








Inteligencia Artificial aplicada a las pericias de Imágenes: Avances en el Ámbito Forense

Sandra E. Roger¹ , Manuel A. Latorre Rosales¹ ,
Germán A. Braun¹ , Laura A. Cecchi¹ , Santiago A. Villarroel¹ ,
Carlos D. Campos Fuentes¹ , and Gabriel O. Jerez² 

¹ GILIA, Facultad de Informática. Universidad Nacional del Comahue
{roger, manuel.latorre, german.braun, laura.cecchi}@fi.uncoma.edu.ar,
{santiago.villarroel,daniel.campos}@est.fi.uncoma.edu.ar

² Cuerpo Médico Forense del Poder Judicial de Neuquén
GabrielOmar.Jerez@jusneuquen.gov.ar

Resumen El análisis forense desempeña un papel fundamental en los procedimientos legales que involucran aspectos médicos y de salud. Su importancia radica en que proporciona una evaluación imparcial basada en conocimientos médicos científicos. Asimismo, las pericias judiciales forenses contribuyen a la valoración de daños, atribución de responsabilidades e interpretación de evidencia médica.

El Cuerpo Médico Forense del Poder Judicial de Neuquén ha recopilado una considerable cantidad de datos sobre pericias judiciales llevadas a cabo, que podrían ser utilizados para generar Sistemas Inteligentes, que asistan a los profesionales en la toma de decisiones.

De esta manera, surge la necesidad de entender, procesar y manipular tanto imágenes como los informes de pericias médicos-legales que las acompañan.

En este trabajo se presentan los resultados del desarrollo de un Sistema Inteligente para el procesamiento de imágenes, que permite determinar si estamos en presencia de una equimosis. Para ello se configuró y entrenó una red neuronal convolucional a partir de un conjunto de datos de acceso público. Se realizaron pruebas para evaluar el rendimiento de la red a partir de imágenes en blanco y negro y en color, considerando que el volumen de cómputo implicado en el entrenamiento para ambos tipos de imágenes resulta un factor importante a tener en cuenta.

Asimismo, se presentan dos enfoques para la extracción de datos a partir de informes de pericias forenses, los cuales pueden estar en formato impreso o manuscrito.

Además, se desarrolló una aplicación móvil que permite acceder al modelo entrenado y determinar, a partir de una imagen, si ésta corresponde a una equimosis, indicando el porcentaje de confiabilidad asociado al resultado.








Keywords: Análisis forense digital · Pericias médico-legales · Procesamiento de Imágenes · Redes Neuronales

Received May 2025; Accepted June 2025; Published July 2025



This work is under a Creative Commons
Attribution – NonComercial – Share Alike 4.0 International License

Artificial Intelligence Applied to Image Forensics: Advances in the Forensic Field

Sandra E. Roger¹ , Manuel A. Latorre Rosales¹ ,
Germán A. Braun¹ , Laura A. Cecchi¹ , Santiago A. Villarroel¹ ,
Carlos D. Campos Fuentes¹ , and Gabriel O. Jerez² 

¹ GILIA, Facultad de Informática. Universidad Nacional del Comahue
{roger, manuel.latorre, german.braun, laura.cecchi}@fi.uncoma.edu.ar,
{santiago.villarroel,daniel.campos}@est.fi.uncoma.edu.ar

² Cuerpo Médico Forense del Poder Judicial de Neuquén
GabrielOmar.Jerez@jusneuquen.gov.ar

Abstract. Forensic analysis plays a crucial role in legal proceedings involving medical and health-related matters. Its significance lies in providing an impartial assessment grounded in scientific medical knowledge. Additionally, forensic evaluations contribute to damage assessment, accountability assignment, and interpretation of medical evidence.

The Forensic Medical Corps of the Judicial Branch of Neuquén has compiled a substantial amount of data on judicial assessments conducted, which could be utilized to develop Intelligent Systems that assist professionals in their decision-making processes.

Consequently, there is a need to understand, process, and manipulate both images and the accompanying medical-legal reports.

This work presents the results of the development of an Intelligent System for image processing, capable of determining the presence of ecchymosis. To achieve this, a convolutional neural network was configured and trained using a publicly available dataset. Tests were conducted to evaluate the network's performance with both black-and-white and color images, considering that the computational volume involved in training for both types of images is a critical factor to be addressed.

Moreover, two approaches for data extraction from forensic reports are presented, which can be either printed or handwritten.

Additionally, a mobile application was developed that allows users to access the trained model and determine, based on an image, whether it corresponds to ecchymosis, indicating the associated reliability percentage of the result.

Keywords: Digital Forensic Analysis · Forensic Examinations · Image Processing · Neural Networks

1. Introducción y Motivación

El análisis forense juega un papel fundamental en los casos jurídicos que involucran cuestiones médicas y de salud. Su importancia radica en que proporciona una evaluación imparcial basada en conocimientos médicos científicos. Asimismo, las pericias judiciales forenses (PJF) colaboran en valorar daños, determinación de responsabilidades e interpretación de evidencia médica.

El rol de las PJF ha adquirido una relevancia crítica en el sistema de justicia del país, siendo clave en la investigación de crímenes y violaciones a los derechos humanos, contribuyendo a la búsqueda de la verdad, la identificación de responsables y la obtención de pruebas sólidas para asegurar juicios justos y transparentes. Particularmente, en casos de violencia de género [1][2][3], las PJF han sido instrumentales para entender la magnitud del problema, comprender sus implicaciones psicosociales y, sobre todo, colaborar en brindar una respuesta adecuada y sensible a las víctimas.

El Cuerpo Médico Forense del Poder Judicial de Neuquén (CMFPJN), al igual que otros institutos forenses de Argentina, utiliza las imágenes fotográficas como respaldo para la emisión de informes periciales forenses, tanto para la justicia civil como penal. En este sentido, los servicios clínicos forenses, que incluyen entre otros la interpretación de las imágenes como la datación de contusiones, son requeridos para respaldar las denuncias y utilizados como prueba, lo que puede ser determinante para la justicia.

En este trabajo nos centramos en un tipo de lesiones contusas, denominadas simples en la medicina legal. Una fuerza contundente actuando con o contra el cuerpo produce, entre otras lesiones, las denominadas equimosis o cardenales, que ocurren por laceración del tejido celular subcutáneo, generando la salida de sangre desde los pequeños vasos sanguíneos por debajo de la piel, dándole una especial coloración que se modificará con el paso de los días por oxidación de la hemoglobina contenida en ella, infiltrando los tejidos en forma de láminas. En el caso de las equimosis producidas por succión, se denominan *sugilaciones* de valor importante en las agresiones sexuales. Cuando en lugar de infiltrar los tejidos la sangre se acumula entre sus planos en forma de bolsa subcutánea se denomina hematoma, que es fluctuante y prominente. Corresponden a rupturas de vasos de mayor tamaño y habitualmente son producto de fuerzas tangenciales. Los hematomas de gran tamaño se conocen como bolsas sanguíneas [4].

Las equimosis traumáticas suelen ser amorfas y no proporcionan ninguna información sobre los objetos contundentes con los que se formaron. Sin embargo, la forma, la ubicación y el color de algunas equimosis ofrecen pistas significativas para la determinación de su etiología, el momento de ocurrencia y el propósito del evento [5][6].

La utilización de la fotografía en el ámbito pericial se enmarca legalmente a través del Código Procesal Penal de la Nación en el Art. 184, 4° ítem, art. 274 (reconocimiento por fotografía) y el Código Procesal Penal de la Provincia de Neuquén, en el art. 14 y 77, no existiendo una regulación específica respecto de las técnicas utilizadas. No obstante existen protocolos específicos [7][8], de los

que remarcamos el argentino sobre *Actuación para la Investigación Científica del Lugar del Hecho* [9].

