

Detección de Objetos y Patrones de Movimiento Usando Redes Neuronales y Algoritmos Genéticos para la Identificación de Robo a Mano Armada

Object Detection and Movement Patterns Using Neural Networks and Genetic Algorithms for the Identification of Armed Robbery

ARTICLE HISTORY

Received 29 April 2021

Accepted 17 May 2021

Walter Iván Leturia-Rodriguez

Ingeniería de Software
Universidad Privada Antenor Orrego
Trujillo, Perú
wleturiar1@upao.edu.pe
ORCID: 0000-0002-8184-2140

Luis Vladimir Urrelo-Huiman

Ingeniería de Computación y Sistemas
Universidad Privada Antenor Orrego
Trujillo, Perú
lurreloh@upao.edu.pe
ORCID: 0000-0003-1523-2640

Detección de Objetos y Patrones de Movimiento Usando Redes Neuronales y Algoritmos Genéticos para la Identificación de Robo a Mano Armada

Object Detection and Movement Patterns Using Neural Networks and Genetic Algorithms for the Identification of Armed Robbery

Walter Iván Leturia-Rodriguez
Ingeniería de Software
Universidad Privada Antenor Orrego
Trujillo, Perú
wleturiar1@upao.edu.pe
ORCID: 0000-0002-8184-2140

Luis Vladimir Urrelo-Huiman
Ingeniería de Computación y Sistemas
Universidad Privada Antenor Orrego
Trujillo, Perú
lurreloh@upao.edu.pe
ORCID: 0000-0003-1523-2640

Resumen—En América latina se encuentran 42 de las 50 ciudades más violentas del mundo, en el Perú el año 2019 el 9.7% de hechos delictivos con arma de fuego fueron realizados en zonas urbanas y en las ciudades de 20 mil a más habitantes el porcentaje se elevó al 10.2%, pero las denuncias, por falta de pruebas, generaron en ciudades como Lima, solo un 19.46% de detenciones. Los miembros del cuerpo policial disponen de dispositivos, vehículos y herramientas que les permiten ejercer sus funciones de una manera segura; sin embargo, no cuentan con un mecanismo efectivo, el cual permita identificar un robo a mano armada y concentrar sus esfuerzos en llevar a cabo una oportuna intervención. Por lo anterior, la presente investigación desarrolla un algoritmo basado en Redes Neuronales Recurrente con OpenCv/YOLOv3 combinada con la técnica de Algoritmos Genéticos para la detección de objetos y patrón de movimiento con un 96.5% de precisión, permitiendo la detección temprana ante un delito perpetrado bajo la modalidad de robo a mano armada.

Palabras claves—Aprendizaje Automático, Detección de Objetos, Detección de Patrón de Movimientos

Abstract—In Latin America there are 42 of the 50 most violent cities in the world, in Peru in 2019 9.7% of criminal acts with firearms were carried out in urban areas and in cities with 20,000 or more inhabitants the percentage rose to 10.2%, but the complaints, due to lack of evidence, generated in cities like Lima, only 19.46% of arrests. The members of the police force have devices, vehicles and tools that allow them to carry out their functions in a safe manner, however, they do not have an effective mechanism, which allows to identify an armed robbery and to concentrate their efforts on carrying out a timely intervention. Therefore, the present research develops an algorithm based on Recurrent Neural Networks with OpenCv / YOLOv3 combined with the Genetic Algorithms technique for the detection of objects and movement patterns with 96.5% accuracy, allowing early detection of a crime perpetrated under the modality of armed robbery.

Keywords—Machine Learning, Object Detection, Movement Pattern Detection

I. INTRODUCCIÓN

A. Planteamiento del Problema: Según [1], en su publicación denominada “A Comparative Study of the World’s Most Dangerous Cities: Violence as the Ultimate Public Health Challenge”, 42 de las 50 ciudades más violentas del mundo están en Latinoamérica. En el Perú, de noviembre 2018 a abril 2019, en víctimas de 15 a más años de edad, se registraron que el 9.7% de hechos delictivos con arma de fuego fueron realizados en zonas urbanas y en las ciudades de 20 mil a más habitantes, el porcentaje se elevó al 10.2% donde, por ejemplo en Lima, se generaron 170 295 denuncias y se detuvo a un total de 33 147 personas, dando un 19.46% de efectividad en este hecho delictivo [2].

