

DOI: <https://doi.org/10.46296/ig.v9i18.0354>

DISEÑO DE UN DATASET PARA SISTEMAS DE SEGURIDAD BASADOS EN DETECCIÓN DE ARMAS

DESIGN OF A DATASET FOR WEAPON DETECTION-BASED SECURITY SYSTEMS

Molina-Cedeño Juan Carlos ¹; Meza-Hormaza Jaime ²

¹ Universidad Técnica de Manabí. Portoviejo, Ecuador. Correo: jcmolina2932@gmail.com

² Universidad Técnica de Manabí. Portoviejo, Ecuador.
Correo: jaime.meza@utm.edu.ec. ORCID ID: <https://orcid.org/0000-0002-8279-5630>.

Resumen

La detección automática de amenazas mediante visión por computadora se ha convertido en una alternativa de gran interés para fortalecer los sistemas de videovigilancia. Sin embargo, el rendimiento de estos modelos de detección depende en gran medida, de la calidad de los datos con los que fueron entrenados. En este contexto, la presente investigación tiene como objetivo diseñar un dataset especializado para la detección de personas armadas y desarmadas, con el objetivo de que sirva como base para el desarrollo de sistemas de monitoreo inteligentes. Para ello, se empleó la metodología CRISP-ML(Q), dividiendo la creación del dataset en las etapas de recopilación, selección, preparación y validación de los datos. El conjunto de datos fue construido a partir de videos obtenidos de fuentes abiertas a nivel del Ecuador y posteriormente etiquetados para su utilización en el entrenamiento del modelo. Por último, para comprobar la validez del dataset, se realizó el entrenamiento de un modelo de detección basado en YOLO. Dando resultados que pudieran evidenciar un desempeño satisfactorio en el modelo entrenado, demostrando que el dataset desarrollado posee características adecuadas para el entrenamiento de modelos de detección automática de amenazas en entornos de videovigilancia.

Palabras clave: Dataset, visión por computadora, armas de fuego, videovigilancia, seguridad, entrenamiento, modelo, YOLO.

Abstract

Automatic threat detection through computer vision has become an increasingly important approach for enhancing video surveillance systems. However, the performance of these detection models largely depends on the quality of the data used for training. In this context, the present research aims to design a specialized dataset for the detection of armed and unarmed individuals, with the objective of serving as a foundation for the development of intelligent monitoring systems. To achieve this, the CRISP-ML(Q) methodology was employed, dividing the dataset creation process into the stages of data collection, selection, preparation, and validation. The dataset was constructed from videos obtained from publicly available sources across Ecuador and subsequently annotated for use in model training. Finally, to validate the proposed dataset, a YOLO-based object detection model was trained. The obtained results demonstrated satisfactory performance, indicating that the developed dataset possesses suitable characteristics for training automatic threat detection models in video surveillance environments.

Keywords: Dataset, computer vision, firearms, video surveillance, security, training, model, YOLO.

Información del manuscrito:

Fecha de recepción: 08 de mayo de 2026.

Fecha de aceptación: 13 de julio de 2026.

Fecha de publicación: 13 de agosto de 2026.



1. Introducción

En la actualidad, los sistemas de videovigilancia son cada vez más utilizados en sectores públicos y privados, con la finalidad de reforzar la seguridad ciudadana y de prevenir actos delictivos, convirtiéndolos en una de las principales herramientas para la recolección de información en tiempo real y el monitoreo de espacios públicos según (Jorge et al., 2023).

La mayoría de estos sistemas utilizan cámaras CCTV (Closed-Circuit Television) ((Matczak et al., 2023)) para la captura de los datos de manera pasiva, sin embargo en la actualiza los avances tecnológicos, especialmente en inteligencia artificial (IA), han permitido el desarrollo de nuevos sistemas de seguridad que ofrecen una solución más inteligente y automatizada para anticipar y mitigar incidentes.

En este sentido, surge la implementación de algoritmos de predicción, lo que se representa como una herramienta estratégica para la prevención del delito y la gestión eficiente de emergencias. La mayoría de estos sistemas utilizan tecnologías como Machine Learning,

Deep Learning, y visión por computadora para el procesamiento de grandes volúmenes de datos, con los que poder identificar patrones de comportamiento, detectar objetos peligrosos y generar alertas en tiempo real ante cualquier tipo de evento (L.Priyanka & Sahithi, 2025).