CMFPJN ha recopilado una gran cantidad de datos sobre las pericias judiciales realizadas, los cuales podrían ser utilizados para generar Sistemas Inteligentes que colaboren en la asistencia a los profesionales en sus decisiones. Así, surge la necesidad de comprender, procesar y manipular imágenes, así como los informes de las pericias médico-legales que las acompañan.

En este contexto, uno de los primeros problemas a abordar es identificar, a partir de una imagen, el tipo de lesión, en especial si se trata de una equimosis. Desde el siglo pasado, la Inteligencia Artificial ha sido aplicada a diversos campos de especialización, entre los que se encuentran la medicina [10], la justicia y el derecho penal [11]. Los estudios [12][13][14] se encuentran estrechamente relacionados y plantean un sistema que toma como entrada una imagen previamente identificada como equimosis y estiman la fecha de su ocurrencia. Por otro lado, una aplicación que delimita, a partir de una imagen, el área de un posible cardenal se puede acceder en [15].

Es importante destacar que ninguno de los trabajos analizados permite la identificación precisa del tipo de lesión. Esta limitación subraya la necesidad de investigaciones adicionales en el campo de la medicina forense para desarrollar métodos de clasificación. Por otra parte, hasta donde sabemos, no existe en la literatura científica evidencia previa de trabajos análogos en el contexto argentino.

Desde el punto de vista forense, la necesidad de utilizar sistemas basados en Inteligencia Artificial como soporte para la toma de decisiones en este ámbito se basa en dos premisas. La primera es la necesidad de disminuir (o eliminar) los sesgos cognitivos en la interpretación de las imágenes, contribuyendo a otorgar un marco objetivo a la pericia. El segundo objetivo es estandarizar los procedimientos, lo que será particularmente útil para aquellas jurisdicciones donde la casuística es muy baja. Como beneficio secundario, no menor en importancia, es la posibilidad de generar bases de datos accesibles a la investigación y planificación.

Los resultados presentados en este trabajo, representan un avance en el desarrollo de un Sistema Inteligente para el procesamiento de imágenes, que permite determinar si estamos en presencia de una equimosis. Con el fin de lograr esto, se configuró y entrenó una red neuronal convolucional utilizando un conjunto de datos de acceso público. Se llevaron a cabo pruebas para evaluar el rendimiento de la red a partir de imágenes tanto en escalas de grises como a color. Considerando que el volumen de cómputo implicado en el entrenamiento para ambos tipos de imágenes resulta un factor importante a tener en cuenta.

Asimismo, se desarrolló una aplicación móvil que posibilita el acceso al modelo entrenado y la identificación de una posible equimosis a partir de una imagen, proporcionando un porcentaje de confiabilidad asociado al resultado.

Además de las imágenes, el CMFPJN cuenta con informes de pericias forenses que incluyen información valiosa sobre lesiones, aunque muchos no están digital-

izados. Se presentan dos enfoques para la extracción de datos a partir de estos informes con el fin de vincular eficientemente las imágenes con sus descripciones.

Los resultados de esta investigación y las acciones que se lleven a cabo a partir de ellos, estarán enmarcados legalmente en las *Recomendaciones para una Inteligencia Artificial Fiable*, Disposición 2/2023, Subsecretaría de Tecnologías de la Información, particularmente en lo referente a la ética de los datos.

Este trabajo está estructurado como sigue. En la siguiente Sección 2 se describen la preparación del corpus de las imágenes y el modelo propuesto de la red neuronal convolucional. Asimismo, se detallan y explican los experimentos basados en imágenes en escala de grises y los basados en imágenes a color y los resultados obtenidos. En la Sección 3 se introduce una aplicación móvil con la que puede consultarse el modelo desarrollado. Luego, en la Sección 4 se analizan las líneas de acción actuales y los desafíos próximos a abordar Finalmente, se presentan las conclusiones y trabajos futuros.

2. Modelo Profundo para Clasificación de Imágenes de Equimosis

En esta sección presentamos el modelo profundo para clasificación de imágenes de equimosis propuesto para este trabajo, la preparación del corpus de imágenes para entrenamiento, los experimentos realizados y sus resultados. El principal componente del modelo es una arquitectura basada en redes neuronales convolucionales. Estas redes han mostrado buenos resultados en trabajos relacionados al entendimiento y a la clasificación de imágenes en otras especialidades de la medicina, como se detalla en la literatura [16,17,18,19,20,21,13].

2.1. Preparación de Imágenes

Para esta investigación inicial sobre equimosis, se realizó la búsqueda Web para la adquisición de un corpus de imágenes, dado que no se contaba con uno propio. Este corpus está compuesto de imágenes a color de equimosis, así como imágenes de áreas corporales sin equimosis, es decir, piel sana.

Posteriormente, se sometió este conjunto a un proceso manual de procesamiento de imágenes con el fin de enfocarse en las áreas de interés y eliminar elementos no deseados. Este proceso incluyó la edición de las imágenes para eliminar información irrelevante, como prendas de vestir u objetos de fondo, y la exclusión de imágenes con problemas de iluminación o de baja calidad. No se aplicaron consideraciones adicionales en cuanto a las dimensiones de las imágenes.

El conjunto resultante consta de 135 imágenes, de las cuales 66 representan áreas con equimosis y 69 representan áreas sin ellas. Para el proceso de aprendizaje, el corpus se dividió en dos, uno para el entrenamiento y otro para la validación. Se seleccionaron aleatoriamente 102 imágenes con y sin equimosis, en igual proporción, para el entrenamiento, y 33 imágenes (15 con equimosis) para el proceso de validación.

2.2. Arquitectura de Aprendizaje Profundo

Con el propósito de clasificar imágenes, se utilizó una *red neuronal convolucional (CNN)* [22,23,24,25]. Las *CNN* son una arquitectura de aprendizaje profundo diseñadas para automatizar la extracción de características y descubrir patrones relevantes para tareas de clasificación. Estas redes consisten típicamente en varios niveles, que incluyen capas de convolución, capas de agrupación y capas de clasificación.

La Fig. 1 muestra los detalles de la configuración del modelo implementado en este trabajo. A lo largo de los niveles de convolución y agrupación, se capturan progresivamente características visuales y se componen en estructuras más complejas a medida que la red iterativa profundiza en el análisis de la imagen. Finalmente, la capa de clasificación utiliza una conexión *sigmoide* para generar las probabilidades que indican la clasificación de muestra, en cada clase específica.

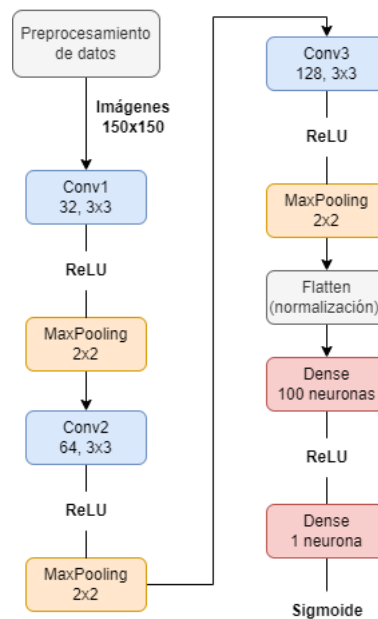


Fig. 1. Red Neuronal Convolutacional propuesta para la determinación de equimosis.

En el nivel de preprocesamiento, se extraen las fragmentos de imágenes conteniendo lesiones, que incluían tanto equimosis como manchas generales. Además, se extrajeron porciones de imágenes sin lesiones para conformar el corpus inicial. Debido a que los recortes presentes son de diferentes tamaños, se estandarizó automáticamente el tamaño a fin de contar con imágenes de 150x150 píxeles.

