



CAPÍTULO I

INTRODUCCIÓN A LA INVESTIGACIÓN

El presente trabajo de investigación contiene un nivel elevado de importancia dada a la necesidad de encontrar nuevas formas de tratar con problemas de salud pública como la anemia ferropénica, aplicando nuevas tecnologías con el uso del aprendizaje automático. La anemia una condición médica global, (Randi et al., 2020) siendo así uno de los problemas que afecta a todas las edades y regiones del mundo, (Saputra et al., 2023).

Los métodos invasivos tradicionales para bien son efectivos, pero requieren mucho tiempo y trabajo de personal calificado, (Ferdousi et al., 2022) así mismo los riesgos al aplicar este procedimiento pueden llegar a ser altos tales como infecciones, hematomas, desmayos y daños en los nervios o vasos sanguíneos.

Los niveles séricos de hemoglobina varían comúnmente en mujeres gestantes, ello se identifica por una disminución en la cantidad de eritrocitos o en la concentración de hemoglobina en la sangre, (Arredondo-Nontol & Arredondo-Nontol, 2020) La hemoglobina es una molécula presente en los eritrocitos que se encarga de transportar oxígeno desde los pulmones hasta los diferentes tejidos del cuerpo (Vu et al., 2021). Una disminución en los niveles de hemoglobina puede resultar en una reducción en la capacidad del cuerpo para transportar oxígeno, lo que puede causar una variedad de síntomas como fatiga, debilidad muscular, mareo, disnea y palpitaciones.

La anemia causada por una variedad de agentes, como la falta de hierro, la deficiencia de vitamina B12, enfermedades crónicas, infecciones y trastornos genéticos. La Organización Mundial de la Salud ha determinado que la anemia impacta a una cifra superior a los 2.200 millones de personas en todo el planeta (Dimauro et al., 2023). lo que la convierte en uno de los problemas médicos más habitual en el mundo entero. Además, se ha encontrado que la anemia es más prevalente en ciertos grupos de la población, como las mujeres circunstancia de embarazo y los niños en desarrollo, y puede tener consecuencias graves si no se trata adecuadamente (Jung et al., 2019).

Un elevado número de personas son afectadas por la anemia, lo que la convierte en un problema de salud pública, especialmente a niños y mujeres. Según el Instituto Nacional de Estadística e Informática (INEI), en 2020 el 38,8% de niños menores de 3 a 35 meses y el 18,8% de mujeres en edad fértil 15 a 49 años presentaron anemia (INEI, 2022). Hay una falta de soluciones efectivas y sostenibles para prevenir y tratar la anemia, a pesar de los esfuerzos del gobierno peruano. Los jóvenes universitarios van a ser parte de un

conjunto de datos para ser validados debido a que son vulnerables a la deficiencia de hierro (Mitani et al., 2019) esto debido a diferentes causantes.

Según un estudio realizado en la Universidad Nacional de Educación con la especialidad de Biología de la Facultad de Ciencias, menciona que el 14,6% de los universitarios presentaban anemia ferropénica (Foy Valencia et al., 2022). Se ha identificado un vacío en el análisis de imágenes de manos para la detección de deficiencia de hierro en estudiantes universitarios, a pesar de que se han desarrollado algunas soluciones utilizando técnicas de aprendizaje automático (Jaiswal et al., 2019).

De acuerdo con la realidad descrita, el problema de investigación formulado es: ¿Cómo se puede desarrollar un método de detección no invasiva de la anemia ferropénica utilizando imágenes de la palma de la mano para mejorar la eficiencia y precisión del diagnóstico? Para rebatir dicho problema se ha propuesto el siguiente objetivo general “Detectar la anemia ferropénica basado en un modelo de visión artificial como método no invasivo utilizando imágenes de la palma de la mano” desarrollando los siguientes objetivos específicos: Realizar campaña de recolección de imágenes de la palma de la mano, junto a información clínica relevante obtenida por el dispositivo no invasivo, desarrollar un modelo de Deep Learning para la clasificación de imágenes de la palma de la mano según los niveles de hemoglobina en sangre, Comparar y evaluar las métricas de rendimiento del modelo propuesto y las de otros tres modelos existentes. Para ello, se tuvo como hipótesis la existencia de una correlación significativa entre las características identificadas en las imágenes de la palma y la presencia de anemia por deficiencia de hierro, lo que sugiere que el reconocimiento de patrones basado en imágenes es un método eficiente y preciso para detectar de forma no invasiva la anemia.

El presente estudio se basa en los parámetros exigidos por la UNSM, de modo que contiene la siguiente estructura:

El capítulo I, titulado Introducción a la investigación, expone el contexto de la problemática estudiada. A partir de la identificación del problema y sus causas, se plantean la hipótesis del estudio y los objetivos, tanto generales como específicos.

El capítulo II, denominado Marco teórico, se analizan los antecedentes nacionales e internacionales relacionados con la temática, los cuales respaldan la hipótesis y objetivos planteados. Además, se desarrolla el marco teórico, que incluye información especializada para fundamentar tanto los conocimientos como la metodología aplicada.

El capítulo III, titulado Materiales y métodos, aborda el contexto de la investigación, describe el sistema de variables y detalla los procedimientos empleados.

En el capítulo IV, llamado Resultados y discusión, se presentan los resultados obtenidos, seguidos de un análisis detallado basado en los objetivos específicos y las variables correspondientes. Finalmente, se incluyen las conclusiones, que responden a los objetivos planteados, las recomendaciones derivadas de dichas conclusiones, cerrando así con las referencias bibliográficas y anexos obtenidos durante el proceso del estudio.

CAPÍTULO II

MARCO TEÓRICO

2.1. Antecedentes de la investigación

En India, Kesarwani et al. 2023 Proponen un sistema de detección no invasiva de la anemia que combina enfoques computacionales avanzados con la observación de la palidez en la palma de la mano. El sistema se basa en inducir cambios en la palidez de la palma mediante la aplicación y liberación de presión adecuada, y luego se mide la tasa de cambio de color. Por ello, capturan un video de los cambios de color en la palma utilizando la cámara de un smartphone, y posteriormente se procesó y analizó utilizando técnicas de procesamiento de imágenes. Los parámetros estimados que utilizaron como entrada para modelos de predicción basados en ensambles, incluyendo regresión y perceptrón multicapa. Los resultados obtenidos determinan una sensibilidad del 93% en la detección de anemia, con un MSE y RMSE de 0.701 y 0.698 respectivamente.

En Ghana, Appiahene et al. 2023 se abordan el problema global de la anemia en niños y mujeres embarazadas. aplicando el método en tres fases, que incluyó la recolección de conjuntos de datos de la palma de la mano, el preprocesamiento de imágenes mediante extracción y aumento de imágenes, y la segmentación de la Región de Interés. Se desarrollaron modelos de detección de anemia utilizando algoritmos como CNN, k-NN, Naïve Bayes, SVM y Árbol de Decisiones. Se utilizaron 527 imágenes iniciales, que se aumentaron hasta 2635 mediante rotación, volteo y traslación. Los resultados mostraron que el algoritmo Naïve Bayes alcanzó una precisión del 99.96%, mientras que SVM obtuvo la menor precisión con un 96.34%. Por su parte, CNN demostró un buen desempeño con una precisión del 99.92% en la detección de la anemia utilizando la palma de la mano.

En Malasia, (Xinming, Hong, b.Mohd Ariffin, et al., 2023) La agricultura enfrenta desafíos por el aumento poblacional y la demanda de alimentos, que exigen a los agricultores incrementar la producción. Este estudio compara dos algoritmos de visión por computadora, YOLOv4 y YOLOv7, para clasificar enfermedades en hojas de plantas a partir de imágenes. Los modelos se entrenaron con fotos de hojas en diversos entornos, logrando alta precisión y confiabilidad en la identificación de enfermedades. Aunque ambos modelos muestran buenos resultados, YOLOv7 destaca por su capacidad de aprendizaje dinámico de etiquetas, lo cual mejora su desempeño. Este enfoque podría ampliarse para predecir la anemia con imágenes de la palma de la mano.

Para mejorar la detección de enfermedades en papaya, este estudio presenta un conjunto de datos recolectado en Dhaka, Bangladesh, (Mustofa et al., 2024a) con 2159 imágenes originales en cinco clases: una clase de control (sano) y cuatro enfermedades en hojas (Antracnosis, Mancha Bacteriana, Rizado y Mancha Anular). Este conjunto incluye imágenes completas y anotadas, útiles para modelos de detección de enfermedades mediante redes neuronales convolucionales (CNN) y técnicas de segmentación semántica como YOLO, U-Net y Mask R-CNN. Además, puede aplicarse en dispositivos y aplicaciones AI.

Este estudio propone un modelo híbrido basado en YOLOv5 y ResNet50 para clasificar y localizar tumores en imágenes histopatológicas, resaltando características relevantes para ayudar a los médicos. YOLOv5 localiza el tumor en imágenes de diapositivas completas, mientras que ResNet50 realiza la extracción de características. Luego, un clasificador de *extreme gradient boosting* estima los grados de glioma, logrando un 97.2% de precisión, 97.8% de exactitud, 98.6% de sensibilidad y un coeficiente dice del 97%. Estos resultados superan los métodos estándar para diferenciar gliomas de bajo y alto grado y mejoran la clasificación en cuatro categorías, (Elazab et al., 2024a).

En Malasia (Ashani et al., 2025) el contexto digital actual, la difusión de imágenes y videos manipulados, o *deepfakes*, representa un desafío creciente. Este estudio explora el uso de Inteligencia Artificial (IA) para detectar *deepfakes*, empleando tres redes neuronales convolucionales (CNN): VGG16, VGG19 y ResNet50. Con un conjunto de datos de 1,200 imágenes (reales y falsas, generadas con FaceApp), se evaluó el rendimiento de cada modelo, encontrando que VGG19 alcanzó un 98% de precisión en detección. Estos resultados destacan la efectividad de VGG19 y su potencial para fortalecer sistemas de detección de *deepfakes* en redes sociales.

2.2. Fundamentos teóricos

2.2.1. Anemia Ferropénica

Principal síndrome que se distingue por la disminución en la producción de glóbulos rojos debido a una carencia de hierro ocasionada por un desequilibrio entre la ingesta (absorción de alimentos) y la pérdida de este mineral (hemorragia), así como una reducción en su asimilación por los glóbulos rojos en formación. La carencia de hierro, el problema nutricional más prevalente en los seres humanos esta se considera generalmente como el resultado de una falta de nutrientes en la dieta. Sin embargo, la anemia por carencia de hierro no es infrecuente en personas cuyas dietas contienen cantidades de hierro cercanas a las recomendadas (Gándara-Santiago, 2020).

2.2.2. Clasificación de la Anemia Ferropénica (Alegría Guerrero et al., 2019)

a) Anemia Leve: Las personas con anemia leve suelen no presentar síntomas evidentes, aunque es posible que experimenten fatiga, somnolencia, dificultad para respirar y palpitaciones, especialmente después de realizar ejercicio. Un aspecto relevante es la disminución del apetito, lo cual tiene un impacto negativo en la nutrición de la persona. Se considera anemia leve cuando los niveles de hemoglobina en sangre se sitúan entre 11 y 11.5 gr/dl.

b) Anemia Moderada: Con frecuencia, las personas que sufren de anemia moderada experimentan síntomas incluso en estado de reposo, y tienen dificultades para tolerar esfuerzos considerables. Los individuos pueden notar un estado de hiperdinámico y manifestar palpitaciones como síntoma. Además, la disminución del apetito es más pronunciada, y la palidez se presenta como un signo físico característico en este tipo de anemia. Los niveles de hemoglobina que se consideran dentro del rango de anemia moderada oscilan entre 8 y 10.9 gr/dl.

c) Anemia Severa: Los síntomas asociados a este tipo de anemia afectan a múltiples sistemas orgánicos. Las personas pueden experimentar mareos, dolores de cabeza y episodios de desmayo. Además, pueden experimentar problemas auditivos como vértigo. Muchos individuos también presentan irritabilidad, dificultades para conciliar el sueño y problemas de concentración. Debido a la disminución del flujo sanguíneo en la piel, es común que los pacientes sean más sensibles al frío. La anemia se considera severa cuando los niveles de hemoglobina caen por debajo de 8 gr/dl.