Diversas investigaciones como la de (Debnath & Bhowmik, 2021) han explorado el uso de aplicaciones de la visión por computadora para la detección de armas de fuego, realizando una exhaustiva revisión de los métodos basados en el aprendizaje profundo para su entrenamiento, destacando el creciente uso de arquitecturas de redes neuronales por su capacidad para identificar objetos peligrosos en escenarios complejos.

Por otro lado, (Castillo et al., 2019), identificó que los modelos más recientes de detección de armas de vigilancia alcanzan resultados prometedores utilizando arquitecturas como YOLO o SSD No obstante la precisión y eficacia de estos sistemas dependen de la calidad de los datos utilizados para el entrenamiento de los modelos, por esto mismo son necesarios datasets que cumplan diferentes factores,

como una cantidad de imágenes, una diversidad de escenarios y variaciones en el tipo de armas, limitando lo menor posible los algoritmos de detección.

En este contexto, la presente investigación propone el diseño de un dataset elaborado a partir de incidentes ocurridos en el Ecuador, para sistemas de seguridad basados en detección de armas de fuego. Con el objetivo de contribuir al entrenamiento y al desarrollo de sistemas de videovigilancia más eficaces. Todo esto mediante la utilización de datos específicos que fueron cuidadosamente clasificados y etiquetados, permitiendo mejorar la detección de amenazas.

2. Metodología

Para el diseño del dataset para sistemas de seguridad basados en detección de armas se empleó la metodología CRISP-ML(Q) (Cross-Industry Standard Process for Machine Learning with Quality Assurance), debido a que amplía el modelo tradicional CRISP-DM al incorporar actividades específicas para sistemas de inteligencia artificial. Entre estas actividades se

incluyen la gestión de riesgos, el aseguramiento de la calidad de los datos, el monitoreo continuo del desempeño y el mantenimiento posterior al despliegue (Studer et al., 2021).

Según (Salazar Franco, 2023) CRISP-ML(Q) se caracteriza por ser una metodología flexible, ya que permite la mejora continua de los procesos que forman parte del desarrollo de soluciones basadas en machine learning. Esto facilita el identificar y corregir problemas durante las diferentes etapas del proyecto, lo que contribuye al incremento de la calidad y confiabilidad de los datos utilizados para el entrenamiento de modelos de detección. Por ello, esta metodología resultó adecuada para guiar el proceso de construcción, validación y evaluación del dataset propuesto en la presente investigación y esta fue adaptada a los requerimientos de la investigación, utilizando las fases de: Comprensión del negocio, Comprensión de los datos, Preparación de los datos, Modelado y Evaluación.

2.1 Comprensión del Negocio

En esta fase se identificó la problemática relacionada con la

creciente necesidad de implementar sistemas de seguridad capaces de detectar armas de manera automática en entornos urbanos, por ello la investigación se enfocó en el desarrollo de un dataset que permita fortalecer sistemas de vigilancia basados en visión por computador y aprendizaje automático, lo que contribuye al apoyo de procesos de monitoreo y prevención de incidentes.

Como parte de esta etapa se determinaron los objetivos principales del proyecto, los cuales están enfocados en la recolección, selección, procesamiento y etiquetado de imágenes que contengan armas o gente armada en diferentes ángulos y perspectivas. Además, se definieron ciertos parámetros a tener en cuenta para estas imágenes, ya que debe existir una diversidad de escenarios, ángulos, iluminación y entornos visuales que representen situaciones reales de vigilancia.

Por ello, esta etapa permitió delimitar el alcance de la investigación y determinar las características necesarias para la construcción del dataset.

2.2 Comprensión de los datos

Mediante el análisis exploratorio se evalúan la calidad, completitud, representatividad y adecuación de los datos disponibles, aspectos clave para la fiabilidad del modelo (Carmona Gálvez, 2025).

Por ello, en esta fase de comprensión de los datos se seleccionaron aproximadamente 100 videos obtenidos de diferentes fuentes abiertas (Molina, 2026) y que estaban relacionados con escenas donde se visualizan personas con armas de fuego en distintos contextos. Posteriormente, se efectuó un proceso de análisis y revisión del contenido con el objetivo de identificar materiales relevantes para la investigación. El proceso de selección de estos videos se realizó considerando algunos parámetros que permitieran garantizar la calidad y diversidad del material empleado para la construcción del dataset.