Para las imágenes en tonalidades de grises, el rango para los valores de los elementos de matriz (escalares) es $[0,255]$, mientras que las imágenes a color,

cuentan con 3 canales del *RGB* ($[0,255],[0,255],[0,255]$). Para nuestro proceso de aprendizaje es necesario normalizar dichas imágenes. Por esta razón, estos valores se ajustaron al rango de 0 a 1; $[0,1]$ en el caso de imágenes en blanco y negro y $([0,1],[0,1],[0,1])$ para determinar los colores *RGB*.

Una vez completado el procesamiento de las imágenes, éstas fueron incorporadas como entrada a las capas de convolución y agrupamiento. El proceso de convolución se repitió tres veces con el objetivo de extraer las características más relevantes de las imágenes. Durante este proceso, se emplearon filtros de tamaño 3×3 . Por otro lado, en las etapas de agrupamiento (*pooling*), se aplicaron filtros de tamaño 2×2 . En cada iteración de este proceso, la cantidad de filtros fue incrementada progresivamente, utilizando 32 filtros en la primera convolución, 64 en la segunda, y finalmente 128 en la tercera convolución.

Luego de que las características de las imágenes son extraídas mediante el proceso de convolución, la salida de la última capa de convolución se transforma de matrices multidimensionales a un vector unidimensional. Este paso se realiza mediante el módulo de *Flatten* (*normalización*) de la arquitectura, como muestra la Fig. 1. El objetivo es preparar los datos para la fase de clasificación de la red neuronal.

En la fase de clasificación, la salida del módulo de *Flatten* alimenta una capa densa que consta de 100 neuronas. Esta capa densa permite aprender características más abstractas de las imágenes extraídas durante las convoluciones. Posteriormente, la salida de esta capa se conecta a una capa final de salida, que consta de una única neurona, utilizada para realizar la tarea específica de clasificación.

Los experimentos se llevaron a cabo mediante el entrenamiento a lo largo de 100 épocas. Finalmente, se selecciona el modelo que muestre el mejor rendimiento en cada época, con los datos de validación durante la etapa de entrenamiento.

2.3. Experimentos y Resultados

Considerando que la calidad del modelo está profundamente influenciada por los datos de entrada, se decidió trabajar con dos enfoques, uno en el cual las imágenes se procesan en escala de grises y otro con las imágenes a color.

Respecto a los resultados, el enfoque en escala de grises logró modelos ligeramente inferiores al 90% de precisión. En la gráfica de la Fig. 2 se puede observar como la precisión del conjunto de entrenamiento evoluciona correctamente (línea gris). Se puede observar que la precisión del conjunto de datos de prueba (línea azul) también se incrementa en una proporción similar al entrenamiento. Si bien no logra equipararse, el margen observado de aproximadamente 0.1 puntos es aceptable y demuestra un funcionamiento correcto del modelo. Esta diferencia entre ambas líneas se debe a que es poco probable que el modelo pueda adaptarse perfectamente a todos los detalles y al ruido en el conjunto de entrenamiento. Además, es importante destacar que ninguna de las dos curvas llega al valor máximo de 1, por lo que no se llegó a tener sobre ajuste.

En la Fig. 3 se puede observar la curva de error a lo largo de las épocas. Esta métrica busca minimizarse, ya que indica cuán diferentes son las predicciones del




Fig. 2. Evolución de la precisión a lo largo de las épocas durante el entrenamiento del modelo con escala de grises

modelo en comparación con los valores reales en el conjunto de entrenamiento. Como se puede observar, tanto para el conjunto de entrenamiento (línea gris) como para el conjunto de validación (línea azul) se consigue una pérdida menor al 0.5, número que, considerando que el set de datos es perfectible, ya sea por más y/o mejores imágenes o por medio de técnicas de ampliación del conjunto de datos, los resultados son aceptables. Además, la pérdida para ambos conjuntos desciende de forma similar, lo que muestra que el modelo no se está adaptando demasiado a los datos de entrenamiento y generaliza correctamente.

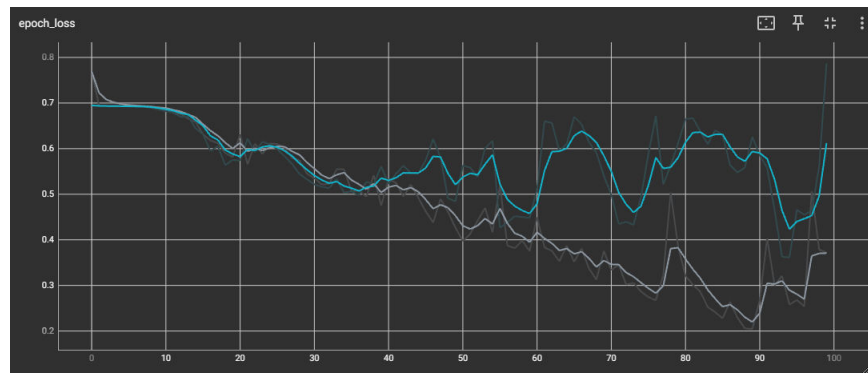


Fig. 3. Evolución de la pérdida a lo largo de las épocas durante el entrenamiento del modelo con escala de grises

El enfoque a color dio como resultado modelos de hasta 90% de precisión, incluso alguno ligeramente superior. Como se observa en la Fig. 4, la precisión de los conjuntos tanto de entrenamiento (línea roja) como de validación (línea azul)




Fig. 4. Evolución de la precisión a lo largo de las épocas durante el entrenamiento del modelo a color




Fig. 5. Evolución de la pérdida a lo largo de las épocas durante el entrenamiento del modelo a color

evoluciona correctamente incrementando en proporciones similares. Además, se mantiene un margen entre ambas curvas similar al observado en el modelo con escalas de grises. En cuanto a la pérdida o error, la Fig. 5 muestra resultados inferiores al 0.4 con los datos de validación (línea azul), lo cual, teniendo en cuenta lo descrito en el enfoque anterior, se puede considerar aceptable.

A partir de las observaciones previamente mencionadas, se puede concluir inicialmente que ambos modelos funcionan de forma correcta, con precisión similar. Sin embargo, el costo computacional de procesar imágenes a color es sensiblemente mayor respecto al conjunto de datos de imágenes en escala de grises. Cabe destacar que cuando las imágenes a ser clasificadas presentan aspectos como cabello, vello, o sombras el modelo presenta un peor rendimiento en cuanto a las métricas evaluadas. Esto tiene relación directa con los criterios que utilizamos a la hora de construir el corpus, ya que es en esa etapa donde filtramos las imágenes que contienen estas características no deseadas, y por lo tanto, las mismas no pertenecen al conjunto de entrenamiento.

3. Aplicación móvil

Con el fin de garantizar la accesibilidad y utilidad del modelo propuesto, se ha desarrollado un prototipo de una aplicación, que permite determinar a partir de una imagen, si ésta corresponde a una equimosis, indicando el porcentaje de confiabilidad asociado al resultado.

Esta aplicación fue implementada con un modelo cliente-servidor. El cliente, que fue desarrollado utilizando *React Native*³ y *Typescript*⁴, ofrece un *GUI* al usuario que le permite elegir una imagen. En este sentido, se ofrece la posibilidad de seleccionar una fotografía desde la galería de imágenes del dispositivo móvil. Esta funcionalidad amplía las opciones de los usuarios al permitirles elegir imágenes existentes para su procesamiento a través de la aplicación. Asimismo, la *GUI* posibilita la selección de imágenes a partir de la captura de fotografías, desde la cámara del dispositivo móvil.

Una vez seleccionada la imagen, el cliente la envía, en forma automática, al servidor para ser procesada. El servidor ofrece un Servicio Web implementado en *Python*⁵, a través de una *API*: recibe imágenes individuales a través de solicitudes *HTTP/S*, las procesa, ejecuta el modelo propuesto de clasificación de imágenes a color y envía al cliente el resultado obtenido. En la Fig. 6 se muestran capturas de pantalla de los resultados obtenidos después de procesar 2 imágenes diferentes.