2.2.3. Causas de la Anemia Ferropénica

La anemia puede tener múltiples causas, siendo la más frecuente la deficiencia de hierro, elemento esencial para la producción de hemoglobina. Cuando se identifica el déficit de hierro como causa de la anemia, es necesario investigar la razón subyacente de esa disminución. Las causas pueden variar desde una baja ingesta de hierro en dietas vegetarianas estrictas, mala absorción en el sistema digestivo debido a enfermedades como la celiaquía o cirugías estomacales/intestinales, hasta incremento de las necesidades de consumo en casos de embarazo o infancia, pérdida de hierro por sangrado menstrual o digestivo, o la combinación de algunas de estas causas. Se estima que alrededor del 20% de las mujeres en edad fértil presentan deficiencia de hierro, y dentro de este grupo, aproximadamente un 7% desarrolla anemia ferropénica relacionada con las pérdidas menstruales. En ocasiones, puede ser necesario realizar pruebas endoscópicas para determinar la causa exacta del cuadro anémico (Oreiro et al., 2009).

2.2.4. Consecuencias de la Anemia Ferropénica

La deficiencia de hierro puede tener consecuencias que se derivan tanto de la anemia como de otros factores no relacionados con la sangre, debido a un funcionamiento inadecuado de las enzimas dependientes de hierro. Algunos efectos descritos incluyen cambios en la capacidad física de trabajo y la actividad motora espontánea, alteraciones en la inmunidad celular y la capacidad de los neutrófilos para combatir bacterias, una posible mayor susceptibilidad a infecciones del tracto respiratorio, disminución en la producción de calor corporal, alteraciones funcionales e histológicas en el sistema digestivo, dificultad para movilizar la vitamina A almacenada en el hígado, mayor riesgo de parto prematuro y problemas de salud perinatales, menor transferencia de hierro al feto, disminución en la velocidad de crecimiento, alteraciones en el comportamiento y en el desarrollo mental y motor, retraso en la velocidad de conducción de los sistemas sensoriales auditivo y visual, y disminución en el tono vagal (Olivares G & Walter K, 2003).

2.2.5. Síntomas de la Anemia Ferropénica

La deficiencia de hierro puede manifestarse a través de diversos síntomas asociados con la anemia ferropénica. Estos síntomas incluyen fatiga, debilidad, palidez de la piel, dificultad para concentrarse, mareos, falta de aliento, taquicardia, uñas quebradizas, dolor de cabeza y pica (deseo de comer sustancias no nutritivas). Además de estos síntomas relacionados con la anemia, también se han descrito otras manifestaciones no hematológicas, como las alteraciones en la capacidad de trabajo físico, la disminución de la actividad motora espontánea, cambios en la inmunidad celular y la capacidad bactericida, mayor susceptibilidad a infecciones del tracto respiratorio, entre otros efectos mencionados anteriormente (Oreiro et al., 2009).

2.2.6. Hemoglobina

La hemoglobina es una proteína presente en los glóbulos rojos de la sangre que se encarga de transportar el oxígeno desde los pulmones hacia los tejidos del cuerpo. En el caso de la anemia ferropénica, la falta de hierro necesario para su producción provoca una disminución en los niveles de hemoglobina, lo cual se manifiesta con síntomas como fatiga, palidez y falta de energía. Esencialmente, la hemoglobina es clave para el transporte de oxígeno y su deficiencia es un factor importante en la anemia ferropénica (Beatriz Jiménez Moraleda, 2021).

2.2.7. Medidor de hemoglobina no invasivo Masimo Rad-67

El Rad-67™ Spot-check Pulse CO-Oximeter es un dispositivo médico que mide la saturación de oxígeno en la sangre y el pulso de una persona. Este dispositivo es portátil y se utiliza para medir la saturación de oxígeno en la sangre de forma no invasiva. Además, el Rad-67™ Spot-check Pulse CO-Oximeter también puede medir la carboxihemoglobina (COHb) y la metahemoglobina (MetHb) en la sangre (Dijk-den Hoed & Vervae, 2018).

2.2.8. Machine Learning - Deep Learning

Machine learning conocido como (aprendizaje automático), junto con el aprendizaje profundo (deep learning), son dos de las herramientas más poderosas en el campo del aprendizaje automático. Estas herramientas tienen como objetivo desarrollar sistemas que puedan aprender de forma automática, reconocer patrones, predecir comportamientos y generalizar información a partir de conjuntos de datos. En particular, las ANNs son algoritmos computacionales inspirados en las redes neuronales biológicas, capaces de aprender y generalizar, lo que les permite reconocer patrones, predecir comportamientos y tomar decisiones. Por otro lado, el aprendizaje profundo toma los fundamentos de las redes neuronales clásicas, pero emplea una mayor cantidad de neuronas y capas ocultas, así como nuevos modelos y paradigmas de entrenamiento.

El avance del ML y el crecimiento de la capacidad computacional de los ordenadores han impulsado el desarrollo de esta nueva tecnología. En este contexto, el DL surge como un concepto estrechamente relacionado al machine learning, aunque con algoritmos distintos. Mientras que el machine learning se apoya en algoritmos de regresión o árboles de decisión, deep learning se basa en el uso de redes neuronales que operan de manera similar a las conexiones neuronales presentes en nuestro cerebro (Sarmiento-Ramos, 2020).

2.2.9. Técnicas de Deep Learning (Alzubaidi et al., 2020)

2.2.9.1. Redes neuronales convolucionales

Son ampliamente utilizadas para tareas de visión por computadora, como detección, localización, reconocimiento y segmentación de objetos en entornos sin restricciones.

2.2.9.2. Redes neuronales recurrentes

Estas redes son especialmente útiles para tareas que implican secuencias de datos, como segmentación de imágenes en video o análisis de texto.

2.2.9.3. Redes de confrontación

Estas redes utilizan múltiples entradas y salidas para comparar y combinar características de diferentes imágenes, lo que resulta en una segmentación más precisa y robusta.

2.2.9.4. Autocodificadores

Son redes neuronales utilizadas para el aprendizaje no supervisado, donde se busca aprender representaciones latentes de los datos. En el contexto de la segmentación de imágenes, los autocodificadores pueden ayudar a extraer características relevantes para identificar y delimitar objetos.

2.2.10. Redes Neuronales Convolucionales.

Las redes neuronales convolucionales (CNN) son fundamentales en el aprendizaje profundo, habiendo logrado avances significativos en áreas como la visión por computadora y el procesamiento de lenguaje natural. Sin embargo, las revisiones existentes se han centrado en aplicaciones específicas y han dejado de lado nuevas ideas. Esta revisión aborda las CNN desde una perspectiva general, cubriendo convoluciones 2-D, 1-D y multidimensionales, así como modelos clásicos y avanzados. También se presentan conclusiones y reglas generales para las funciones y selección de hiperparámetros. Además, se exploran aplicaciones en diferentes dimensiones y se discuten temas abiertos y direcciones prometedoras para futuras investigaciones, buscando inspirar avances en este emocionante campo del aprendizaje profundo basado en CNN (Li et al., 2022).

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1. Ámbito y condiciones de la investigación

3.1.1. Contexto de la investigación

La investigación se llevará a cabo en la Universidad Nacional de San Martín, Ciudad Universitaria, Distrito de Morales, Provincia de San Martín, Región de San Martín, Perú.

3.1.2. Periodo de ejecución

De acuerdo con los procesos tanto en la etapa de recolección, entrenamiento y análisis, el periodo de ejecución tiene una duración de 6 meses.

3.1.3. Autorizaciones y permisos

De acuerdo con la “Ley que establece los derechos de las personas usuarias de los servicios de salud” (Alva L. & León A., 2009), los individuos que forman parte de la muestra deberán otorgar su consentimiento informado para participar en la misma. Por ello, antes de proceder a realizar la intervención no invasiva de recolección de muestras de hemoglobina, el participante tendrá que haber aceptado voluntariamente otorgar dicho consentimiento marcando la casilla de verificación correspondiente.

3.1.4. Control ambiental y protocolos de bioseguridad

Protocolos de limpieza y desinfección: se establece un protocolo riguroso de limpieza y desinfección de los equipos utilizados, como el dispositivo Masimo Rad-67TM, el sensor reutilizable DCI – mini SC 1000 y el dispositivo celular. Esto garantizará la eliminación de cualquier posible contaminante y reducirá el riesgo de transmisión de enfermedades

3.1.5. Aplicación de principios éticos internacionales

Los investigadores declaran que su intervención respetará los principios éticos generales de la investigación; particularmente:

La información obtenida en el desarrollo de la investigación se presentará tal cual la brindó la muestra, de modo que no existirá manipulación alguna por intereses de los autores. En consecuencia, se garantizará la legitimidad y veracidad del estudio. La investigación respetará la propiedad intelectual y las contribuciones de teorías y definiciones tomadas de distintos autores serán citadas según lo establecido por las normas APA.

3.2. Sistema de variables

3.2.1. Variables principales

Variable independiente: Reconocimiento de imágenes de la palma de la mano.

Variable dependiente: Detección no invasiva de anemia ferropénica.

3.2.2. Variables secundarias

3.3. Procedimientos de la investigación

Su diseño es experimental, factorial, debido a que se establecerá la relación existente entre los resultados que se obtienen del modelo implementado en este estudio y los resultados obtenidos mediante el dispositivo Masimo Rad-67™.

3.3.1. Actividades del objetivo específico 1

Recopilar una base de datos con imágenes de la palma de la mano de estudiante de entre 18 y 25 años, con diagnósticos positivo y negativo de anemia, junto a información clínica relevante.

a) Actividades y tareas

- Definir los criterios de selección para establecer los criterios específicos para seleccionar a los estudiantes que formarán parte de la muestra, como la edad (entre 18 y 25 años) y la presencia de diagnóstico positivo o negativo de anemia.
- Designar responsables para la realización de los procesos de obtención de datos tanto clínicos como no invasivos.
- Adquisición del dispositivo de medición no invasivos de la hemoglobina.
- Capacitación en el uso de equipos de medición de hemoglobina no invasivos y el uso de aplicaciones de recolección de datos.
- Construcción de caja para la colocación de la palma de la mano, sin intervención de luz exterior, de tal forma que la obtención de las imágenes sea la más apropiada en cuanto a calidad.
- Realización de las campañas de mediciones utilizando el dispositivo Masimo Rad-67™ para medir la Hemoglobina (SpHb) de los estudiantes y tomando los valores del dedo índice de manera sistemática y estandarizada.
- Registrar y almacenar los datos para mantener un registro preciso y sistemático de los datos recolectados, asegurando la confidencialidad y privacidad de la información, utilizando un sistema de almacenamiento seguro y encriptado para proteger los datos.

b) Descripción de procedimientos

La fuente de recolección de datos se llevará a cabo durante las campañas de mediciones no invasivas en la UNSM, que se realizarán en la ciudad universitaria. Para ello, siguiendo el cronograma de actividades establecido, se utilizará el dispositivo Masimo Rad-67TM para registrar información de medición de hemoglobina y capturar imágenes de la palma de la mano de los estudiantes participantes.

Se tomarán videos de entre 5 y 10 segundos de duración, enfocando la palma de la mano y mediante la luz led (blanco frio) para obtener imágenes claras. Estos videos serán almacenados en la memoria del celular, junto con la información del individuo que forma parte de la muestra, incluyendo su edad, diagnóstico de anemia (positivo o negativo) y valores de Hemoglobina medidos a través del dispositivo Masimo Rad-67.

Durante el proceso de recolección de información, se aplicarán los protocolos de limpieza y sanidad más estrictos para garantizar la seguridad y salud tanto de los investigadores como de los participantes de la muestra. Se adquirirán y utilizarán equipos de protección personal adecuados para prevenir cualquier riesgo o contaminación durante las mediciones.

Este procedimiento permitirá recopilar los datos necesarios para el desarrollo del modelo de detección no invasiva de la anemia ferropénica, utilizando imágenes de la palma de la mano como indicadores.

c) Técnicas de procesamiento y análisis de datos

Documentar el proceso de recopilación de datos con la finalidad de mantener un registro detallado de todas las actividades realizadas durante el proceso de recopilación de datos, incluyendo fechas, procedimientos, problemas encontrados y soluciones implementadas. Esta documentación será útil para el análisis posterior y la redacción del proyecto.



