








Hacia el procesamiento de imágenes de pericias asistido por Sistemas Inteligentes en el ámbito forense *

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

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

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

Resumen 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 colaboran en valorar daños, determinación de responsabilidades e interpretación de evidencia médica. El Cuerpo Médico Forense del Poder Judicial de Neuquén ha recopilado una gran cantidad de datos, sobre pericias judiciales realizadas, que podrían ser utilizados para generar Sistemas Inteligentes, que colaboren en asistir a los profesionales en sus decisiones. Así, surge la necesidad de comprender, procesar y manipular imágenes de pericias forenses médico-legales.

En este trabajo se presentan los resultados iniciales 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 dataset público. Se realizaron pruebas para determinar el comportamiento de la red a partir de imágenes tanto en blanco y negro 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.

Como complemento, 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

* Financiado por la Universidad Nacional del Comahue en el contexto del Proyecto de Investigación *04-F020 Tecnologías Semánticas para el Desarrollo de Agentes Inteligentes* y del Proyecto de Extensión *Análisis Forense de Pericias Médico-legales asistidas por Sistemas Inteligente: preparación de datos*

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 de Neuquén, 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].

El Cuerpo Médico Forense del Poder Judicial de Neuquén ha recopilado una gran cantidad de datos, sobre pericias judiciales realizadas, que podrían ser utilizados para generar Sistemas Inteligentes, que colaboren en asistir a los profesionales en sus decisiones. Así, surge la necesidad de comprender, procesar y manipular imágenes de pericias forenses médico-legales.

En este sentido, un primer problema de interés a resolver es la determinación a partir de una imagen del tipo de lesión, particularmente, si corresponde a una equimosis.

Desde el siglo pasado, la Inteligencia Artificial ha atravesado muchos campos de especialización, entre los que se encuentran la medicina [10] y la justicia y el derecho penal [11]. En el estudio de [12] se analizan diversas aplicaciones en el ámbito de la medicina forense, señalando que en relación al análisis de imágenes de equimosis se puede referenciar y consultar a [13]. Asimismo, en [14], se presenta otro trabajo similar al mencionado. En ambos casos, el sistema toma como entrada una imagen previamente identificada como equimosis y estima 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.

En este trabajo se presentan los resultados iniciales del 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 dataset 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.

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. 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 a la clasificación de imágenes en otras especialidades de la medicina, como se detalla en la literatura [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) [16,17]. Las CNNs 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 Figura 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.

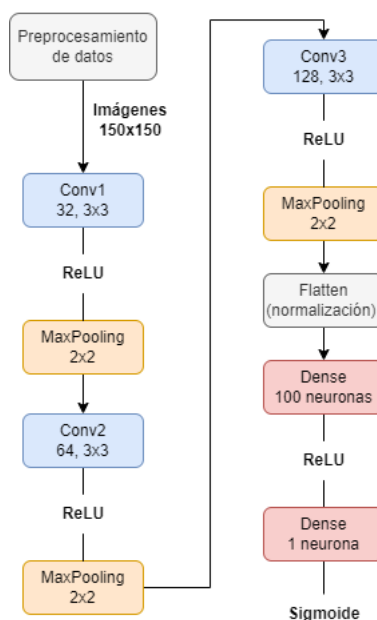


Figura 1. Red Neuronal Convolutacional propuesta para la determinación de equimosis.

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 Figura 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 Figura 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.




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

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




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




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




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

El enfoque a color dio como resultado modelos de hasta 90% de precisión, incluso alguno ligeramente superior. Como se observa en la Figura 4, la precisión de los conjuntos tanto de entrenamiento (línea roja) como de validación (línea azul) 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 Figura 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 Figura 6 se muestran capturas de pantalla de los resultados obtenidos después de procesar 2 imágenes diferentes.

³ <https://reactnative.dev/>

⁴ <https://www.typescriptlang.org/>

⁵ <https://www.python.org/>



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

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 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. 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.

Finalmente, 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.

Como trabajo futuro, 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. Asimismo, se planea extender el Sistema Inteligente desarrollando un modelo que permita datar a la equimosis identificada. El tono de piel es una característica clave en la determinación y datación de equimosis, y se reconoce que los rangos de tonos de piel en Neuquén pueden ser diferentes a los de otras regiones del país.

Referencias

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. Troussel, 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 *Simposio 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. 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.
17. A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Advances in neural information processing systems*, vol. 25, 2012.