Entre los criterios considerados se evaluaron aspectos como calidad visual y resolución de los videos, las condiciones de iluminación, la estabilidad de las imágenes, la visibilidad de las personas y de las armas de fuego, así como la presencia de distintos escenarios,

perspectivas y distancias respecto a la cámara. Además, se buscó incluir ambientes interiores y exteriores, con el fin de obtener una mayor variabilidad en las muestras.

2.3 Preparación de los datos

La preparación de los datos constituye una etapa fundamental dentro del desarrollo del proyecto, ya que la calidad y consistencia de la información influyen directamente en el desempeño de los modelos de machine learning (Carvajal Gutiérrez & Lozano Zamora, 2026).

Una vez seleccionados los 100 videos, se desarrolló un script en Python (juanmolina15, s. f.) el cual se encargó de automatizar la extracción de fotogramas. Este procedimiento permitió obtener múltiples imágenes de cada video de forma sistemática, conservando la diversidad de las muestras y evitando la selección manual. Como resultado de este proceso se generaron aproximadamente 1000 imágenes.

Posteriormente, las imágenes fueron distribuidas en tres carpetas correspondientes a los subconjuntos de entrenamiento, validación y prueba. Esta organización permitió


estructurar adecuadamente la información antes de su incorporación en la plataforma Roboflow.

Una vez cargadas las imágenes en Roboflow, se realizó el proceso de etiquetado manual mediante anotaciones de tipo bounding box, y en las cuales se definieron dos clases de interés:

Persona_armada, que identifica mediante cuadros delimitadores de color rojo a individuos que portaban armas de fuego visible.

Persona_desarmada, que identifica mediante cuadros delimitadores de color verde a individuos que no presentaban armas de fuego.

Figura 1. Etiquetado de imágenes en Roboflow. Fuente: Los autores




Con el propósito de evitar problemas asociados al desequilibrio de clases, se procuró mantener una cantidad

similar de muestras en ambas categorías, esto con el objetivo de garantizar un equilibrio entre personas armadas y desarmadas. Este equilibrio permite reducir

sesgos durante el entrenamiento y mejorar la capacidad del modelo para reconocer adecuadamente ambas clases.

Figura 2. Análisis del conjunto de datos. Fuente: Los autores




2.4 Validación del set

Con el objetivo de verificar la calidad y utilidad del conjunto de datos desarrollado, se realizaron pruebas experimentales utilizando la arquitectura YOLO, ya que este modelo destaca para tareas de detección de objetos. Por ello, esta fase tuvo el objetivo de determinar si

el dataset creado proporcionaba información suficiente para permitir la identificación de personas armadas o desarmadas en distintos escenarios. Para validar y comprobar el dataset se empleó una variante de YOLO con bajos recursos computacionales y una alta velocidad de procesamiento.

Figura 3. Métricas de detección iniciales obtenidas de la primera prueba. Fuente: Los autores



Como se ve en la figura 3, una vez concluido el entrenamiento y la


evaluación sobre el conjunto de prueba, se obtuvieron valores de

42.6 % de Precisión, 42.3 % de Recall, 42.4 % de F1-score y un mAP@50 de 28.9 %. A partir de estos resultados se decidió utilizar una variante de YOLO con una mayor capacidad de representación, con el propósito de analizar el comportamiento del conjunto de datos utilizando una arquitectura más robusta. Por ello, se optó por utilizar una variante con una

mayor cantidad de parámetros y una capacidad superior de representación.

Como se observa en la figura 4, tras repetir el proceso de entrenamiento, se obtuvieron unos resultados significativamente mejores, ya que alcanza una Precisión de 91.8 %, un Recall de 79.6 %, un F1-score de 84.9 % y un mAP@50 de 80.1%.

Figura 4. Métricas de detección de YOLO obtenidas en la segunda prueba. Fuente: Los autores



Al comparar ambas arquitecturas se puede evidenciar una mejora significativa en el desempeño del modelo, especialmente en términos de precisión y capacidad de detección, lo que demuestra un rendimiento consistente.

2.5 Evaluación

Los resultados obtenidos de la segunda prueba mostraron un desempeño favorable del modelo YOLO, ya que las métricas reflejan una alta precisión en las detecciones realizadas, lo que resulta en una capacidad adecuada para identificar

las personas armadas y desarmadas dentro del conjunto de prueba.