Figura 1
Maquetas



Figura 2
Reunión con especialistas



Figura 3
Dispositivo no invasivo para detección de la anemia



Figura 4
Recolección de imágenes palmares



Figura 5
Recolección de información clínica



Figura 6
Espacio de recolección



Figura 7

Grupo encargado de recolección

3.3.2. Actividades del objetivo específico 2

Desarrollar un modelo de Deep Learning para la clasificación de imágenes de la palma de la mano según los niveles de hemoglobina en sangre.

a) Actividades y tareas

- Recopilar una base de datos de imágenes de la palma de la mano con información clínica relevante y los niveles de hemoglobina en sangre correspondientes.
- Preprocesar y normalizar las imágenes para su posterior procesamiento y análisis.
- Dividir la base de datos en conjuntos de entrenamiento, validación y prueba.
- Diseñar y entrenar un modelo de Deep Learning utilizando técnicas como redes neuronales convolucionales (CNN) para la detección y clasificación de calcificaciones en las imágenes de la palma de la mano.
- Evaluar la precisión y rendimiento del modelo utilizando el conjunto de prueba.
- Ajustar y optimizar el modelo según los resultados obtenidos.
- Validar el modelo utilizando conjuntos de datos adicionales y comparar los resultados con otros métodos de detección de calcificaciones.

b) Descripción de procedimientos

El proyecto comienza recopilando una base de datos de imágenes de la palma de la mano con información clínica y los niveles de hemoglobina en sangre correspondientes. Luego, se realiza el preprocesamiento de las imágenes, que incluye la normalización de los valores de píxeles y la eliminación de ruido o artefactos. A continuación, se divide la base de datos en conjuntos de entrenamiento, validación y prueba.

Para el desarrollo del modelo de Deep Learning, se diseña una arquitectura de red neuronal convolucional (CNN) adecuada para el procesamiento de imágenes. El modelo se entrena utilizando el conjunto de entrenamiento, ajustando los pesos y los hiper parámetros para maximizar el rendimiento. Posteriormente, se evalúa el modelo utilizando el conjunto de prueba, calculando métricas de precisión y rendimiento.

Se realizan ajustes y optimizaciones adicionales en el modelo, como cambios en la arquitectura de la red o técnicas de regularización, basándose en los resultados obtenidos. Finalmente, se valida el modelo utilizando conjuntos de datos adicionales y se comparan los resultados con otros métodos de detección de calcificaciones para evaluar su efectividad.

c) Técnicas de procesamiento y análisis de datos

Se utilizarán técnicas de procesamiento y análisis de datos que incluyen el preprocesamiento de imágenes para normalizar las imágenes, eliminar ruido o artefactos y mejorar la calidad de las imágenes de la palma de la mano. Se emplearán arquitecturas de redes neuronales convolucionales para el aprendizaje y análisis de las características de las imágenes. Además, se dividirá la base de datos en conjuntos de entrenamiento, validación y prueba para el desarrollo y evaluación del modelo de Deep Learning.

Se utilizarán métricas como la precisión, el recall y el F1-score para evaluar el rendimiento del modelo en la detección y clasificación de calcificaciones en las imágenes de la palma de la mano. También se realizarán ajustes en los hiper parámetros del modelo, como la tasa de aprendizaje, el tamaño del batch, la arquitectura de la red, etc., para optimizar el rendimiento y la precisión del modelo. Estas técnicas permitirán procesar y analizar efectivamente las imágenes de la palma de la mano y desarrollar un modelo de Deep Learning que sea capaz de detectar y clasificar las calcificaciones según los niveles de hemoglobina en sangre.

3.3.3. Actividades del objetivo específico 3

Comparar y evaluar las métricas de rendimiento del modelo propuesto y las de otros tres modelos existentes.

a) Actividades y tareas

- Seleccionar tres modelos de referencia para la clasificación de imágenes de la palma de la mano basados en técnicas de Deep Learning, que sean adecuados para detectar y clasificar niveles de hemoglobina en sangre.
- Entrenar los modelos de referencia utilizando el mismo conjunto de datos y los mismos segmentos de entrenamiento y validación, para asegurar condiciones de comparación equitativas.
- Segmentar el conjunto de validación en diez subconjuntos homogéneos para ejecutar pruebas asiladas de cada subconjunto y por cada modelo.
- Aplicar el modelo propuesto y los modelos de referencia en los diez subconjuntos de validación, generando predicciones y recolectando métricas de rendimiento de cada modelo.
- Analizar las métricas de rendimiento de cada modelo, incluyendo exactitud, precisión, recall, F1-score, Kappa de Cohen y AUC ROC OVR.
- Comparar los resultados de los tres modelos mediante la prueba estadística de análisis de varianza (ANOVA) de un factor y de ser necesario, la prueba post hoc de Tukey para encontrar las diferencias significativas.

b) Descripción de procedimientos

El procedimiento comienza seleccionando tres modelos de referencia con arquitecturas relevantes en el campo de la clasificación de imágenes, que sean conocidos por su rendimiento en tareas de análisis de imágenes. Posteriormente, se entrena cada uno de estos modelos con la misma base de datos de imágenes de la palma de la mano utilizada para el modelo propuesto, asegurando que los tres modelos usen los mismos conjuntos de entrenamiento y validación.

Una vez entrenados, se evalúan los cuatro modelos con diez subconjuntos de datos homogéneos creados a partir del conjunto de validación, obteniendo las métricas de: exactitud, precisión, recall, F1-score, Kappa de Cohen y AUC ROC OVR. Estas métricas se analizarán estadísticamente mediante la prueba ANOVA de un factor para determinar la existencia de diferencias significativas en el rendimiento de uno o más modelos.

d) Técnicas de procesamiento y análisis de datos

Para la evaluación y comparación de los modelos, se emplearán las siguientes técnicas y métricas:

- **Métricas de rendimiento:** se utilizarán precisión, recall, F1-score, curva ROC, área bajo la curva (AUC) y tiempo de inferencia para medir el rendimiento y la eficiencia de los modelos.
- **Técnicas estadísticas:** se emplearán pruebas de significancia y análisis estadístico de las métricas obtenidas para identificar diferencias en el rendimiento de los modelos.
- **Visualización de resultados:** se crearán gráficos comparativos para evaluar las diferencias de rendimiento entre los modelos de manera visual, facilitando la interpretación de los resultados.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1. Resultados del Objetivo específico 1

Recopilar una base de datos con imágenes de la palma de la mano de estudiante de entre 18 y 25 años, con diagnósticos positivo y negativo de anemia, junto a información clínica relevante.

Las imágenes fueron recolectadas en el centro médico universitario de la Universidad Nacional de San Martín, se guardaron los videos de la palma de la mano directamente en el dispositivo Android, identificados con los números de DNI y nombre del video creado por defecto, todo ello almacenado en un Excel, obteniendo un total de 980 imágenes.

Se ha completado con éxito la recopilación de datos no invasivos mediante el dispositivo Masimo Rad-67TM, capturando imágenes de la palma de la mano de estudiantes entre 18 y 25 años con diagnósticos positivos y negativos de anemia. Se logró establecer un conjunto de criterios específicos para la selección de la muestra, incluyendo la edad y el diagnóstico anémico. Los resultados preliminares indican una eficacia en la adquisición de datos clínicos y de tipo no invasivos, asegurando la confidencialidad y privacidad de la información recolectada.

La meticulosa selección de la muestra y la utilización del dispositivo de medición no invasivo han sentado las bases para la consecución. Los criterios de selección permitieron obtener datos relevantes para el desarrollo del modelo de detección no invasiva de anemia ferropénica. La utilización del dispositivo Masimo Rad-67TM garantiza mediciones precisas de hemoglobina, proporcionando una base sólida para la fase siguiente del proyecto.

4.2. Resultados del Objetivo específico 2

Desarrollar un modelo de Deep Learning para la clasificación de imágenes de la palma de la mano según los niveles de hemoglobina en sangre.

Para el desarrollo del modelo de clasificación, comenzamos importando el archivo de datos que contiene la información biométrica de los participantes, así como el nivel de hemoglobina en función a valores de anemia. Este último dato, es utilizado posteriormente como la etiqueta de entrenamiento.

```
raw_data = pd.read_excel('BD FORMATO PLANO.xlsx')
```

Luego de esto, establecemos las columnas específicas que formarán parte del dataset inicial. Además de esto, rellenamos con ceros los campos con valores nulos y recodificamos los valores que inicialmente contenían variantes del carácter 'x' por el valor numérico 1, en caso de encontrarse valores nulos o vacíos, empleamos el valor 0.

```
base_datos = raw_data.copy()
columnas = [
    'DNI', 'Fatiga', 'Debilidad', 'Latidos del corazón',
    'Dificultad para respirar',
    'Mareos o aturdimiento', 'Dolor en el pecho', 'Manos y pies
    fríos', 'Dolores de cabeza',
    'Normal', 'Leve ', 'Moderado', 'FC', 'Oxígeno', 'Peso',
    'Talla', 'Sexo', 'Hemoglobina'
]
base_datos = base_datos[columnas].copy()
base_datos.fillna(0, inplace=True)
correcciones = {'X': 1, ' X': 1, 'x': 1, ' ': 0}
base_datos.replace(correcciones, inplace=True)
```

Continuando con el desarrollo del modelo de clasificación, realizamos un proceso de balanceo en las clases del dataset para garantizar una representación equitativa de cada nivel de anemia. Con el fin de que el modelo no esté sesgado hacia una categoría específica procedimos con el balanceo del dataset. Esto se logró seleccionando 75 muestras aleatorias de las clases "Normal" y "Leve", y sumándolas a las muestras de la clase "Moderado".

```
base_datos_balanced = base_datos[base_datos['Normal'] ==
1].sample(75).copy()
base_datos_balanced = pd.concat([base_datos_balanced,
base_datos[base_datos['Leve ' ] == 1].sample(75).copy()])
base_datos_balanced = pd.concat([base_datos_balanced,
base_datos[base_datos['Moderado'] == 1].copy()])
base_datos_balanced = base_datos_balanced.reset_index(drop=True)
```

A continuación, visualizamos la distribución de las muestras en cada categoría mediante un gráfico de barras que muestra la frecuencia de cada clase: "Normal", "Leve" y "Moderado".

```
hist_data = base_datos_balanced[['Normal', 'Leve ',
'Moderado']].value_counts()

x_labels = [str(idx) for idx in hist_data.index]
x_labels_names = ['Normal', 'Leve', 'Moderado']
```

```
plt.bar(x_labels_names, hist_data.values)
plt.xticks(rotation=45, ha='right')
plt.xlabel("Grado de anemia")
plt.ylabel("Frecuencia")
plt.title("Distribución")
plt.tight_layout()
plt.show()
```

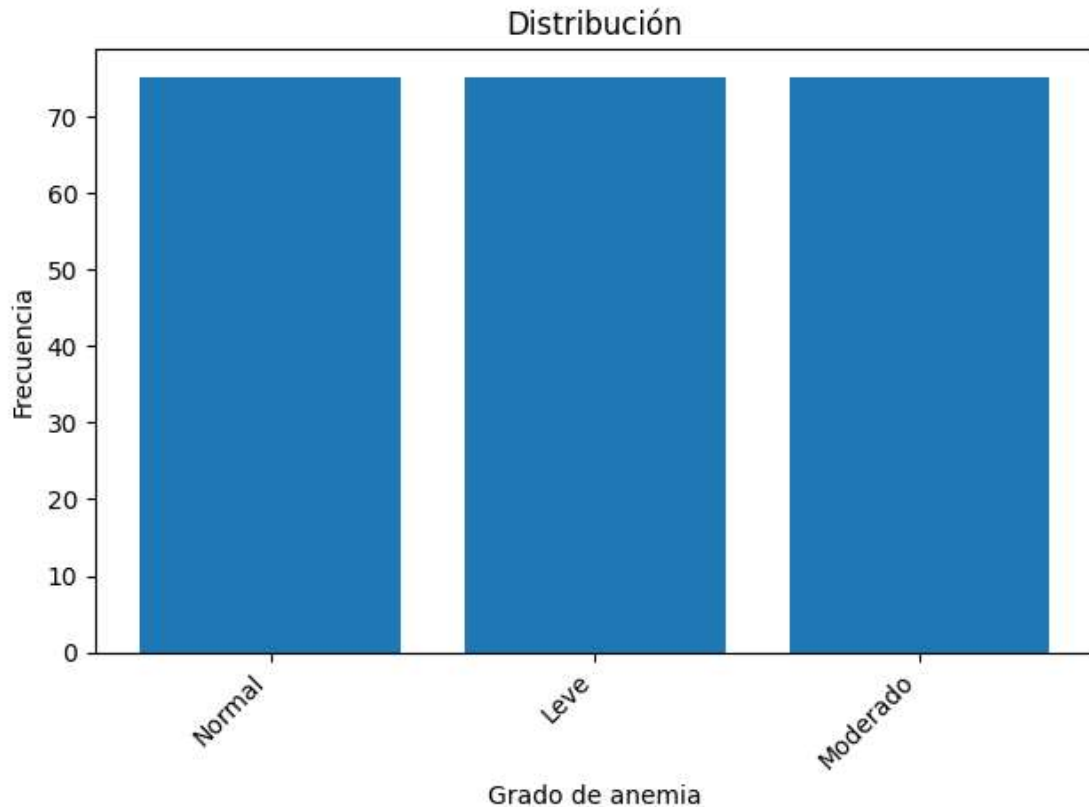


Figura 8

Gráfico de distribución de participantes según el grado de anemia

Analizamos la correlación entre las variables biométricas para comprender su relación con los niveles de anemia. Todo esto mediante un mapa de calor de correlación utilizando la librería seaborn, el cual nos permitió visualizar la intensidad de la relación entre las variables.

```
import seaborn as sns
base_datos_corr = base_datos_balanced.copy()
d_sexo = pd.get_dummies(base_datos_corr['Sexo'])
base_datos_corr = pd.concat([base_datos_corr, d_sexo], axis=1)
base_datos_corr.drop(columns=['Sexo', 'DNI', 'Normal', 'Leve',
' Moderado'], inplace=True)
corr_matrix = base_datos_corr.corr()
plt.figure(figsize=(14, 12))
```

```
sns.heatmap(corr_matrix, annot=True, cmap='coolwarm', fmt=".2f")
plt.show()
```




Figura 9

Matriz de correlación entre dimensiones del set de datos

Con el gráfico resultante es posible corroborar que los datos contenidos dentro del dataset mantienen cierto nivel de relación entre uno o más dimensiones.