Además de facilitar el acceso al modelo de clasificación de equimosis, esta estructura ofrece ventajas significativas en términos de escalabilidad y distribución de la carga de procesamiento. Si se alojara el servidor en un servicio de nube, la carga de trabajo puede distribuirse de manera eficiente, lo que garantiza una alta escalabilidad del sistema, tanto en el procesamiento como en el almacenamiento

³ <https://reactnative.dev/>

⁴ <https://www.typescriptlang.org/>

⁵ <https://www.python.org/>



Fig. 6. Capturas de pantalla de la aplicación donde se muestran los resultados obtenidos después de procesar diferentes imágenes.

de datos. Esta capacidad de escalabilidad asegura que el sistema pueda adaptarse fácilmente a futuras demandas y requerimientos, proporcionando una experiencia fluida y eficiente.

Por otra parte, utilizar *React Native* para la implementación del cliente asegura su portabilidad, ya que posibilita que la aplicación pueda ejecutarse en múltiples sistemas operativos, como *iOS* y *Android*, con un código base compartido. Esto reduce considerablemente el esfuerzo y el tiempo de desarrollo al no requerir la creación de aplicaciones separadas para cada plataforma, lo que permite una mayor eficiencia en el proceso de desarrollo y una mayor accesibilidad para los usuarios finales.

Asimismo, este primer prototipo de la aplicación móvil al ser implementado como una *API* y al utilizar protocolos de comunicación web estándar, presenta un alto grado de desacople, por lo que resulta sencillo integrarlo a herramientas ya desarrolladas, que requieran de esta funcionalidad.

Desde el punto de vista del hardware, esta aplicación no requiere para la captura y el procesamiento de las imágenes de ninguna cámara web, ni de tarjeta gráfica de video dedicadas ni de características especiales. Así, con un dispositivo móvil con una cámara convencional es posible ejecutarla.

4. Líneas de acción en curso y retos actuales

4.1. Extracción de datos a partir de informes de pericias forenses

En la actualidad, el CMFPJN ha acumulado un conjunto de informes completos de pericias forenses, los cuales incluyen, además de las imágenes pertinentes,

textos que contienen información contextual, fechas relevantes y detalles sobre los instrumentos presumiblemente utilizados para causar las lesiones, entre otros datos significativos.

Dada la existencia de estos informes, aunque no todos han sido digitalizados, se vislumbra un alto potencial considerable para su integración en la generación de una base de conocimiento que brinde información específica acerca de las imágenes analizadas. Este enfoque contribuiría a un mejor entendimiento del contexto de las lesiones y a su adecuada clasificación. En este sentido, la creación de un corpus de datos estructurado, contextualizado en la realidad de Neuquén, facilitaría el acceso a esta información y contribuiría una base sólida para el entrenamiento futuro de modelos de aprendizaje automático, aumentando de este modo la efectividad y precisión del análisis forense.

Para avanzar en esta dirección, se consideró digitalizar los informes, a fin de extraer información relevante de las pericias y detalles específicos de las imágenes descritas textualmente. El sistema de reconocimiento óptico de caracteres (*OCR*, por sus siglas en inglés *Optical Character Recognition*) es una tecnología de vanguardia que permite identificar automáticamente a partir de una imagen, los símbolos y caracteres de un alfabeto, convirtiendo imágenes en datos editables y con capacidad de búsqueda. Con este sistema se busca trazar una relación representada a partir de los registros de la forma (*imagen, descripción*), conformando una base de conocimiento. De este modo, logramos filtrar información específica deseada de manera eficiente, sin necesidad de leer el informe completo.

En esta etapa, se comenzó realizando algunas pruebas con la herramienta web *Image Text Vision App*⁶[26]. Esta herramienta es capaz de procesar imágenes en diferentes formatos de hasta 10MB. Además, tiene la capacidad de extraer texto de fuentes manuscritas o impresas.

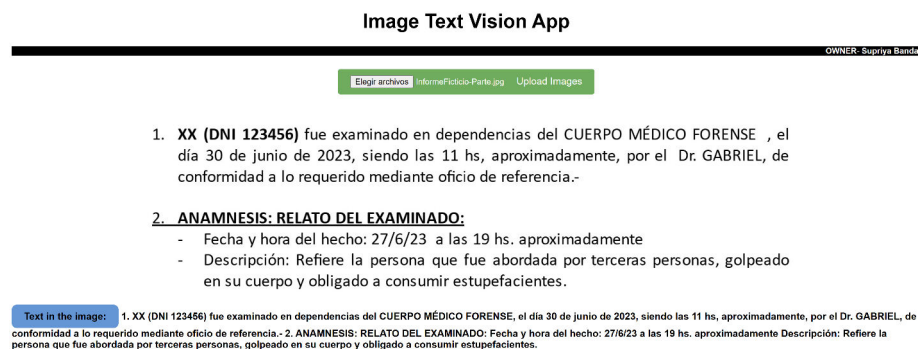


Fig. 7. Prueba de la herramienta *Image Text Vision App* para digitalización de texto impreso.

⁶ <https://digital-forensics-text-vision.netlify.app/>

Las pruebas realizadas sobre un informe completamente ficticio en formato impreso y manuscrito. En la Fig. 7 se puede observar cómo la herramienta es capaz de reconocer y transcribir a la perfección el texto impreso que aparece en la imagen elegida. En la parte superior se puede apreciar la imagen del informe y en la parte inferior (a partir del texto *Text in the image*) se presenta el texto editable que extrae la herramienta. En este caso, la herramienta demostró un desempeño muy satisfactorio, reconociendo con precisión la totalidad de los caracteres presentados.

En la Fig. 8 se observa la funcionalidad de la herramienta de reconocer y extraer texto con fuente manuscrita en la imagen seleccionada. Nótese que el texto manuscrito, fue escrito sobre un fondo cuadrículado, lo que aumenta la complejidad de entendimiento de la letra. En esta prueba, la herramienta presentó dificultades para reconocer caracteres en texto manuscrito cursivo. Cabe destacar que no se efectuó ningún esfuerzo adicional para estilizar la escritura de manera caligráfica, en la muestra. Sin embargo, respecto del texto en letra imprenta mayúscula manuscrita, se observó un buen rendimiento, similar al obtenido con texto impreso, con una alta tasa de reconocimiento. Finalmente, con letra imprenta minúscula manuscrita, el desempeño fue variable, con una precisión moderada en la identificación de caracteres.

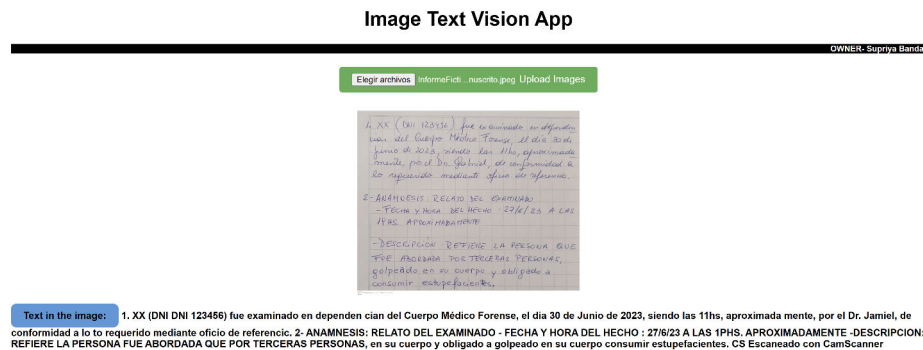


Fig. 8. Pruebas de la herramienta *Image Text Vision App* para digitalización de texto manuscrito.