Teniendo en cuenta los resultados de las métricas, el valor de Precisión muestra que el modelo presentó una baja proporción de falsas detecciones, lo cual indica que la mayoría de las predicciones realizadas fueron correctas. Por otro lado, el Recall demuestra que el modelo logró identificar una gran cantidad de los casos presentes en las imágenes, aunque esto tiene margen de mejora en la detección de ciertos objetos que pueden pasar desapercibidos, especialmente en

escenarios con condiciones visuales más complejas.


Así mismo, el resultado del F1-score muestra que el modelo tiene un buen equilibrio entre las detecciones correctas y los casos que logra identificar dentro de las imágenes. Además, el valor obtenido en mAP@50 indica que el modelo tuvo un buen desempeño al reconocer y ubicar a las personas armadas y desarmadas dentro de las imágenes adecuadas.

A partir de estos resultados se puede considerar que el dataset desarrollado cumple con las condiciones necesarias para ser utilizado en el entrenamiento de modelos de detección.

3. Resultados y discusión

Con el fin de construir un dataset que permita entrenar modelos de detección de personas armadas y desarmadas, se recolectaron datos audiovisuales de diversas fuentes, en los cuales se utilizó un pequeño script de autoría propia el cual permitió realizar la extracción de diversos fotogramas, los cuales fueron sometidos a un proceso de limpieza de datos en el cual se eliminaron fotogramas demasiado parecidos, muy borrosos o que no tuviesen nada que ver con el objetivo final del dataset, seguido de esto se estructuró el dataset en 3 diversas carpetas, dando como resultado el dataset sin etiquetar.

Figura 5. Distribución de clases y etiquetas. Fuente: Los autores




La Figura 5 muestra la distribución de las anotaciones o etiquetas que se encuentran presentes dentro del dataset, teniendo un registro aproximado de 2900 instancias de la clase Persona_armada y 2650 de la clase Persona_desarmada, lo que evidencia una distribución equilibrada entre clases, permitiendo reducir posibles sesgos durante el entrenamiento de modelos de

aprendizaje profundo, como lo son falsos positivos o falsos negativos.

La distribución espacial de las etiquetas muestra que se encuentran ubicadas a lo largo de diferentes regiones de la imagen y presentan diversas dimensiones, lo cual indica la presencia de personas a distintas distancias y posiciones dentro de los escenarios analizados.


Figura 6. Evolución del entrenamiento. Fuente: Los autores



Con el fin de validar la calidad del dataset, se entrenó un modelo de YOLOv8 durante 150 épocas, como se puede visualizar en la Figura 6, evidenciando una disminución progresiva de las funciones de pérdida de entrenamiento y validación, mientras que las métricas de evaluación presentan un


incremento sostenido tal como se evidencia en la gráfica.

Este comportamiento indica que las imágenes y etiquetas del dataset contienen información suficiente para que el modelo aprenda características relevantes a partir de los datos del mismo.

Figura 7. Curva Precision-Recall. Fuente: Los autores

La evaluación mediante la curva Precision-Recall, mostrada en la Figura 7 muestra un Average Precision (AP) de 0.920 para la clase Persona_armada y un AP de 0.742

para la clase Persona_desarmada, obteniendo así un valor global de mAP@0.5 de 0.831, equivalente a un 83.1 % de desempeño promedio sobre ambas categorías.

Figura 8. Matriz de confusión normalizada. Fuente: Los autores

La Figura 8 muestra la matriz de confusión normalizada. Los resultados indican que la mayoría de

las instancias fueron clasificadas correctamente por el modelo. La clase Persona_armada alcanzó una

tasa de reconocimiento cercana al 81 %, mientras que la clase Persona_desarmada obtuvo aproximadamente un 64 %. Estos resultados sugieren que las anotaciones realizadas presentan una calidad adecuada para el entrenamiento de modelos de detección.

Discusión

Mediante los diversos parámetros obtenidos durante el entrenamiento de un modelo YOLO, los cuales validan y dan viabilidad al dataset como un recurso eficaz para entrenar modelos de detección aplicados a la videovigilancia, se logra un elevado rendimiento global y una alta efectividad en la detección de amenazas en tiempo real.