Cargamos el segundo archivo de datos, el cual almacena a manera de índice la relación participante – archivo, con el cual relacionaremos la muestra imágenes tomadas al participante y sus datos biométricos.

```
indice_datos = pd.read_excel('INDICE ARCHIVOS - DATASET.xlsx')
indice_datos.drop(columns=['NOM_FOTO', 'N°'], inplace=True)
indice_datos.dropna(inplace=True)
```

Una vez cargados dichos datos, los relacionamos a los datos biométricos a través del dato de DNI con una unión sobre el cual primarán los registros presentes en el índice participante – archivo.

```
indice_dataset = pd.merge(indice_datos, base_datos_balanced[['DNI',
'Normal', 'Leve ', 'Moderado']], on='DNI', how='left')
indice_dataset.dropna(inplace=True)
```

Mediante un gráfico de histograma verificamos la distribución de participantes según sus niveles de hemoglobina.

```
x_labels = [str(idx) for idx in hist_data.index]
x_labels_names = ['Normal', 'Leve', 'Moderado']

plt.bar(x_labels_names, hist_data.values)
plt.xticks(rotation=45, ha='right')
plt.xlabel("Grado de anemia")
plt.ylabel("Frecuencia")
plt.title("Distribución")
plt.tight_layout()
plt.show()
```

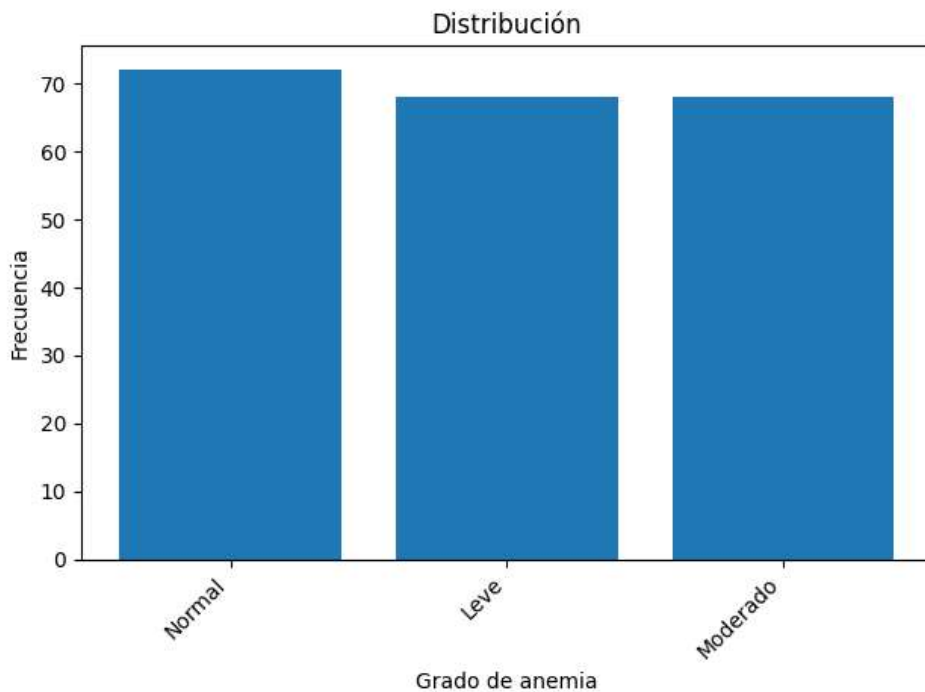


Figura 10

Gráfico de distribución de participantes según el grado de anemia ajustado al índice participante – archivo

El siguiente paso consistió en combinar la información biométrica de los participantes con los videos correspondientes de la palma de la mano, permitiendo la extracción de fotogramas específicos para alimentar el modelo de clasificación. Se creó un dataset de imágenes almacenadas en carpetas organizadas por clase.

```

input_folder = "Hemo/Toma muestras/Palma+Uña/Camera/"
output_folder = "palmas_dataset/"

categories = ['Normal', 'Leve', 'Moderado']
for cat in categories:
    os.makedirs(os.path.join(output_folder, 'train', cat),
exist_ok=True)
    os.makedirs(os.path.join(output_folder, 'val', cat),
exist_ok=True)

def save_image(frame, category, filename, is_train):
    subset = 'train' if is_train else 'val'
    folder_path = os.path.join(output_folder, subset, category)
    cv2.imwrite(os.path.join(folder_path, filename), frame)

for index, row in indice_dataset.iterrows():
    video_path = os.path.join(input_folder, row['NOM_VIDEO'])
    cap = cv2.VideoCapture(video_path)

    if not cap.isOpened():
        print(f"Error al abrir el video: {row['NOM_VIDEO']}")
        continue

    category = 'Normal' if row['Normal'] == 1 else 'Leve' if
row['Leve'] == 1 else 'Moderado'

    frame_count = int(cap.get(cv2.CAP_PROP_FRAME_COUNT))
    current_frame = 90
    saved_images = 0

    while cap.isOpened() and saved_images < 15 and current_frame <
frame_count:
        cap.set(cv2.CAP_PROP_POS_FRAMES, current_frame)
        ret, frame = cap.read()

        if not ret:
            break
        is_train = np.random.rand() < 0.8
        filename =
f"{row['DNI']}_{row['NOM_VIDEO']}_frame{current_frame}.jpg"
        save_image(frame, category, filename, is_train)

        saved_images += 1

```

```

current_frame += 45

cap.release()

```

Para el desarrollo del modelo de clasificación de imágenes de la palma de la mano, optamos por utilizar la arquitectura YOLOv11 en su variante “cls”, diseñada específicamente para tareas de clasificación en tiempo real. La red fue entrenada sobre el dataset balanceado de imágenes generadas.

```

dataset_dir = 'palmas_dataset/'
from ultralytics import YOLO

model = YOLO('yolo11n-cls.pt')
results = model.train(data=dataset_dir, epochs=100, imgsz=224)
model = YOLO('runs/classify/train2/weights/best.pt')

```

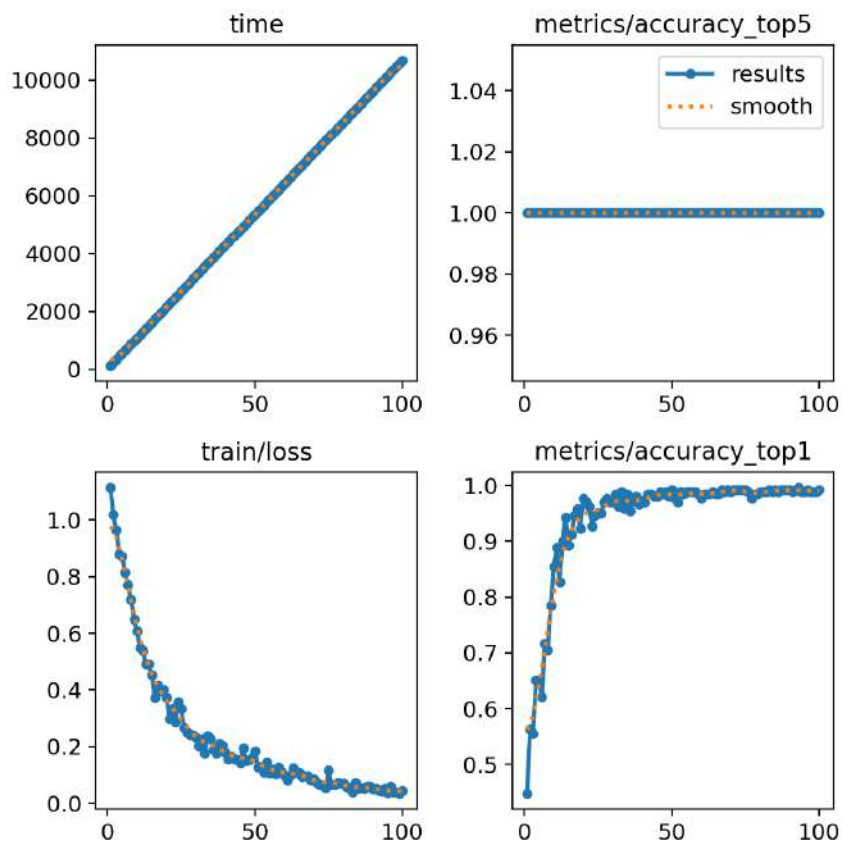


Figura 11

Gráficos de la evolución del entrenamiento según métrica de rendimiento

Al finalizar con el entrenamiento, podemos observar un comportamiento satisfactorio con el set de datos proporcionado, alcanzando altos valores en la exactitud y bajos valores en la pérdida, lo que nos permite comprender que el modelo ha alcanzado una gran capacidad de generalización entre las clases y una baja desviación en la probabilidad de la predicción que genera respecto al valor de referencia. Esto se alinea a los resultados encontrados en investigaciones similares como los de Mustofa et al. (2024) y Elazab et al. (2024) alcanzando en este último, valores superiores al 97% en métricas como la exactitud, la precisión y el recall.