Estos resultados sugieren que la herramienta es eficaz para extraer textos impresos y manuscritos, aunque se presentan algunas limitaciones respecto de los textos manuscritos en letra cursiva, influenciada por el estilo de la escritura. Esta dificultad para reconocer grafía ilegible no es exclusiva de la herramienta, ya que incluso los seres humanos tenemos dificultades para entender este tipo de escritura, bastante desordenada y compleja de descifrar.

Una forma automática alternativa de extracción de datos de un informe de pericia forense, es a partir de herramientas de basadas en técnicas de *Inteligencia Artificial Generativa (IAgen)*, particularmente *Large Language Models (LLM)*.

En este sentido se realizaron algunas pruebas con *ChatGPT 3.5* [27] y *Copilot* [28]. En ambos casos se utilizaron los mismos *prompts* y los mismos informes ficticios. Un ejemplo de *prompt* que fue acompañado del archivo correspondiente es:

Considerando este informe forense, extrae la información más importante respecto de las imágenes propuestas. Estructurará la información en formato de viñetas.

En el caso de un informe impreso, *ChatGPT 3.5* realizó una mejor extracción de información estructurándola con viñetas tituladas (Ver Fig. 9). Si bien *Copilot* extrajo en general los mismos datos que *ChatGPT 3.5*, este último realizó una mejor identificación, clasificando la información. En el caso de un informe manuscrito, *ChatGPT 3.5* extrajo información comparable con la herramienta basada en *OCR* analizada, e incluso la estructuró (ver Fig. 10). *Copilot* no pudo resolver el *prompt* (ver Fig. 11).

El uso de sistemas basados en *LLM* en el dominio forense es un área de estudio aún en vacancia, aunque se han identificado algunos desafíos [29,30,31]. Un condicionamiento es el hecho de que utilizar un *LLM* alojado públicamente no es factible en muchos casos de uso, como el expuesto en este trabajo, ya que manejan datos confidenciales o sensibles, por lo que sería necesaria una instalación alojada localmente o bien anonimizar los datos, lo que en algunos casos es complejo. Por otra parte, otra limitación a considerar en estos casos radica en nuestra capacidad de controlar si la información obtenida del informe forense proporcionado al sistema de *IAgen* corresponde con precisión al mismo.

A partir del análisis de los informes de pericias forenses, se busca obtener un conjunto de imágenes, el cual ya se encuentre clasificado, realizando inferencia a partir de la descripción detallada extraída. Esto es útil para ampliar el conjunto de datos de entrenamiento de nuevos modelos de clasificación de heridas.

La base de conocimiento obtenida posee diversos usos potenciales en el futuro. Uno de los más destacados es la *comparación de similitud de imágenes*, que facilita la identificación de patrones en las heridas. Este enfoque podría resultar beneficioso para datar la longevidad de las heridas siguiendo un criterio unificado, así como para proporcionar indicios sobre la naturaleza de las mismas.

Otro uso posible es la *validación de informes*. A partir de la base de conocimiento se busca identificar cualquier irregularidad que pueda sugerir manipulaciones o errores en la confección de un informe por parte de los peritos.

A partir de la base de conocimiento, se propone desarrollar un proceso de *fine-tuning* utilizando una arquitectura de transformadores con el objetivo de adaptar el modelo a casos específicos de la región. Específicamente, se busca determinar en qué medida las características demográficas como la raza, etnia y localización geográfica pueden mejorar el estudio de la datación y determinación de equimosis. En particular, se analizará en qué medida los patrones en las imágenes de equimosis, varían en función de estas características en diferentes regiones.

Este enfoque permitiría obtener modelos más precisos y generalizables, adecuados para aplicarse a diferentes contextos y poblaciones, donde la capacidad

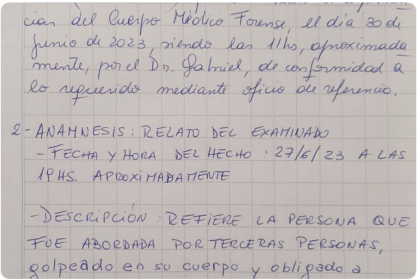


Información destacada del informe forense (formato en viñetas):

- **Identificación del examinado:**
 - Nombre: XX.
 - DNI: 123456.
 - Fecha y hora del examen: 30 de junio de 2023, a las 11:00 horas.
 - Examinado por: Dr. Gabriel.
- **Anamnesis:**
 - Fecha y hora del hecho: 27 de junio de 2023, aproximadamente a las 19:00 horas.
 - Descripción del examinado:
 - Afirma haber sido abordado por terceras personas, golpeado y obligado a consumir una sustancia blanquecina, probablemente cocaína, bajo amenazas con arma de fuego.
- **Hallazgos clínicos:**
 - **Físicos:**
 - Limitación en la elevación voluntaria de hombros.
 - Cicatriz hipocoloreada en el hombro izquierdo compatible con vacunación antituberculosa (de antigua data).
 - **Conductuales:**
 - Facies de exaltación, rigidez generalizada y comportamientos bizarros compatibles con consumo de estupefacientes (probable cocaína).
- **Datos adicionales:**
 - Presencia de cocaína corroborada en examen de orina realizado en el Hospital de Tricao Malal.
 - Tiempo estimado de las lesiones: 1-2 días desde su ocurrencia.
 - Mecanismo de producción: consumo desmedido de sustancias de abuso.
- **Aspectos médico-legales:**
 - No se constató deformación permanente del rostro.
 - La vida no estuvo en peligro real.
 - Se estima una curación en 2-3 días, salvo complicaciones.
 - No se generó inutilidad para las tareas habituales del examinado.
- **Consideraciones finales:**
 - El examinado acudió al peritaje por sus propios medios y presentó datos inconsistentes sobre el lugar y circunstancias del hecho.

🔊 📄 👍 🗑️ 🔄 ⌵

Fig. 9. Información extraída por ChatGPT 3.5 de un informe en formato pdf.



Considerando ese informe forense, extrae la información más importante respecto de las imágenes propuestas. Estructura la información en formato en viñetas

Basándome en el contenido visible de la imagen proporcionada, aquí tienes la información estructurada en viñetas:

- **Identificación del examinado:**
 - Nombre: XX.
 - DNI: 123456.
 - Fecha y hora del examen: 30 de junio de 2023, aproximadamente a las 11:00 horas.
 - Lugar del examen: Dependencias del Cuerpo Médico Forense.
 - Realizado por: Dr. Gabriel, según lo requerido mediante oficio de referencia.
- **Anamnesis (Relato del examinado):**
 - **Fecha y hora del hecho:** 27 de junio de 2023, aproximadamente a las 18:00 horas.
 - **Descripción de los hechos:**
 - El examinado refiere haber sido abordado por terceras personas.
 - Señala haber sido golpeado en su cuerpo.
 - Fue obligado a consumir estupefacientes.

¿Necesitas que organice la información de manera más específica o algún análisis adicional?

🗨️ 📄 📌 🔄 🗑️

Fig. 10. Resultado del *ChatGPT 3.5* con un informe parcial manuscrito.