Una de las aportaciones más relevantes del conjunto de datos es lo variado de las dimensiones de las cajas delimitadoras y de las posiciones de los objetos. La presencia de personas en distintos lugares dentro de la imagen y la variación en tamaño debido a las diferencias de tiempos en las que fueron capturadas las imágenes de cada video de vigilancia proporciona condiciones óptimas de monitoreo en tiempo real. Esto ayuda a

entrenar el modelo de forma más exacta sin sesgos como falsos positivos al detectar patrones repetitivos.

Estos resultados son consistentes con investigaciones recientes en el ámbito de la detección de amenazas mediante visión por computador.

(Ahmed et al., 2022), en su estudio sobre detección de armas en videos de vigilancia, señala que la diversidad de escenarios, escalas de los objetos y condiciones de captura constituye un factor determinante para mejorar el desempeño de los modelos de detección en entornos reales. Así mismo, (Hnoohom et al., 2022), mediante el dataset ACF (Armed CCTV Footage Dataset), destaca que los conjuntos de datos orientados específicamente a imágenes de videovigilancia permiten obtener modelos más robustos frente a variaciones de iluminación, distancia y resolución presentes en sistemas CCTV.

Los resultados de la curva Precision-Recall reflejan un mejor desempeño en la detección de la clase Persona_armada, la cual alcanzó un AP elevado. Este comportamiento puede atribuirse a que la presencia de armas de fuego genera patrones

visuales distintivos que facilitan el proceso de aprendizaje. Por el contrario, la clase *Persona_desarmada* presentó un AP ligeramente inferior, posiblemente debido a una mayor variabilidad en posturas, vestimenta, condiciones de iluminación y contextos presentes en las imágenes, lo que dificulta el reconocimiento. Este comportamiento coincide con lo reportado por (Amado-Garfias et al., 2024), indicando que la identificación automática de personas armadas resulta más efectiva cuando existen características visuales claramente diferenciables entre las clases analizadas, mientras que las variaciones en apariencia y contexto incrementan la complejidad de clasificación.

Adicionalmente, la matriz de confusión evidencia que existe una separación aceptable entre las clases definidas, sin embargo aún persisten ciertos errores de clasificación que podrían reducirse mediante la incorporación de nuevas muestras, escenarios y condiciones de captura.

Los resultados obtenidos validan la utilidad del dataset propuesto como

recurso para investigaciones futuras relacionadas con la detección automática de amenazas en sistemas de videovigilancia basados en inteligencia artificial.

4. Conclusiones

El entrenamiento del modelo YOLO se limitó a 150 épocas, lo que disminuye las funciones de pérdida y mostró unas métricas de evaluación bastante altas, lo que demuestra que el dataset contiene información más que suficiente para que el modelo aprenda características visuales relevantes, sin embargo, las curvas de pérdida mostradas en resultados mostraron que el entrenamiento podría mejorar añadiendo un mayor número de etapas.

La diferencia observada entre el desempeño de las clases de “*Persona_armada*” y “*Persona_desarmada*” revela que existe una desigualdad en el rendimiento de detección de ambas categorías, donde la clase “*Persona_armada*” alcanzó un Average Precisión superior al 92% en comparación al 74% de la clase “*Persona_desarmada*”, lo que concluye que, es más complicado

para el sistema, reconocer a una persona desarmada que a una persona armada, por lo que se podría mejorar el dataset agregando mas imagenes de personas desarmadas en diferentes situaciones.

Por otro lado, se concluye que el proceso de selección de los videos iniciales fue una fase clave para determinar la calidad del dataset, permitiendo un buen rendimiento en el modelo, gracias al script desarrollado que extrajo las imágenes con la calidad justa y necesaria, lo que demuestra que no se necesitan cámaras de alto coste o resolución.

Recomendaciones y Trabajo a futuro

Como plan a futuro, se plantea la idea de ampliar el dataset mediante nuevas muestras provenientes de diferentes escenarios, la incorporación de nuevas armas y la captura de datos en condiciones más desafiantes, lo cual ayudará a reforzar la representación de la clase Persona_desarmada, debido a que presentó un desempeño inferior en comparación con la clase

Persona_armada durante el proceso de validación.

A futuro se propone realizar pruebas comparativas utilizando otros modelos de detección, con el fin de analizar el comportamiento del dataset frente a otros modelos diferentes a YOLO. Esto ayudaría a determinar si existe algún modelo que aproveche mejor las características del dataset desarrollado.