Si bien, las denuncias tienen gran importancia durante el proceso de captura de los criminales, es un trabajo manual y arduo, el cual reduce el tiempo de operatividad de las fuerzas de seguridad del país.

B. Formulación del problema: La presente investigación busca resolver la interrogante de ¿Cómo incrementar la efectividad de detección ante un delito bajo la modalidad de robo a mano armada apoyándose en la inteligencia artificial?

C. Objetivo General: desarrollar un software de detección de objetos y patrones de movimiento usando Redes Neuronales y Algoritmos Genéticos para incrementar la efectividad de detección de delitos de robo a mano armada.

D. Objetivos específicos: estudiar el proceso de detección de delito de robo a mano armada con la finalidad de destacar su eficiencia. Recopilar datos previos a un evento de suceso

delictivo bajo la modalidad de robo a mano armada e identificar los indicadores determinantes para el diseño de la red neuronal de detección de patrones de peligro. Identificar los objetos que interactúan en un delito efectuado bajo la modalidad de robo con arma para el desarrollo de la red neuronal de detección de objetos reconocidos como arma. Identificar el comportamiento normal en los escenarios comunes de amplio tránsito y desarrollar la red neuronal para determinar la normalidad en un ambiente. Identificar la acción previa a la ejecución de un delito bajo la modalidad de robo a mano armada. Medir la eficacia en el tiempo de detección y certeza en un patrón de peligro provocado por un delito bajo la modalidad de robo con arma.

E. Antecedentes del estudio: los siguientes antecedentes abordan la problemática con técnicas de inteligencia artificial.

En la investigación: “Weapon Detection in Surveillance Camera Images” [3] se evaluaron 10 imágenes en las cuales se buscó calcular el rendimiento de la red neuronal entrenada con un dataset de 12830 imágenes. Tuvo una eficacia de 83.05% y la detección dependía de la calidad de imagen.

En la investigación: Crime Scene Prediction by Detecting Threatening Objects Using Convolutional Neural Network [4] se pudo detectar eficientemente sangre, armas blancas (cuchillo) y armas en las cuales se logró determinar si ocurrió un crimen o no. El modelo generado demostró una eficiencia al 90.2%.

En la investigación [5], Object detection from images using convolutional neural networks se demostró por qué las redes neuronales regulares no son suficiente para las tareas relacionadas con reconocimiento de imagen y cómo las redes de convolución constitutivas invariables proporcionan una solución efectiva para muchos problemas de visión de computadora.

La investigación Automated Detection of Firearms and Knives in a CCTV Image [6], propuso, implementó y probó algoritmos para la detección de un arma sostenida por una mano, obteniendo resultados positivos, divididos en “especificidad” y “sensibilidad”, los resultados obtenidos fueron: cuchillo con 94.93% y 81.18% respectivamente, así como 96.69% y 35.98% para armas de fuego. La limitación de la investigación está representada como “escenario” haciendo hincapié en la naturaleza de un escenario indoor y outdoor, descritos en la investigación como “bank scenario” y “street scenario”.

II. MARCO TEÓRICO

Aprendizaje automático: busca proporcionar a las computadoras la capacidad de aprender, sin ser programadas explícitamente. Se centra en el desarrollo de programas informáticos que pueden cambiar cuando se exponen a nuevos datos creando algoritmos que generalizan el comportamiento e identifican los patrones a partir de la información ingresada como ejemplo o entrenamiento, a esto se le denomina proceso de inducción del conocimiento [7], [8].

Red Neuronal Recurrente: son redes neuronales que integran bucles de realimentación, permitiendo a través de ellos que la información persista en algunas épocas de entrenamiento, lo anterior debido a conexiones desde las capas de salida insertándolos nuevamente en las capas de entrada [9].

Red Neuronal Convolutacional o de convolución: es un tipo de red neuronal artificial donde las neuronas corresponden a campos receptivos de una manera muy similar a las neuronas en la corteza visual primaria de un cerebro biológico. Este tipo de red es una variación de un perceptrón multicapa, sin embargo, debido a que su aplicación es realizada en matrices bidimensionales, son muy efectivas para tareas de visión artificial, como en la clasificación y segmentación de imágenes, entre otras aplicaciones [10].