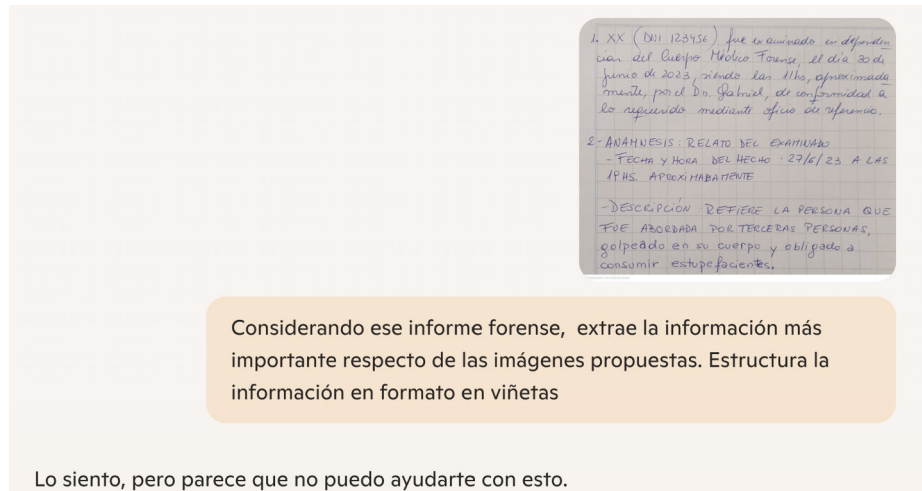


Fig. 11. Resultado de Copilot con un informe parcial manuscrito.

de identificar y datar equimosis de manera más precisa puede ser crucial en el ámbito médico-legal.

El último caso de uso que se plantea es la *generación de informes automatizados*. En primera instancia, a partir de la base de conocimiento se podrían generar resúmenes de evaluación médica que destaquen los aspectos más importantes de las imágenes, proporcionando un acceso rápido a la información relevante de éstas. En segunda instancia, puede facilitar la generación de informes más detallados y coherentes que incluyan a las imágenes y descripciones precisas de las heridas que aparecen en éstas, proporcionando así coherencia y consistencia en la generación de los informes.

4.2. Coloración de la piel y colorimetría en la evaluación de equimosis

Muchos modelos de IA enfrentan dificultades para generalizar más allá de los conjuntos de datos en los que fueron entrenados, especialmente cuando se encuentran con contextos o poblaciones distintas. La inclusión de metadatos relevantes, como antecedentes del caso y características demográficas, podría mejorar significativamente el rendimiento de los modelos de IA en este contexto [\[32\]](#).

En este sentido, es que se plantea determinar en qué medida las características demográficas como son la raza, etnicidad y ubicación geográfica mejora nuestro estudio para la determinación y datación de las equimosis.

La coloración de una equimosis está relacionada no solo a la evolución de la misma a lo largo del tiempo sino también en la tonalidad de la piel. En lo que respecta a la evolución cromática a lo largo del tiempo, es importante señalar que, inicialmente, la equimosis puede presentar un color rojo lívido o rojo oscuro,

lo cual depende del grosor de la piel que cubre la extravasación sanguínea. A medida que transcurre el tiempo, la tonalidad tiende a oscurecerse, adoptando matices casi violáceos e incluso negruzcos. Posteriormente, se observa una transición hacia el color azulado, seguido de la aparición de un tono verde que se aclara gradualmente hasta alcanzar un amarillo más pálido, hasta que eventualmente desaparece por completo. Además, es relevante destacar que la intensidad del color es generalmente más pronunciada en el centro de la equimosis en comparación con su periferia [33]. Por otro lado, la tonalidad de la piel desempeña un papel crucial en la percepción de la equimosis, dado que la cantidad y distribución de melanina, hemoglobina y otros cromóforos varían considerablemente entre los individuos [32]. En individuos con piel de tonalidades más oscuras, las equimosis tienden a ser menos visibles, o pueden requerir más tiempo para ser reconocidas, debido a la mayor pigmentación, que dificulta la observación de los cambios de color característicos a lo largo de la cronología cromática previamente detallada. Por esta razón, la evaluación de la equimosis en diferentes tonos de piel puede demandar enfoques más objetivos para lograr una clasificación más precisa.

A pesar de la ausencia de estadísticas específicas para la provincia de Neuquén, se ha identificado una limitada cantidad de documentación respecto a la diversidad étnica en Argentina. Los datos censales disponibles indican que aproximadamente el 8% de la población se reconoce como indígena o descendiente de pueblos indígenas, mientras que alrededor del 0,75% se identifica como afrodescendiente o descendiente de antepasados africanos. Además, en el contexto argentino, existen encuestas que permiten el análisis de la auto-percepción étnica, la cual se presenta en una escala más aplicable (véase Tabla 1).

Tabla 1. Etnias de Argentina: (1) Latinobarómetro [34] (2) Statista [35] (3) Pablo De Grande y Agustín Salvia [36]

Etnias	Porcentaje		
	2011 (1)	2020/21 (2)	2017 (3)
Blanco	60,60%	43,30%	60,30%
Mestizo	25,50%	18,40%	38,10%
Indígenas	1,50%	1,20%	1,10%
Negro	0,50%	0,30%	0,20%
Mulato	0,70%	0,70%	
Asiático	0,10%	0,20%	0,10%
Otras “razas”:	3,10%	1,80%	0,30%
No sabe/No responde:	8,00%	34,10%	-

Tomando en cuenta estas limitaciones, algunos investigadores utilizan instrumentos que identifiquen la tonalidad de piel de las personas, de acuerdo a una escala de “color” que va desde la tonalidad más clara hasta la más os-

cura [37,38,39,40,41,37,38,39,40,41]. La diversidad de escalas de color de piel utilizadas en las diferentes investigaciones se puede observar en la Fig. 12 [42].

La colorimetría emerge como una herramienta valiosa en la evaluación de la equimosis, proporcionando mediciones objetivas y cuantitativas del color de la piel. Esta técnica permite detectar cambios sutiles que podrían no ser visibles a simple vista. Mediante el uso de dispositivos como colorímetros, es posible identificar variaciones en la intensidad y tonalidad asociadas con la equimosis, mejorando así la precisión en su determinación. Esta metodología resulta especialmente beneficiosa en personas con piel de tonos más oscuros, donde la evaluación visual de las equimosis puede ser más desafiante.

En los estudios analizados también se pueden encontrar diferencias en términos metodológicos de cómo y quién realizaba la clasificación de la tonalidad de piel del individuo. Encontramos por un lado investigadores que privilegian la clasificación de la persona que realiza la medición de una manera subjetiva, y por otro lado sistemas de toma de color más estandarizados.

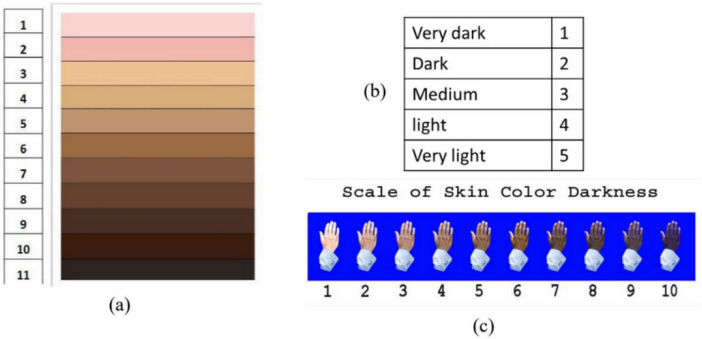


Fig. 12. Escala de color de piel utilizadas: (a) Telles y Steele (2012). Pereira y Telles (2024); (b) Espino y Franz (2008), Araujo-Dawson (2008); (c) Hersch (2008)

El espacio de color CIELAB se utiliza para cuantificar el color de la piel ofreciendo un marco estandarizado para descripciones y mediciones consistentes [43]. Se basa en tres componentes:

- L^* : Luminosidad, donde 0 representa negro y 100 representa blanco, correlacionándose con el nivel de pigmentación.
- a^* : Intensidad del componente rojo-verde, con valores positivos que indican rojo y negativos que indican verde, siendo útil para medir el eritema.
- b^* : Componente amarillo-azul, donde los valores positivos indican amarillo y los negativos azul, correlacionándose con la pigmentación y el bronceado.