4.3. Resultados del Objetivo específico 3

Comparar y evaluar las métricas de rendimiento del modelo propuesto y las de otros tres modelos existentes

Comenzamos, construyendo los tres modelos que se compararán con el modelo propuesto YOLO11, las arquitecturas de dichos modelos son los siguientes:

ResNet50

```
from tensorflow.keras.applications import ResNet50
from tensorflow.keras import layers, models
from tensorflow.keras.callbacks import ModelCheckpoint

input_tensor = layers.Input(shape=(224, 224, 3))

base_model = ResNet50(weights='imagenet', include_top=False,
input_tensor=input_tensor)
base_model.trainable = True

x = layers.GlobalAveragePooling2D()(base_model.output)
x = layers.Dense(128, activation='relu')(x)
x = layers.Dropout(0.5)(x)
output = layers.Dense(3, activation='softmax')(x)

model_resnet = models.Model(inputs=input_tensor, outputs=output)

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

checkpoint_resnet = ModelCheckpoint(
    'hemo_palmas_resnet50.keras',
    monitor='val_accuracy',
    mode='max',
    save_best_only=True,
    verbose=1
)
```

```

model_resnet.fit(
    train_generator,
    validation_data=val_generator,
    epochs=100,
    callbacks=[checkpoint_resnet]
)

```

EfficientNetB0

```

from tensorflow.keras.applications import EfficientNetB0
from tensorflow.keras import layers, models
from tensorflow.keras.callbacks import ModelCheckpoint

input_tensor = layers.Input(shape=(224, 224, 3))

base_model = EfficientNetB0(weights='imagenet', include_top=False,
input_tensor=input_tensor)
base_model.trainable = True

x = layers.GlobalAveragePooling2D()(base_model.output)
x = layers.Dense(128, activation='relu')(x)
x = layers.Dropout(0.5)(x)
output = layers.Dense(3, activation='softmax')(x)

model_efficientnet = models.Model(inputs=input_tensor,
outputs=output)

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

checkpoint_efficientnet = ModelCheckpoint(
    'hemo_palmas_efficientnet.keras',
    monitor='val_accuracy',
    mode='max',
    save_best_only=True,
    verbose=1
)

model_efficientnet.fit(
    train_generator,
    validation_data=val_generator,
    epochs=100,
    callbacks=[checkpoint_efficientnet]
)

```

InceptionV3

```

from tensorflow.keras.applications import InceptionV3
from tensorflow.keras import layers, models
from tensorflow.keras.callbacks import ModelCheckpoint

input_tensor = layers.Input(shape=(224, 224, 3))

base_model = InceptionV3(weights='imagenet', include_top=False,
input_tensor=input_tensor)
base_model.trainable = False

x = layers.GlobalAveragePooling2D()(base_model.output)
x = layers.Dense(128, activation='relu')(x)
x = layers.Dropout(0.5)(x)
output = layers.Dense(3, activation='softmax')(x)

model_inception = models.Model(inputs=input_tensor, outputs=output)

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

checkpoint_inception = ModelCheckpoint(
    'hemo_palmas_inceptionV3.keras',
    monitor='val_accuracy',
    mode='max',
    save_best_only=True,
    verbose=1
)

history_inception = model_inception.fit(
    train_generator,
    validation_data=val_generator,
    epochs=100,
    callbacks=[checkpoint_inception]
)

```

Tras correr el entrenamiento en los 3 modelos que servirán de comparación para el modelo propuesto, obtenemos las siguientes gráficas que marcan la evolución del entrenamiento en los distintos modelos:




Figura 12

Gráfica de la evolución en el entrenamiento del modelo ResNet50

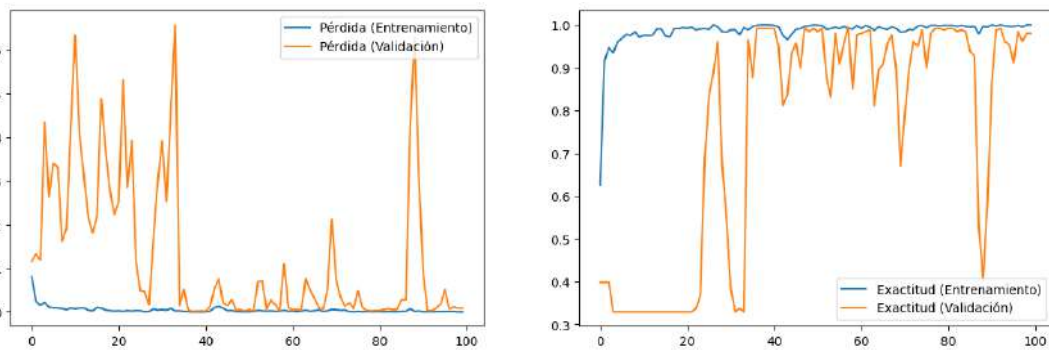


Figura 13

Gráfica de la evolución en el entrenamiento del modelo EfficientNetB0




Figura 14

Gráfica de la evolución en el entrenamiento del modelo InceptionV3

Cargamos los pesos obtenidos durante la fase de entrenamiento. Cabe resaltar que YOLO 11 es capaz de seleccionar la mejor instancia del modelo durante su entrenamiento de manera automática, por lo no es necesario implementar funciones de tipo callback para este propósito.

```
model = YOLO('runs/classify/train2/weights/best.pt')
```

Antes de pasar a las pruebas más específicas, ejecutamos una pequeña validación del modelo cargado para verificar que es un modelo válido y de buen rendimiento.

```
results = model.val()
```

```
100%|██████████| 755k/755k [00:00<00:00, 19.9MB/s]
      classes top1_acc top5_acc: 100%|██████████| 17/17 [00:41<00:00, 2.42s/it]
      all      0.996      1
```

Figura 15

Resultado de la prueba de validación rápida al modelo YOLO11

Como se puede observar en los resultados, el modelo cargado alcanza una exactitud del 99.6% en esta prueba rápida.

Para determinar si existía alguna diferencia significativa entre los modelos planteados, aplicamos la prueba de análisis de varianza (ANOVA) a partir de una muestra de 10 pruebas de rendimiento con datos tomados del conjunto de validación, aislados entre sí en grupos correctamente balanceados, mediante 6 indicadores: Exactitud, precisión, recall, score F1, Kappa de Cohen y área bajo la curva ROC.

```
def get_images_from_category(path):
    """Obtiene todas las rutas de imágenes en una categoría"""
    return [os.path.join(path, img) for img in os.listdir(path) if
            img.endswith('.jpg') or img.endswith('.png')]

def create_balanced_subsets(categories_paths, num_subsets,
                             num_images_per_category):
    """Crea los subconjuntos balanceados en memoria"""
    subsets = []

    for subset_idx in range(num_subsets):
        subset = {'image_path': [], 'dx': []}

        for category, images in categories_paths.items():
            # Selecciona aleatoriamente las imágenes de la
            categoría
            selected_images = random.sample(images,
            num_images_per_category)

            # Agrega las imágenes y las etiquetas al subconjunto
            subset['image_path'].extend(selected_images)
            subset['dx'].extend([category] *
            num_images_per_category)

        # Mezcla aleatoriamente las imágenes dentro del subconjunto
        df_subset =
        pd.DataFrame(subset).sample(frac=1).reset_index(drop=True)
        subsets.append(df_subset)
```


	10	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
RESNET50	1	0.9524	0.9583	0.9524	0.9521	0.9286	0.9932
	2	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	3	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	4	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	5	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	6	0.9524	0.9583	0.9524	0.9521	0.9286	1.0000
	7	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	8	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	10	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
EFFICIENTNETB0	1	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	2	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	3	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	4	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	5	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	6	0.9524	0.9583	0.9524	0.9521	0.9286	0.9966
	7	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	8	0.9524	0.9583	0.9524	0.9521	0.9286	0.9966
	9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	10	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
INCEPTIONV3	1	0.9048	0.9259	0.9048	0.9071	0.8571	0.9252
	2	0.9524	0.9583	0.9524	0.9521	0.9286	0.9932
	3	0.9524	0.9583	0.9524	0.9521	0.9286	1.0000
	4	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
	5	0.9048	0.9107	0.9048	0.9045	0.8571	0.9728
	6	0.9524	0.9583	0.9524	0.9521	0.9286	0.9864
	7	0.9524	0.9583	0.9524	0.9521	0.9286	0.9932
	8	0.9524	0.9583	0.9524	0.9521	0.9286	0.9728
	9	0.9048	0.9167	0.9048	0.9000	0.8571	0.9830
	10	0.9524	0.9583	0.9524	0.9521	0.9286	1.0000

Con el fin de comparar y evaluar los modelos empleados, empezamos evaluando la existencia de diferencias significativas entre sus métricas de rendimiento a través del análisis de varianza (ANOVA) unidireccional. Según esta prueba, la hipótesis nula (H_0) establece que no hay diferencias significativas entre las medias de los grupos, mientras que la hipótesis alterna (H_1) plantea la existencia de al menos una diferencia significativa.

A continuación, introducimos estos resultados en el software de análisis estadístico SPSS y ejecutamos la prueba ANOVA de un solo factor:

Tabla 2
Resultados de la prueba ANOVA de un factor

		Suma de cuadrados	GL	Media cuadrática	F	SIG
Exactitud	Entre grupos	0.018	3	0.006	12.584	0.000
	Dentro de grupos	0.017	36	0.000		
	Total	0.036	39			
Precisión	Entre grupos	0.014	3	0.005	12.488	0.000
	Dentro de grupos	0.013	36	0.000		
	Total	0.027	39			
Recall	Entre grupos	0.018	3	0.006	12.584	0.000
	Dentro de grupos	0.017	36	0.000		
	Total	0.036	39			
F1	Entre grupos	0.019	3	0.006	12.562	0.000
	Dentro de grupos	0.018	36	0.000		
	Total	0.036	39			
Kappa	Entre grupos	0.041	3	0.014	12.584	0.000
	Dentro de grupos	0.039	36	0.001		
	Total	0.080	39			
ROC AUC OVR	Entre grupos	0.002	3	0.001	5.475	0.003
	Dentro de grupos	0.005	36	0.000		
	Total	0.007	39			

Dado que el valor sig (p) es menor a 0.01 en todas las comparaciones, podemos afirmar con un 99% de confianza que hay diferencias significativas entre al menos dos de los modelos comparados. Esto significa que al menos uno de los modelos se desempeña de manera distinta a los demás. Para poder determinar cuál es el modelo que presenta dicha diferencia significativa ejecutamos la prueba Tukey. Dicha prueba post-hoc nos devolvió los siguientes resultados:

Tabla 3
Resultados de la prueba de Tukey (Post hoc)

Variable dependiente	HSD Tukey	(I) Modelo	(J) Modelo	Diferencia de medias (I-J)	Desv. Error	Sig.	Intervalo de confianza al 95%	
							Límite inferior	Límite superior
							r	r
Exactitud	YOLO11	ResNet50		0.00476	0.0098	0.96	-	0.0377
					5	2	0.0282	
	ResNet50	YOLO11		-0.00476	0.0098	0.96	-	0.0282
					5	2	0.0377	
YOLO11	EfficientNetB0		0.00476	0.0098	0.96	-	0.0377	
				5	2	0.0282		
ResNet50	InceptionV3		.05236*	0.0098	0.00	0.0194	0.0853	
				5	0			

		EfficientNetB	0.00000	0.0098	1.00	-	0.0329
		0		5	0	0.0329	
		InceptionV3	.04760*	0.0098	0.00	0.0147	0.0805
				5	0		
	EfficientNetB	YOLO11	-0.00476	0.0098	0.96	-	0.0282
	0			5	2	0.0377	
		ResNet50	0.00000	0.0098	1.00	-	0.0329
				5	0	0.0329	
		InceptionV3	.04760*	0.0098	0.00	0.0147	0.0805
				5	0		
	InceptionV3	YOLO11	-0.05236*	0.0098	0.00	-	-0.0194
				5	0	0.0853	
		ResNet50	-.04760*	0.0098	0.00	-	-0.0147
				5	0	0.0805	
		EfficientNetB	-.04760*	0.0098	0.00	-	-0.0147
	0			5	0	0.0805	
Precisión	YOLO11	ResNet50	0.00417	0.0085	0.96	-	0.0329
				9	2	0.0246	
		EfficientNetB	0.00417	0.0085	0.96	-	0.0329
	0			9	2	0.0246	
		InceptionV3	.04552*	0.0085	0.00	0.0168	0.0742
				9	0		
	ResNet50	YOLO11	-0.00417	0.0085	0.96	-	0.0246
				9	2	0.0329	
		EfficientNetB	0.00000	0.0085	1.00	-	0.0287
	0			9	0	0.0287	
		InceptionV3	.04135*	0.0085	0.00	0.0126	0.0701
				9	0		
	EfficientNetB	YOLO11	-0.00417	0.0085	0.96	-	0.0246
	0			9	2	0.0329	
		ResNet50	0.00000	0.0085	1.00	-	0.0287
				9	0	0.0287	
		InceptionV3	.04135*	0.0085	0.00	0.0126	0.0701
				9	0		
	InceptionV3	YOLO11	-0.04552*	0.0085	0.00	-	-0.0168
				9	0	0.0742	
		ResNet50	-.04135*	0.0085	0.00	-	-0.0126
				9	0	0.0701	
		EfficientNetB	-.04135*	0.0085	0.00	-	-0.0126
	0			9	0	0.0701	
Recall	YOLO11	ResNet50	0.00476	0.0098	0.96	-	0.0377
				5	2	0.0282	