Adicionalmente también se recomienda evaluar el desempeño del dataset en diferentes escenarios de videovigilancia en tiempo real. Lo que permitirá comprobar qué tan útil es el sistema en otro tipo de entornos que pongan a prueba el sistema de detección, y así poder identificar cuales son las limitaciones que presenta el dataset.

Conflictos de interés

El autor declara no tener ningún conflicto de interés financiero ni personal que pudieran haber influido en este trabajo.

Bibliografía

- Ahmed, S., Bhatti, M. T., Khan, M. G., Lövsström, B., & Shahid, M. (2022). Development and Optimization of Deep Learning Models for Weapon Detection in Surveillance Videos. *Applied Sciences*, 12(12), 5772. <https://doi.org/10.3390/app12125772>
- Amado-Garfias, A. J., Conant-Pablos, S. E., Ortiz-Bayliss, J. C., & Terashima-Marín, H. (2024). Improving Armed People Detection on Video Surveillance Through Heuristics and Machine Learning Models. *IEEE Access*, 12, 111818-111831. <https://doi.org/10.1109/ACCESS.2024.3442728>
- Carmona Gálvez, J. (2025). Especialización de un modelo LLM en una disciplina específica. <https://hdl.handle.net/10630/46582>
- Carvajal Gutiérrez, H. A., & Lozano Zamora, J. S. (2026). Diseño e implementación de modelos predictivos y analíticos entrenados con datos históricos empresariales para evaluar riesgo, desempeño y anomalías en empresas futuras bajo el enfoque CRISP-ML. <https://hdl.handle.net/20.500.12494/64341>
- Castillo, A., Tabik, S., Pérez, F., Olmos, R., & Herrera, F. (2019). Brightness guided preprocessing for automatic cold steel weapon detection in surveillance videos with deep learning. *Neurocomputing*, 330, 151-161. <https://doi.org/10.1016/j.neucom.2018.10.076>
- Debnath, R., & Bhowmik, M. K. (2021). A comprehensive survey on computer vision based concepts, methodologies, analysis and applications for automatic gun/knife detection. *Journal of Visual Communication and Image Representation*, 78, 103165. <https://doi.org/10.1016/j.jvcir.2021.103165>
- Detector gente armada Model > Overview. (s. f.). Roboflow. <https://universe.roboflow.com/trabajo-articulo/detector-gente-armada>
- Hnoohom, N., Chotivatunyu, P., & Jitpattanakul, A. (2022). ACF: An Armed CCTV Footage Dataset for Enhancing Weapon Detection. *Sensors*, 22(19), 7158. <https://doi.org/10.3390/s22197158>
- Jorge, M., Aragon, J., & Gonzales, C. (2023). Uso de herramientas tecnológicas para la prevención del crimen. *Revista Escpogra PNP*, 3, 34-43.

<https://doi.org/10.59956/escpograpnpv3n1.3>

<https://bibdigital.epn.edu.ec/handle/15000/25083>

juanmolina15. (s. f.). Script/script.py at main · juanmolina15/Script. GitHub.

<https://github.com/juanmolina15/Script/blob/main/script.py>

L.Priyanka, & Sahithi, D. (2025). AUTONOMOUS FIREARMS DETECTION AND THREAT MONITORING USING DEEP VISION MODELS IN SMART CITIES. International Journal of Data Science and IoT Management System, 4(4), 181-186.

<https://doi.org/10.64751/>

Matczak, P., Wójtowicz, A., Dąbrowski, A., & Mączka, K. (2023). Cost-Effectiveness of CCTV Surveillance Systems: Evidence from a Polish City. European Journal on Criminal Policy and Research, 29(4), 555-577.

<https://doi.org/10.1007/s10610-022-09527-5>

Molina, J. (2026). Videos dataset. <https://doi.org/10.5281/zenodo.20724901>

Salazar Franco, M. A. (2023). Plataforma para desarrollo y evaluación de modelos de reconocimiento de gestos de la mano: Modelo de reconocimiento de 11 gestos de la mano usando deep learning y celdas de memoria desarrollado en Python.

Studer, S., Bui, T. B., Drescher, C., Hanuschkin, A., Winkler, L., Peters, S., & Müller, K.-R. (2021). Towards CRISP-ML(Q): A Machine Learning Process Model with Quality Assurance Methodology. Machine Learning and Knowledge Extraction, 3(2), 392-413.
<https://doi.org/10.3390/make3020020>