Además, el uso de dispositivos colorimétricos permite obtener mediciones objetivas, lo que reduce la subjetividad en la evaluación visual, un aspecto crucial en las realización de pericias. Asimismo, facilita la clasificación de la pigmentación

de la piel según el ángulo de tipología individual, aportando información sobre la diversidad de los tipos de piel. En resumen, el espacio CIELAB facilita una evaluación precisa y objetiva del color de la piel. Esto lo comprueba investigaciones llevadas a cabo en este espacio de color en diferentes poblaciones con distintas tonalidades de piel [44,45].

Nuestro objetivo es extender el trabajo mediante el proceso de *fine-tuning* mencionado en la Sección 4.1. Lo que se busca es crear un corpus más completo que, además de incluir imágenes, considere otras características demográficas y patológicas relevantes para lograr una mejor clasificación y datación de las equimosis, teniendo en cuenta las particularidades de la población regional.

La incorporación de variables como la edad, el sexo, la raza y la etnia, así como factores contextuales asociados a la ubicación geográfica, pueden influir en la presentación y evolución de las equimosis. Al integrar estos elementos en nuestro modelo de aprendizaje, se espera mejorar su precisión y capacidad de generalización, lo que permitirá abordajes más apropiados y efectivos en la determinación de estas lesiones. Este enfoque no solo enriquecerá la base de datos, sino que también permitirá obtener resultados más relevantes y específicos para la población que se estudia.

4.3. Aumentación del conjunto de datos de entrenamiento

Dada la sensibilidad de la información tratada en el área forense, existe muy poca disponibilidad pública de datos para realizar el entrenamiento de modelos de IA. Por este motivo, es que se propone hacer uso de estrategias de aumentación de datos, las cuales permiten incrementar la cantidad y diversidad de los datos de entrenamiento. Las estrategias de aumento de datos que se proponen implementar son [46]:

- **Transformaciones Geométricas:** Rotar, escalar, recortar o voltear imágenes para crear variaciones del mismo objeto.
- **Modificaciones de Color:** Ajustar el brillo, el contraste o los colores para generar nuevas versiones de las imágenes.
- **Añadir ruido:** Introducir ruido aleatorio en las imágenes para hacer los modelos más robustos a variaciones.
- **Recortes Aleatorios:** Seleccionar partes aleatorias de imágenes y utilizarlas como nuevos ejemplos.
- **Desplazamiento:** Mover el contenido de las imágenes ligeramente en diferentes direcciones.

Por otro lado, se propone experimentar con el uso de Redes Generativas Adversariales (*Generative Adversarial Network* - GAN) [47] por sus siglas en inglés. Este tipo de arquitectura tiene el objetivo de crear datos sintéticos capaces de engañar a modelos como la Red Neuronal Convolutiva presentada en este trabajo. Con esto se espera ampliar considerablemente el conjunto de datos de entrenamiento ya que permitiría aplicar sobre las imágenes sintéticas generadas las estrategias de transformación que se mencionaron antes.

Esta idea se sustenta en el trabajo [48] donde se demuestra un aumento considerable en el rendimiento de clasificación de los modelos entrenados con este tipo de estrategias de aumentación para imágenes de heridas.

5. Conclusión

En este trabajo se ha presentado el desarrollo de un Sistema Inteligente basado en una red neuronal convolucional para el procesamiento de imágenes con el objetivo de determinar la presencia de equimosis. Esto representa un avance en el ámbito forense argentino, marcando un primer paso hacia la asistencia automatizada de profesionales en la interpretación de imágenes para pericias judiciales.

Para este propósito, se ha construido un conjunto de datos (*dataset*) compuesto por 135 imágenes (66 con equimosis). Este corpus ha sido sometido a un preprocesamiento para ser utilizado en el proceso de creación de un modelo mediante la utilización de una red neuronal convolucional (CNN) profunda. Se evaluó el rendimiento de la red utilizando tanto imágenes a color como imágenes convertidas a escala de grises.

Los resultados iniciales de los modelos indican un funcionamiento adecuado con una precisión comparable. No obstante, se observó que el uso de imágenes a color implica un mayor costo computacional durante el proceso de aprendizaje en comparación con las imágenes en escala de grises.

Se desarrolló el prototipo de una aplicación móvil con el objetivo de garantizar la accesibilidad y utilidad del modelo propuesto. Esta aplicación permite a partir de una imagen determinar si corresponde a una equimosis, proporcionando un porcentaje de confiabilidad asociado al resultado.

Finalmente, se presentaron dos enfoques a fin de extraer información relevante de las pericias y detalles específicos de las imágenes descritas textualmente. A partir del análisis de los informes de pericias forenses, se busca obtener un conjunto de imágenes con sus correspondiente descripción detallada. Esto es útil para ampliar el conjunto de datos de entrenamiento de nuevos modelos de clasificación de equimosis.

Se proyecta la creación de una base de conocimiento compuesta por imágenes contextualizadas, enriquecidas con información extraída de informes correspondientes. A partir de esta base de conocimiento, se propone implementar un proceso de *fine-tuning* con el propósito de adaptar el modelo a casos específicos de la región. Asimismo, se contempla la incorporación de características demográficas, tales como raza, etnia y localización geográfica, con la finalidad de mejorar el análisis relacionado con la datación y determinación de equimosis.

Finalmente, se pretende ampliar el modelo propuesto considerando los distintos aspectos de la violencia física, como el objeto utilizado, la intensidad y la ubicación tanto corporal como geográfica del evento de violencia.

References

1. Organización Mundial de la Salud, “Violencia contra la mujer,” 2021. <https://www.who.int/es/news-room/fact-sheets/detail/violence-against-women>. Accedido en Abril 2024.
2. The World Bank, “Gender Data Portal - Violence,” 2024. <https://genderdata.worldbank.org/topics/violence>. Accedido en Abril 2024.
3. The World Bank, “Gender Data Portal - Argentina,” 2024. <https://genderdata.worldbank.org/countries/argentina>. Accedido en Abril 2024.
4. E. Arribas and Z. Fortuny, *Guía práctica de lesiones + acceso web: Valoración clínica y sus implicaciones legales*. Elsevier Health Sciences Spain, 2013.
5. M. Asirdizer, E. Z. Besik, and E. Kartal, “Non-traumatic ecchymoses: A literature review from a medico-legal perspective,” *Journal of Forensic and Legal Medicine*, vol. 95, p. 102490, 2023.
6. N. Epperla, J. J. Mazza, and S. H. Yale, “A review of clinical signs related to ecchymosis,” *WMJ*, vol. 114, no. 2, pp. 61–5, 2015.
7. Office of the United Nations High Commissioner for Human Rights, “Protocolo de Minnesota sobre la Investigación de Muertes Potencialmente Ilícitas,” 2016. https://www.ohchr.org/sites/default/files/Documents/Publications/MinnesotaProtocol_SP.pdf. Accedido Abril 2024.
8. Office of the United Nations High Commissioner for Human Rights, “Istanbul Protocol: Manual on the Effective Investigation and Documentation of Torture and Other Cruel, Inhuman or Degrading Treatment or Punishment,” 2022. https://www.ohchr.org/sites/default/files/documents/publications/2022-06-29/Istanbul-Protocol_Rev2_EN.pdf. Accedido Abril 2024.
9. Secretaría de Seguridad y Política Criminal. Ministerio de Seguridad, “Actuación para la Investigación Científica del Lugar del Hecho,” 2021. https://www.conicet.gov.ar/wp-content/uploads/anexo_6486329_1.pdf. Accedido Abril 2024.
10. D. Riaño, S. Wilk, and A. Ten Teije, *Artificial Intelligence in Medicine: 17th Conference on Artificial Intelligence in Medicine, AIME 2019, Poznan, Poland, June 26–29, 2019, Proceedings*, vol. 11526. Springer, 2019.
11. A. Završnik, “Criminal justice, artificial intelligence systems, and human rights,” vol. 20, no. 4, pp. 567–583, 2020.
12. L. Tournois, V. Troussset, D. Hatsch, T. Delabarde, B. Ludes, and T. Lefèvre, “Artificial intelligence in the practice of forensic medicine: a scoping review,” *International Journal of Legal Medicine*, vol. 138, pp. 1023–1037, 2024.
13. J. Tirado and D. Mauricio, “Bruise dating using deep learning,” *Journal of forensic sciences*, vol. 66, no. 1, pp. 336–346, 2021.
14. G. Llajaruna, D. Mauricio, and L. Gutiérrez, “Datación de equimosis en el peritaje médico legal peruano mediante redes neuronales artificiales y procesamiento de imágenes. congreso latino-iberoamericano de investigación operativa,” in *Simpósio Brasileiro de Pesquisa Operacional*, 2012.
15. N. Alanbar, “bruise dataset.” <https://universe.roboflow.com/nabeel-alanbar-2vn5y/bruise-x5paj>, may 2023. visited on 2024-04-12.
16. D. Sarvamangala and R. V. Kulkarni, “Convolutional neural networks in medical image understanding: a survey,” *Evolutionary intelligence*, vol. 15, no. 1, pp. 1–22, 2022.
17. H. Yu, L. T. Yang, Q. Zhang, D. Armstrong, and M. J. Deen, “Convolutional neural networks for medical image analysis: State-of-the-art, comparisons, improvement and perspectives,” *Neurocomputing*, vol. 444, pp. 92–110, 2021.