		EfficientNetB	0.00476	0.0098	0.96	-	0.0377
		0		5	2	0.0282	
		InceptionV3	.05236*	0.0098	0.00	0.0194	0.0853
				5	0		
	ResNet50	YOLO11	-0.00476	0.0098	0.96	-	0.0282
				5	2	0.0377	
		EfficientNetB	0.00000	0.0098	1.00	-	0.0329
		0		5	0	0.0329	
		InceptionV3	.04760*	0.0098	0.00	0.0147	0.0805
				5	0		
	EfficientNetB	YOLO11	-0.00476	0.0098	0.96	-	0.0282
	0			5	2	0.0377	
		ResNet50	0.00000	0.0098	1.00	-	0.0329
				5	0	0.0329	
		InceptionV3	.04760*	0.0098	0.00	0.0147	0.0805
				5	0		
	InceptionV3	YOLO11	-.05236*	0.0098	0.00	-	-0.0194
				5	0	0.0853	
		ResNet50	-.04760*	0.0098	0.00	-	-0.0147
				5	0	0.0805	
		EfficientNetB	-.04760*	0.0098	0.00	-	-0.0147
		0		5	0	0.0805	
F1	YOLO11	ResNet50	0.00479	0.0099	0.96	-	0.0380
				4	3	0.0284	
		EfficientNetB	0.00479	0.0099	0.96	-	0.0380
		0		4	3	0.0284	
		InceptionV3	.05279*	0.0099	0.00	0.0196	0.0860
				4	0		
	ResNet50	YOLO11	-0.00479	0.0099	0.96	-	0.0284
				4	3	0.0380	
		EfficientNetB	0.00000	0.0099	1.00	-	0.0332
		0		4	0	0.0332	
		InceptionV3	.04800*	0.0099	0.00	0.0148	0.0812
				4	0		
	EfficientNetB	YOLO11	-0.00479	0.0099	0.96	-	0.0284
	0			4	3	0.0380	
		ResNet50	0.00000	0.0099	1.00	-	0.0332
				4	0	0.0332	
		InceptionV3	.04800*	0.0099	0.00	0.0148	0.0812
				4	0		
	InceptionV3	YOLO11	-.05279*	0.0099	0.00	-	-0.0196
				4	0	0.0860	

		ResNet50	-.04800*	0.0099	0.00	-	-0.0148
				4	0	0.0812	
		EfficientNetB	-.04800*	0.0099	0.00	-	-0.0148
		0		4	0	0.0812	
Kappa	YOLO11	ResNet50	0.00714	0.0147	0.96	-	0.0565
				7	2	0.0423	
		EfficientNetB	0.00714	0.0147	0.96	-	0.0565
		0		7	2	0.0423	
		InceptionV3	.07857*	0.0147	0.00	0.0292	0.1280
				7	0		
	ResNet50	YOLO11	-0.00714	0.0147	0.96	-	0.0423
				7	2	0.0565	
		EfficientNetB	0.00000	0.0147	1.00	-	0.0494
		0		7	0	0.0494	
		InceptionV3	.07143*	0.0147	0.00	0.0220	0.1208
				7	0		
	EfficientNetB	YOLO11	-0.00714	0.0147	0.96	-	0.0423
	0			7	2	0.0565	
		ResNet50	0.00000	0.0147	1.00	-	0.0494
				7	0	0.0494	
		InceptionV3	.07143*	0.0147	0.00	0.0220	0.1208
				7	0		
	InceptionV3	YOLO11	-.07857*	0.0147	0.00	-	-0.0292
				7	0	0.1280	
		ResNet50	-.07143*	0.0147	0.00	-	-0.0220
				7	0	0.1208	
		EfficientNetB	-.07143*	0.0147	0.00	-	-0.0220
		0		7	0	0.1208	
ROC AUC OVR	YOLO11	ResNet50	0.00068	0.0051	0.99	-	0.0178
				1	9	0.0164	
		EfficientNetB	0.00068	0.0051	0.99	-	0.0178
		0		1	9	0.0164	
		InceptionV3	.01734*	0.0051	0.00	0.0003	0.0344
				1	9		
	ResNet50	YOLO11	-0.00068	0.0051	0.99	-	0.0164
				1	9	0.0178	
		EfficientNetB	0.00000	0.0051	1.00	-	0.0171
		0		1	0	0.0171	
		InceptionV3	0.01666	0.0051	0.01	-	0.0337
				1	2	0.0004	
	EfficientNetB	YOLO11	-0.00068	0.0051	0.99	-	0.0164
	0			1	9	0.0178	

	ResNet50	0.00000	0.0051	1.00	-	0.0171
			1	0	0.0171	
	InceptionV3	0.01666	0.0051	0.01	-	0.0337
			1	2	0.0004	
InceptionV3	YOLO11	-0.01734*	0.0051	0.00	-	-0.0003
			1	9	0.0344	
	ResNet50	-0.01666	0.0051	0.01	-	0.0004
			1	2	0.0337	
	EfficientNetB	-0.01666	0.0051	0.01	-	0.0004
	0		1	2	0.0337	

Los resultados obtenidos de la prueba de Tukey nos permiten identificar que el valor Sig.(p) es menor a 0.01 en muchas de las comparaciones, lo que indica que las diferencias observadas no son debidas al azar y que al menos algunos de los modelos tienen un rendimiento significativamente diferente.

Ya en detalle, nos damos cuenta que el modelo InceptionV3 presenta las mayores diferencias significativas, presentando un valor menor al 0.01 en comparación con los otros modelos y en casi todas las métricas.

Tabla 4
Estadísticos descriptivos de los datos comparados

		N	Media	Desv. Desviación	Desv. Error	95% del intervalo de confianza para la media		Mínimo	Máximo
						Límite inferior	Límite superior		
Exactitud	YOLO11	10	0.9952	0.01505	0.00476	0.9845	1.0060	0.95	1.00
	ResNet50	10	0.9905	0.02007	0.00635	0.9761	1.0048	0.95	1.00
	EfficientNetB0	10	0.9905	0.02007	0.00635	0.9761	1.0048	0.95	1.00
	InceptionV3	10	0.9429	0.03010	0.00952	0.9213	0.9644	0.90	1.00
	Total	40	0.9798	0.03027	0.00479	0.9701	0.9895	0.90	1.00
Coefficiente F1	YOLO11	10	0.9958	0.01319	0.00417	0.9864	1.0053	0.96	1.00
	ResNet50	10	0.9917	0.01758	0.00556	0.9791	1.0042	0.96	1.00
	EfficientNetB0	10	0.9917	0.01758	0.00556	0.9791	1.0042	0.96	1.00
	InceptionV3	10	0.9503	0.02613	0.00826	0.9316	0.9690	0.91	1.00
	Total	40	0.9824	0.02636	0.00417	0.9739	0.9908	0.91	1.00
Precisión	YOLO11	10	0.9952	0.01505	0.00476	0.9845	1.0060	0.95	1.00
	ResNet50	10	0.9905	0.02007	0.00635	0.9761	1.0048	0.95	1.00
	EfficientNetB0	10	0.9905	0.02007	0.00635	0.9761	1.0048	0.95	1.00
	InceptionV3	10	0.9429	0.03010	0.00952	0.9213	0.9644	0.90	1.00
	Total	40	0.9798	0.03027	0.00479	0.9701	0.9895	0.90	1.00
Recall	YOLO11	10	0.9952	0.01515	0.00479	0.9844	1.0060	0.95	1.00
	ResNet50	10	0.9904	0.02020	0.00639	0.9760	1.0049	0.95	1.00
	EfficientNetB0	10	0.9904	0.02020	0.00639	0.9760	1.0049	0.95	1.00
	InceptionV3	10	0.9424	0.03048	0.00964	0.9206	0.9642	0.90	1.00

	Total	40	0.9796	0.03054	0.00483	0.9699	0.9894	0.90	1.00
Kappa de Cohen	YOLO11	10	0.9929	0.02258	0.00714	0.9767	1.0090	0.93	1.00
	ResNet50	10	0.9857	0.03010	0.00952	0.9642	1.0073	0.93	1.00
	EfficientNetB0	10	0.9857	0.03010	0.00952	0.9642	1.0073	0.93	1.00
	InceptionV3	10	0.9143	0.04520	0.01429	0.8820	0.9466	0.86	1.00
	Total	40	0.9696	0.04543	0.00718	0.9551	0.9842	0.86	1.00
ROC OVR	YOLO11	10	1.0000	0.00000	0.00000	1.0000	1.0000	1.00	1.00
	ResNet50	10	0.9993	0.00215	0.00068	0.9978	1.0009	0.99	1.00
	EfficientNetB0	10	0.9993	0.00143	0.00045	0.9983	1.0003	1.00	1.00
	InceptionV3	10	0.9827	0.02269	0.00718	0.9664	0.9989	0.93	1.00
	Total	40	0.9953	0.01324	0.00209	0.9911	0.9996	0.93	1.00
ROC OVO	YOLO11	10	0.9952	0.01505	0.00476	0.9845	1.0060	0.95	1.00
	ResNet50	10	0.9905	0.02007	0.00635	0.9761	1.0048	0.95	1.00
	EfficientNetB0	10	0.9905	0.02007	0.00635	0.9761	1.0048	0.95	1.00
	InceptionV3	10	0.9429	0.03010	0.00952	0.9213	0.9644	0.90	1.00

Si nos fijamos en el valor de las medias obtenidas por cada modelo, observamos que InceptionV3 presenta en la mayoría de las métricas un rendimiento inferior a la de los demás modelos. Por lo tanto, es posible señalar que el modelo InceptionV3 tiene un rendimiento significativamente inferior a la de los demás modelos.

En cuanto a los modelos restantes, YOLO11, ResNet50 y EfficientNetB0, ninguno presenta diferencias significativas entre sí. Sin embargo, al examinar las medias y los errores estándar, observamos que el modelo planteado (YOLO11), presenta en promedio los valores más altos y con menor variabilidad en comparación con los otros modelos. Estos resultados reflejan un avance notable de los modelos de visión artificial como lo son YOLO en sus distintas variantes, lo que en contraste con estudios como los de Xinming et al. (2023) demuestran un aumento del rendimiento que presenta dicho modelo a lo largo de sus versiones más avanzadas.

CONCLUSIONES

1. Recopilamos una base de datos con imágenes de la palma de la mano de estudiante de entre 18 y 25 años, con diagnósticos positivo y negativo de anemia, junto a información clínica relevante de manera exitosa. Los criterios de selección meticulosos permitieron obtener información clínica relevante de estudiantes entre 18 y 25 años con diagnósticos positivos y negativos de anemia. Esta fase establece una base sólida para el desarrollo del modelo de detección no invasiva.
2. Desarrollamos un modelo de Deep Learning para la clasificación de imágenes de la palma de la mano según los niveles de hemoglobina en sangre. Empleamos la variante más pequeña de clasificación de YOLO11 el cual fue entrenado con un conjunto de datos de 980 imágenes logrando una alta exactitud y baja pérdida en la tarea de clasificación para tres categorías distintas.
3. Comparamos y evaluamos las métricas de rendimiento del modelo propuesto y las de tres modelos existentes (YOLO11, ResNet50, EfficientNetB0 e InceptionV3). Los análisis revelaron diferencias significativas, con InceptionV3 mostrando un rendimiento inferior en casi todas las métricas evaluadas. Aunque YOLO11, ResNet50 y EfficientNetB0 no presentaron diferencias significativas entre sí, YOLO11 destacó por su rendimiento promedio superior y menor variabilidad. Esto posiciona a YOLO11 como el modelo más robusto y consistente para la detección de anemia ferropénica en este estudio.
4. Detectamos la anemia ferropénica utilizando un modelo de visión artificial como método no invasivo basado en imágenes de la palma de la mano. El modelo desarrollado demostró ser efectivo al clasificar imágenes según niveles de hemoglobina en sangre, logrando un desempeño robusto en las métricas clave. Esta propuesta combina precisión, eficiencia y una alternativa accesible a los métodos invasivos tradicionales, estableciendo un avance significativo hacia la implementación de herramientas tecnológicas que faciliten el diagnóstico temprano y no invasivo de la anemia ferropénica en poblaciones jóvenes.

RECOMENDACIONES

1. Recomendamos obtener los valores de referencia de hemoglobina a través de métodos de medición más precisos, como aquellos que emplean instrumentos con menor margen de error, para garantizar la confiabilidad de los resultados futuros. Además, se recomienda enriquecer el conjunto de datos con variables biométricas adicionales para obtener una comprensión más completa del fenómeno estudiado.
2. Para futuros trabajos, recomendamos explorar, ampliar y comparar diversas arquitecturas de redes convolucionales para identificar aquella que mejor se adapte a las características particulares del problema en estudio. Para ello, se recomienda utilizar métricas de evaluación similares a las empleadas en esta investigación.
3. Comparamos y evaluamos las métricas de rendimiento del modelo propuesto y las Para adaptar el modelo a las características específicas del problema, se recomienda ajustar los hiperparámetros, tales como la tasa de aprendizaje, los tipos y los números de capas, el tipo de optimizador o el tipo de modelo utilizado, de forma personalizada con el fin de obtener el mejor desempeño posible.
4. Con el objetivo de mejorar la precisión del modelo en la detección de diferentes niveles de hemoglobina, se recomienda equilibrar la composición de la muestra de manera previa a la toma de muestras, incluyendo una mayor variedad de casos como el nivel severo que no fue contemplado en esta investigación.

REFERENCIAS BIBLIOGRÁFICAS

- Alegría Guerrero, R. C., Gonzales Medina, C. A., & Huachín Morales, F. D. (2019). El tratamiento de la anemia por deficiencia de hierro durante el embarazo y el puerperio. *Revista Peruana de Ginecología y Obstetricia*, 65(4), 503–509. <https://doi.org/10.31403/rpgo.v65i2220>
- Alzubaidi, L., Fadhel, M. A., Al-Shamma, O., Zhang, J., & Duan, Y. (2020). Deep Learning Models for Classification of Red Blood Cells in Microscopy Images to Aid in Sickle Cell Anemia Diagnosis. *Electronics*, 9(3), 427. <https://doi.org/10.3390/electronics9030427>
- Appiahene, P., Asare, J. W., Donkoh, E. T., Dimauro, G., & Maglietta, R. (2023a). Detection of iron deficiency anemia by medical images: a comparative study of machine learning algorithms. *BioData Mining*, 16(1), 2. <https://doi.org/10.1186/s13040-023-00319-z>
- Appiahene, P., Asare, J. W., Donkoh, E. T., Dimauro, G., & Maglietta, R. (2023b). Detection of iron deficiency anemia by medical images: a comparative study of machine learning algorithms. *BioData Mining*, 16(1), 2. <https://doi.org/10.1186/s13040-023-00319-z>
- Arredondo-Nontol, M., & Arredondo-Nontol, R. (2020). The need to optimize the definition of anemia in the management of the world health organization in the field of physiological changes of the manager at sea level and at height. *Revista Médica de Trujillo*, 15(2), 55–56. <https://doi.org/10.17268/rmt.2020.v15i02.02>
- Ashani, Z. N., Ilias, I. S. C., Ng, K. Y., Ariffin, M. R. K., Jarno, A. D., & Zamri, N. Z. (2025). Comparative Analysis of Deepfake Image Detection Method Using VGG16, VGG19 and ResNet50. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, 47(1), 16–28. <https://doi.org/10.37934/araset.47.1.1628>
- Avetisyan, B. R., Druzhinina, N. S., & Daudov, I. M. (2020). Neural networks and artificial intelligence as trends for the development of the future. *Journal of Physics: Conference Series*, 1582(1), 012005. <https://doi.org/10.1088/1742-6596/1582/1/012005>
- Beatriz Jiménez Moraleda, M. D. F. M. M. S. B. M. L. G. A. C. M. M. G. C. N. (2021, September 30). *Hemoglobina, estructura y trastornos, revisión bibliográfica*.

<https://revistasanitariadeinvestigacion.com/hemoglobina-estructura-y-trastornos-revision-bibliografica/>

- Dijk-den Hoed, G. van., & Vervaet, E. (Ewald A. Z. M. (2018). *Handleiding en antwoorden : klank- en vormspel : klanken en vormen in de onderbouw van de basisschool*. Ontdekkend Leren.
- Dimauro, G., Griseta, M. E., Camporeale, M. G., Clemente, F., Guarini, A., & Maglietta, R. (2023). An intelligent non-invasive system for automated diagnosis of anemia exploiting a novel dataset. *Artificial Intelligence in Medicine*, 136, 102477. <https://doi.org/10.1016/j.artmed.2022.102477>
- Elazab, N., Gab-Allah, W. A., & Elmogy, M. (2024a). A multi-class brain tumor grading system based on histopathological images using a hybrid YOLO and RESNET networks. *Scientific Reports*, 14(1), 4584. <https://doi.org/10.1038/s41598-024-54864-6>
- Elazab, N., Gab-Allah, W. A., & Elmogy, M. (2024b). A multi-class brain tumor grading system based on histopathological images using a hybrid YOLO and RESNET networks. *Scientific Reports*, 14(1), 4584. <https://doi.org/10.1038/s41598-024-54864-6>
- Ferdousi, R., Mabrubah, N., Laamarti, F., El Saddik, A., & Yang, C. (2022). *Non-invasive Anemia Detection from Conjunctival Images* (pp. 189–201). https://doi.org/10.1007/978-3-031-22061-6_14
- Foy Valencia, E. C., Asencios Espejo, R. W., Sánchez Durand, E. M., Gutiérrez Avellaneda, M. M., & Casas Mallqui, Ú. M. (2022). Prevalencia de anemia ferropénica en estudiantes de Biología de la Universidad Nacional de Educación Lima, 2019. *Dilemas Contemporáneos: Educación, Política y Valores*. <https://doi.org/10.46377/dilemas.v9i2.3128>
- Gándara-Santiago, C. D. (2020). Anemia grave en atención primaria: ferropenia y riesgos de transfusión. *REMUS - Revista Estudiantil de Medicina de La Universidad de Sonora*, 31–32. <https://doi.org/10.59420/remus.4.2020.38>
- Ganzleben, I., Klett, D., Hartz, W., Götzfried, L., Vitali, F., Neurath, M. F., & Waldner, M. J. (2022). Multispectral optoacoustic tomography for the non-invasive identification of patients with severe anemia in vivo. *Photoacoustics*, 28, 100414. <https://doi.org/10.1016/j.pacs.2022.100414>

- Jaiswal, M., Srivastava, A., & Siddiqui, T. J. (2019). *Machine Learning Algorithms for Anemia Disease Prediction* (pp. 463–469). https://doi.org/10.1007/978-981-13-2685-1_44
- Jung, J., Rahman, Md. M., Rahman, Md. S., Swe, K. T., Islam, Md. R., Rahman, Md. O., & Akter, S. (2019). Effects of hemoglobin levels during pregnancy on adverse maternal and infant outcomes: a systematic review and meta-analysis. *Annals of the New York Academy of Sciences*, nyas.14112. <https://doi.org/10.1111/nyas.14112>
- Kesarwani, A., Das, S., Dalui, M., Kisku, D. R., Sen, B., Roy, S., & Basu, A. (2023). Non-invasive anaemia detection by examining palm pallor: A smartphone-based approach. *Biomedical Signal Processing and Control*, 79, 104045. <https://doi.org/10.1016/j.bspc.2022.104045>
- KILICARSLAN, S., CELIK, M., & SAHIN, Ş. (2021). Hybrid models based on genetic algorithm and deep learning algorithms for nutritional Anemia disease classification. *Biomedical Signal Processing and Control*, 63, 102231. <https://doi.org/10.1016/j.bspc.2020.102231>
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- LUIS ALVA CASTRO, & ANTONIO LEÓN ZAPATA. (2009). *ley 29414 Ley que establece que las personas usuarias de los servicios de salud.*
- Mitani, A., Huang, A., Venugopalan, S., Corrado, G. S., Peng, L., Webster, D. R., Hammel, N., Liu, Y., & Varadarajan, A. V. (2019). Detection of anaemia from retinal fundus images via deep learning. *Nature Biomedical Engineering*, 4(1), 18–27. <https://doi.org/10.1038/s41551-019-0487-z>
- Mustofa, S., Ahad, M. T., Emon, Y. R., & Sarker, A. (2024a). BDPapayaLeaf: A dataset of papaya leaf for disease detection, classification, and analysis. *Data in Brief*, 57, 110910. <https://doi.org/10.1016/j.dib.2024.110910>
- Mustofa, S., Ahad, M. T., Emon, Y. R., & Sarker, A. (2024b). BDPapayaLeaf: A dataset of papaya leaf for disease detection, classification, and analysis. *Data in Brief*, 57, 110910. <https://doi.org/10.1016/j.dib.2024.110910>

- Olivares G, M., & Walter K, T. (2003). CONSECUENCIAS DE LA DEFICIENCIA DE HIERRO. *Revista Chilena de Nutrición*, 30(3). <https://doi.org/10.4067/S0717-75182003000300002>
- Oreiro, M. B., Moreira, V. F., López, A., & Román, S. (2009). ¿QUÉ ES LA ANEMIA FERROPÉNICA? Sección coordinada por. In *REV ESP ENFERM DIG (Madrid)* (Vol. 101).
- Raj, R. J. S., Shobana, S. J., Pustokhina, I. V., Pustokhin, D. A., Gupta, D., & Shankar, K. (2020). Optimal Feature Selection-Based Medical Image Classification Using Deep Learning Model in Internet of Medical Things. *IEEE Access*, 8, 58006–58017. <https://doi.org/10.1109/ACCESS.2020.2981337>
- Randi, M. L., Bertozzi, I., Santarossa, C., Cosi, E., Lucente, F., Bogoni, G., Biagetti, G., & Fabris, F. (2020). Prevalence and Causes of Anemia in Hospitalized Patients: Impact on Diseases Outcome. *Journal of Clinical Medicine*, 9(4), 950. <https://doi.org/10.3390/jcm9040950>
- Santa María Pinedo, J. C., Ríos López, C. A., Rodríguez Grández, C., & García Estrella, C. W. (2021). Reconocimiento de patrones de imágenes a través de un sistema de visión artificial en MATLAB. *Revista Científica de Sistemas e Informática*, 1(2), 15–26. <https://doi.org/10.51252/rcsi.v1i2.131>
- Saputra, D. C. E., Sunat, K., & Ratnaningsih, T. (2023). A New Artificial Intelligence Approach Using Extreme Learning Machine as the Potentially Effective Model to Predict and Analyze the Diagnosis of Anemia. *Healthcare*, 11(5), 697. <https://doi.org/10.3390/healthcare11050697>
- Sarmiento-Ramos, J. L. (2020). Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica. *Revista UIS Ingenierías*, 19(4), 1–18. <https://doi.org/10.18273/revuin.v19n4-2020001>
- Vu, C., Bush, A., Choi, S., Borzage, M., Miao, X., Nederveen, A. J., Coates, T. D., & Wood, J. C. (2021). Reduced global cerebral oxygen metabolic rate in sickle cell disease and chronic anemias. *American Journal of Hematology*, 96(8), 901–913. <https://doi.org/10.1002/ajh.26203>
- Wahed, F. F., Juliette A., A., Sinthia, P., & Mary, G. A. A. (2022). *Detection of sickle cell anemia using SVM classifier*. 020006. <https://doi.org/10.1063/5.0074138>

Xinming, W., Hong, T. S., Ariffin, M. K. A. b. M., & Ismail, M. I. S. b. (2023). Comparative study on Leaf disease identification using Yolo v4 and Yolo v7 algorithm. *AgBioForum*, 25(1), 58–67.

Xinming, W., Hong, T. S., b.Mohd Ariffin, M. K. A., & b. Ismail, M. I. S. (2023). Comparative study on Leaf disease identification using Yolo v4 and Yolo v7 algorithm. *AgBioForum*, 25(1), 58–67.

ANEXOS

Anexo 1. Consentimiento informado



UNIVERSIDAD NACIONAL
DE SAN MARTÍN

GRUPO DE INVESTIGACIÓN IA

Consentimiento informado

Estimado/Estimada participante:

El Grupo de Investigación IA de la Universidad Nacional de San Martín se encuentra realizando un proyecto de investigación titulado "HemoTupunaApp: Detección clínica no invasiva de anemia ferropénica utilizando smartphones", desarrollado por Ing. Dr. Miguel Angel Valles Coral (Investigador Responsable), en el marco del Concurso de proyectos de investigación básica, aplicada y desarrollo tecnológico a nivel docente, financiado por la UNSM, período 2022 (Resolución N° 1063-2022-UNSM/CU-R). El presente documento tiene como finalidad hacerle conocer los detalles del estudio y solicitarle su consentimiento informado para participar en él.

1. Objetivo de la investigación

El objetivo de esta investigación es desarrollar un aplicativo móvil para la detección clínica no invasiva de anemia ferropénica utilizando smartphone en estudiantes de la Universidad Nacional de San Martín.

2. Breve descripción del proyecto

Un cuarto de la población mundial es anémico, siendo la anemia la etapa final de un prolongado periodo de deficiencia de hierro; en los estudiantes universitarios su deficiencia genera déficit de atención que repercute en su rendimiento académico dificultándoles terminar sus estudios en los plazos esperados. En esta investigación pretendemos determinar la efectividad de los resultados de la medición de anemia ferropénica mediante la app HemoTuponaApp respecto de un medidor de hemoglobina no invasiva. Para ello formularemos un modelo de reconocimiento de imágenes usando técnicas de inteligencia artificial al que se le proporcionarán videos, capturados mediante la cámara del celular y las etiquetas de nivel de hemoglobina detectado por el medidor no invasivo.