18. F. Ciompi, B. de Hoop, S. J. van Riel, K. Chung, E. T. Scholten, M. Oudkerk, P. A. de Jong, M. Prokop, and B. van Ginneken, "Automatic classification of pulmonary peri-fissural nodules in computed tomography using an ensemble of 2d views and a convolutional neural network out-of-the-box," *Medical Image Analysis*, vol. 26, no. 1, pp. 195–202, 2015.
19. M. A. Abdou, "Literature review: Efficient deep neural networks techniques for medical image analysis," *Neural Computing and Applications*, vol. 34, no. 8, pp. 5791–5812, 2022.
20. F. A. Mohammed, K. K. Tune, B. G. Assefa, M. Jett, and S. Muhie, "Medical image classifications using convolutional neural networks: A survey of current methods and statistical modeling of the literature," *Machine Learning and Knowledge Extraction*, vol. 6, no. 1, pp. 699–735, 2024.
21. R. Kumar, P. Kumbharkar, S. Vanam, and S. Sharma, "Medical images classification using deep learning: a survey," *Multimedia Tools and Applications*, vol. 83, no. 7, pp. 19683–19728, 2024.
22. Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
23. Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
24. A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, 2012.
25. M. A. HASAN, T. Bhargav, V. SANDEEP, V. S. REDDY, and R. AJAY, "Image classification using convolutional neural networks," *International Journal of Mechanical Engineering Research and Technology*, vol. 16, no. 2, pp. 173–181, 2024.
26. S. Bandal and S. Rath, "Unveiling digital secrets: An image text vision app for enhanced digital forensics investigations," in *2024 12th International Symposium on Digital Forensics and Security (ISDFS)*, pp. 1–6, IEEE, 2024.
27. OPENAI, "Introducing ChatGPT ." <https://openai.com/index/chatgpt/>. Accedido Enero 2025.
28. Microsoft, "Copilot ." <https://copilot.microsoft.com/>. Accedido Enero 2025.
29. M. Scanlon, B. Nikkel, and Z. Geradts, "Digital forensic investigation in the age of ChatGPT," *Forensic Science International: Digital Investigation*, vol. 44, p. 301543, 03 2023.
30. M. Scanlon, F. Breitingner, C. Hargreaves, J.-N. Hilgert, and J. Sheppard, "Chatgpt for digital forensic investigation: The good, the bad, and the unknown," *Forensic Science International: Digital Investigation*, vol. 46, p. 301609, 2023.
31. R. J. Dinis-Oliveira and R. M. S. Azevedo, "Chatgpt in forensic sciences: a new pandora's box with advantages and challenges to pay attention," *Forensic Sciences Research*, vol. 8, pp. 275–279, 11 2023.
32. B. C. K. Ly, E. B. Dyer, J. L. Feig, A. L. Chien, and S. Del Bino, "Research techniques made simple: cutaneous colorimetry: a reliable technique for objective skin color measurement," *Journal of Investigative Dermatology*, vol. 140, no. 1, pp. 3–12, 2020.
33. L. Pereda and G. Marilú, "Automatización de la datación de equimosis en el peritaje médico legal peruano mediante redes neuronales artificiales y procesamiento de imágenes," Master's thesis, Universidad Nacional Mayor de San Marcos. Programa Cybertesis Perú, 2011.
34. Latinobarómetro, "Corporación latinobarómetro. informe 2011." http://www.infoamerica.org/primer/1b_2011.pdf, 2011.

35. Statista, "Distribución porcentual de la población en países seleccionados de américa latina en 2020 y 2021, por grupo étnico." <https://es.statista.com/estadisticas/1417603/distribucion-de-grupos-etnicos-en-america-latina-en-paises>, 2021. visited on 2025-01-03.
36. P. De Grande and A. Salvia, "Aportes para la medición de la desigualdad racialista en la argentina," *Estudios sociológicos*, vol. 39, no. 117, pp. 741–771, 2021.
37. R. Espino and M. M. Franz, "Latino phenotypic discrimination revisited: The impact of skin color on occupational status," *Social Science Quarterly*, vol. 83, no. 2, pp. 612–623, 2002.
38. T. Golash-Boza and W. Darity Jr, "Latino racial choices: the effects of skin colour and discrimination on latinos' and latinas' racial self-identifications," *Ethnic and Racial Studies*, vol. 31, no. 5, pp. 899–934, 2008.
39. J. Hersch, "Profiling the new immigrant worker: The effects of skin color and height," *Journal of Labor Economics*, vol. 26, no. 2, pp. 345–386, 2008.
40. K. M. Perreira and E. E. Telles, "The color of health: skin color, ethnoracial classification, and discrimination in the health of latin americans," *Social science & medicine*, vol. 116, pp. 241–250, 2014.
41. E. E. Telles, *Pigmentocracies: Ethnicity, race, and color in Latin America*. UNC Press Books, 2014.
42. I. P. G. Santiago, M. F. M. Suárez, M. F. Ortiz, and M. S. Rivera²⁶, "Color y desigualdad: Estudio exploratorio sobre el uso de escalas de color de piel para conocer la vulnerabilidad y percepción del discrimen entre latinos y latinas," *Revista Umbral*, p. 33, 2018.
43. R. Shamey, *Encyclopedia of color science and technology*. Springer, 2023.
44. P. Dabas, B. Nayak, H. Khajuria, S. Jain, and K. Saraswathy, "Analysis of skin color variation using cielab index: An empirical study from delhi, india," *Journal of Indian Academy of Forensic Medicine*, vol. 46, no. 1, pp. 76–80, 2024.
45. A. Kaur and B. Kranthi, "Comparison between ycbcr color space and cielab color space for skin color segmentation," *International Journal of Applied Information Systems*, vol. 3, no. 4, pp. 30–33, 2012.
46. L. Taylor and G. Nitschke, "Improving deep learning with generic data augmentation," in *2018 IEEE symposium series on computational intelligence (SSCI)*, pp. 1542–1547, IEEE, 2018.
47. I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative adversarial networks," *Communications of the ACM*, vol. 63, no. 11, pp. 139–144, 2020.
48. H. Narayanan and S. Ghanta, "A study of data augmentation techniques to overcome data scarcity in wound classification using deep learning," *arXiv preprint arXiv:2411.02456*, 2024.