3. Metodología

Su participación consiste en la etapa de recolección de datos, es decir, la detección de hemoglobina utilizando un medidor no invasivo marca Rad-67™ y las grabaciones y fotos de su mano o partes de ella que servirán de referencia. Para lo cual, se realizarán los siguientes pasos en un promedio de 5 minutos:

Paso 1. Se hará conocimiento del presente consentimiento informado para su firma respectiva.

Paso 2. Se solicitará sus datos personales y antropométricos (medidos al momento de su participación): DNI, Correo electrónico, Edad, Sexo, Talla, Peso.

Paso 3. Se verificará la limpieza de su mano, de corresponder, se aplicará una desinfección y/o limpieza de uña cuando estén pintados o manchados.

Paso 4. Se medirá la cantidad de hemoglobina total (SpHb) con el medidor no invasivo (sin agujas o pinchazos) Rad-67™.

Paso 5. Se grabará un video de 10 segundos de su dedo índice con una cámara de celular marca Samsung Galaxy A73.

Paso 6. Se tomará una foto de la palma de su mano con otro celular del mismo modelo.

Paso 7. Se tomará una foto de su uña del dedo índice con otro celular del mismo modelo (Fin del proceso de recolección de datos.).

La intervención se llevará a cabo en el Centro Médico de la Universidad Nacional de San Martín, por profesionales técnicos en enfermería bajo la supervisión de los investigadores del proyecto: Ing. Dr. Miguel Angel Valles Coral, Ing. M. Sc. Richard Enrique Injante Oré, Lic. Enf. M. Sc. Luz Karen Quintanilla Morales, Dra. María Elena Farro Roque, Ing. Lloy Pool Pinedo Tuanama, Ing. Jorge Raul Navarro Cabrera e Ing. Luis Gerardo Salazar Ramírez.

Podrán participar universitarios que cumplan las siguientes condiciones:

1. Edad entre 18 y 25 años.
2. Cualquier sexo.



UNIVERSIDAD NACIONAL
DE SAN MARTÍN

GRUPO DE INVESTIGACIÓN IA

3. No tener enfermedades vinculados al virus de inmunodeficiencia humana (VIH, SIDA, etc.)
4. No tener antecedentes de fiebre amarilla, uta, etc.
5. No haber donado sangre en los últimos 3 meses.
6. No tener tatuajes en el último año

4. Su participación en el estudio

Su participación en este estudio es de carácter libre y voluntario, pudiendo solicitar ser excluido de esta investigación y que sus intervenciones no sean consideradas en este estudio sin justificación previa ni perjuicio para usted. Si usted participa en esta investigación lo hace bajo su expreso consentimiento informado que firma y autoriza.

5. Confidencialidad

La confidencialidad de su identidad será resguardada por las siguientes medidas: a) Solo los investigadores del proyecto tendrán acceso a los datos proporcionados en ellas. b) Dadas las características del estudio los datos serán usados solamente en instancias académicas de investigación y aquellas propias de la divulgación investigativa. Asimismo, el Investigador Responsable asume un compromiso de confidencialidad para resguardar la identidad de todos los involucrados en este estudio.

6. Beneficios

Producto de su participación no se generan incentivos económicos ni de ningún tipo. Cabe destacar que su participación en este estudio tampoco tiene asociado ningún tipo de costo. En tal sentido, creemos que la investigación produce más bien beneficios indirectos en sus participantes puesto que les permitirá detectar de forma no invasiva la cantidad de hemoglobina en su sangre a partir del medidor Rad-67™, para tomar acciones preventivas o correctivas en su salud en caso de identificar niveles altos o alarmantes de anemia ferropénica.

7. Riesgos o molestias asociadas a la participación

Si se generara alguna controversia o molestia producto de algún paso del proceso de recolección de datos, el Investigador Responsable procurará contener emocionalmente y brindar la asistencia requerida al participante.

8. Almacenamiento y resguardo de la información

Toda la información que se recabe de esta investigación estará siempre resguardada y al cuidado del Investigador Responsable. Tanto este consentimiento, como los datos o documentos impresos que se generen y sean necesarios utilizar se almacenarán de forma permanente, teniendo la oportunidad de realizar tratamientos sobre ella para fines académicos de investigación.

9. Acceso a los resultados de la investigación

Los participantes podrán consultar la información que ha generado en cualquier momento durante la ejecución del proyecto previa solicitud al Investigador Responsable del estudio, quien se compromete a brindar cooperación y proponer vías para tal acceso. Asimismo, el Investigador Responsable se compromete con cada participante a enviar el informe de investigación que se genere al final del estudio a los correos electrónicos respectivos, así también copia de los artículos científicos que pudieran resultar del estudio.



**UNIVERSIDAD NACIONAL
DE SAN MARTÍN**

GRUPO DE INVESTIGACIÓN IA

10. Compromiso

Por su aceptación los participantes se comprometen a proveer información real en cada instancia que sea solicitada y participar de forma respetuosa y responsable en cada paso del proceso de recolección de datos.

11. Contacto

Si usted tiene preguntas acerca de sus derechos como participante de este estudio, reclamos o dudas acerca de esta investigación, por favor contáctese con el Investigador Responsable, Ing. Dr. Miguel Angel Valles Coral, Celular: 942 023 414, Correo electrónico: mavalles@unsm.edu.pe

En síntesis,

Declaro conocer los términos de este consentimiento informado, los objetivos de la investigación, las formas de participación, de los costos y riesgos implicados, y del acceso a la información y resguardo de información que sea producida en el estudio. Reconozco que la información que provea en el curso de esta investigación es estrictamente confidencial y anónima. Además, esta será usada solo con fines de difusión científica.

He sido informado/informada de que puedo hacer preguntas sobre el proyecto en cualquier momento y que puedo retirarme del mismo cuando así lo decida, sin tener que dar explicaciones ni sufrir consecuencia alguna por tal decisión.

Nombre completo del participante:.....

DNI: **Correo electrónico:**

Edad: **Sexo:** **Talla:** **Peso:**

Firma

Investigador Responsable
Ing. Dr. Miguel Angel Valles Coral
Grupo de Investigación IA
Universidad Nacional de San Martín

Se deja constancia en este instante que este documento (consentimiento informado) será firmado a dos copias, quedando una de ellas en manos de la investigador responsable y la otra copia en manos del participante.

Anexo 2. Ficha de recolección de datos



UNIVERSIDAD NACIONAL
DE SAN MARTÍN

GRUPO DE
INVESTIGACIÓN DE IA

FICHA DE RECOLECCIÓN DE DATOS

Fecha: ___ / ___ / 2023

I. Datos de identificación

Apellidos y Nombres: _____
 Edad: _____
 Sexo: Femenino / Masculino
 Escuela Profesional: _____

II. Síntomas de anemia experimentados en el último mes. Marcar con una X de acuerdo a la respuesta del estudiante

Fatiga
 Debilidad
 Latidos del corazón irregulares
 Dificultad para respirar
 Mareos o aturdimiento
 Dolor en el pecho
 Manos y pies fríos
 Dolores de cabeza
 Pregunta adicional: ¿Es vegetariano o vegano? Si / No

III. Funciones vitales

Pulso:
 Respiración:
 Temperatura:
 Presión arterial:

IV. Datos antropométricos

Peso:
 Talla:
 IMC:
 Circunferencia abdominal:

V. Resultados de prueba no invasiva

Hemoglobina:

Anemia	
Mujer	Varón
<input type="checkbox"/> Normal (12 a más)	<input type="checkbox"/> Normal (13 a más)
<input type="checkbox"/> Leve (11,0 - 11,9)	<input type="checkbox"/> Leve (11,0 - 12,9)
<input type="checkbox"/> Moderada (8,0 - 10,9)	<input type="checkbox"/> Moderada (8,0 - 10,9)
<input type="checkbox"/> Severa (<8,0)	<input type="checkbox"/> Severa (<8,0)

Frecuencia cardíaca:
 Oxígeno en sangre:

Anexo 3. Primera prueba de recolección de datos



Anexo 4. Área de recolección de datos (centro médico universitario – UNSM)



Anexo 5. Matriz de consistencia.

MATRIZ DE CONSISTENCIA					
Detección no invasiva de la anemia ferropénica mediante reconocimiento de imágenes de la palma de la mano					
PROBLEMAS	OBJETIVOS	HIPOTESIS	VARIABLES	DIMENSIONES	METODOLOGIA
GENERAL ¿Cómo se puede desarrollar un método de detección no invasiva de la anemia ferropénica utilizando imágenes de la palma de la mano para mejorar la eficiencia y precisión del diagnóstico?	GENERAL Detectar la anemia ferropénica basado en un modelo de visión artificial como método no invasivo utilizando imágenes de la palma de la mano.	GENERAL Existe una correlación significativa entre las características identificadas en las imágenes de la palma y la presencia de anemia por deficiencia de hierro.	Variable independiente: Reconocimiento de imágenes de la palma de la mano.	Características físicas de la palma. Color, textura, presencia de patrones asociados con deficiencia de hierro.	1.Tipo de estudio: Experimental 2.Diseño de estudio: Experimental, factorial. Población 3.Tipo de muestra: Estudiantes universitarios con niveles conocidos de hemoglobina e información clínica relevante. 4.Tamaño de Muestra: 900 estudiantes. 5.Técnicas e instrumentos: Variable 1: Reconocimiento de imágenes de la palma de la mano. Técnica: Recolección de datos clínicos. Instrumento: Hoja de información clínica relevante de elaboración propia. Variable 2: Detección no invasiva de anemia ferropénica. Técnica: Procesamiento y entrenamientos del modelo de Deep Learning. Instrumento: Cuatro modelos de Deep Learning uno de creación propia.
ESPECIFICOS Realizar campaña de recolección de imágenes de la palma de la mano, junto a información clínica relevante obtenida por el dispositivo no invasivo.	ESPECIFICOS Diseñar una metodología para recopilar un conjunto de datos de alta calidad que permita entrenar y validar el modelo de Deep Learning.	ESPECIFICOS La calidad de los datos recolectados tiene un impacto significativo en la precisión del modelo de aprendizaje profundo desarrollado.		Algoritmo del modelo. Normal (>12 g/dL), anemia leve (10-11.9 g/dL), anemia severa (<10 g/dL).	
Desarrollar un modelo de Deep Learning para la clasificación de imágenes de la palma de la mano según los niveles de hemoglobina en sangre.	Entrenar y validar un modelo de Deep Learning que clasifique las imágenes según las características asociadas con niveles de hemoglobina en sangre.	Un modelo de aprendizaje profundo es capaz de clasificar de manera precisa las imágenes de la palma de la mano para detectar niveles bajos de hemoglobina.	Variable dependiente: Detección no invasiva de anemia ferropénica.	Validación y entrenamiento creación del modelo y comparación frente a los otros tres modelos existentes.	
Comparar y evaluar las métricas de rendimiento del modelo propuesto y las de otros tres modelos existentes	Determinar cuál de los modelos evaluados presenta mejores métricas de precisión, sensibilidad y especificidad para la detección de anemia ferropénica.	El modelo propuesto tiene un rendimiento igual o superior al de los modelos existentes evaluados.		Resultado del procesamiento con el algoritmo Sensibilidad y precisión	

Deteccción no invasiva de la anemia ferropénica mediante reconocimiento de imágenes de la palma de la mano

por Pool Valles Saavedra

Fecha de entrega: 27-jun-2025 09:20a.m. (UTC-0500)

Identificador de la entrega: 2706884672

Nombre del archivo: TESIS_Pool_Antony_Valles_Saavedra_16.06.2025.docx (2.95M)

Total de palabras: 11719

Total de caracteres: 70693

Detección no invasiva de la anemia ferropénica mediante reconocimiento de imágenes de la palma de la mano

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	repositorio.unsm.edu.pe Fuente de Internet	4%
2	Submitted to Universidad Nacional de San Martín Trabajo del estudiante	2%
3	Submitted to Coventry University Trabajo del estudiante	1%
4	tesis.unsm.edu.pe Fuente de Internet	1%
5	hdl.handle.net Fuente de Internet	1%
6	www.coursehero.com Fuente de Internet	1%
7	www.researchgate.net Fuente de Internet	1%
8	qa1.scielo.br Fuente de Internet	<1%