Robo a mano armada: de acuerdo a la estructuración de las formas agravadas de comisión en el Código Penal Peruano [11], toda circunstancia agravante del robo, también del hurto y en general de todo delito que haya sido construido con el esquema bipolar: tipo básico y modalidades agravadas tiene en el tipo básico o simple su núcleo de tipicidad de observancia obligada, lo que exige, para afirmar el delito de robo agravado, verificar la concurrencia de todos los elementos objetivos y subjetivos contenidos en él. El hecho de hallarse el agente armado implica violencia/amenaza que se superponga a la del robo simple, y se trata de una de las expresiones concretas y particularizadas que ésta asume, significando un evidente aumento del injusto penal que hace más insoportable dicha conducta en términos jurídico-sociales.

Es importante precisar en el contexto de la presente investigación, la diferencia que existen entre las conductas ilícitas penales de hurto simple y robo, que atentan contra el bien jurídico del patrimonio, de la forma como están tipificadas en nuestro Código Penal, aprobado por el Decreto Legislativo N° 635 y modificatorias: Así, el tipo penal de hurto simple está definido en el Artículo 185 del Código Penal como “El que, para obtener provecho, se apodera ilegítimamente de un bien mueble, total o parcialmente ajeno, sustrayéndolo del lugar donde se encuentra será reprimido con pena privativa de libertad no menor de uno ni mayor de tres años ...” Para esta figura delictiva se admite un tipo penal agravante, en el Artículo 136, como hurto agravado, como consecuencia de la conducta: si se desarrolla durante la noche, sobre bienes que forman parte de equipaje de viajero, por el concurso de dos o más personas, entre otros.

Siendo así, debemos diferenciar el hurto de otro tipo penal contra el patrimonio, el robo; éste está definido en el Artículo 188 del Código Penal, como: “El que se apodera ilegítimamente de un bien mueble total o parcialmente ajeno, para aprovecharse de él, sustrayéndolo del lugar en que se encuentra, empleando violencia contra la persona o amenazándola con un peligro inminente para su vida o integridad física será reprimido con pena privativa de libertad no menor de tres ni mayor de ocho años”.

Ambas figuras delictivas atentan contra el patrimonio, siendo el robo el que representa la mayor peligrosidad, que se refleja en la pena más grave; la diferencia sustancial es que en el robo la apropiación de los bienes se realiza con violencia contra la persona agraviada, como por ejemplo con el uso de armas de fuego u otros medios que pueden atentar incluso con la vida del agraviado.

Hipótesis: un software de detección de objetos y patrones de movimiento usando Redes Neuronales y Algoritmos Genéticos incrementa la efectividad en la detección de delitos de robo a mano armada.

III. METODOLOGÍA

La metodología aplicada en la presente investigación siguió las siguientes fases:

Estudio del proceso de detección de delito de robo a mano armada con la finalidad de destacar su eficiencia.

Identificación de objetos que interactúan en un delito efectuado bajo la modalidad de robo con arma para el desarrollo de la red neuronal de detección de objetos reconocidos como arma.

Detección de patrón de movimiento para la identificación de delito de robo a mano armada.

Desarrollo y entrenamiento de las Redes Neuronales determinando el número de neuronas de las capas de entrada, oculta y salida, así como también las diferentes funciones de activación que se utilizarán en las neuronas de la capa oculta y salida.

Identificación de la acción previa a la ejecución de un delito bajo la modalidad de robo con arma.

Medición del tiempo de detección y precisión del modelo que busca detectar un patrón de peligro provocado por un delito bajo la modalidad de robo con arma.

IV. DISEÑO E IMPLEMENTACIÓN

A. El proceso de detección de delito de robo a mano armada.

El artículo 259 del Código Procesal Penal Peruano establece los siguientes supuestos específicos de Flagrancia Delictiva: La Policía Nacional del Perú detiene, sin mandato judicial, a quien sorprenda en flagrante delito. Existe flagrancia cuando: El agente es descubierto en la realización del hecho punible. El agente acaba de cometer el hecho punible y es descubierto. El agente ha huido y ha sido identificado durante o inmediatamente después de la perpetración del hecho punible, sea por el agraviado o por otra persona que haya presenciado el hecho, o por medio audiovisual, dispositivos o equipos con cuya tecnología se haya registrado su imagen, y es encontrado dentro de las veinticuatro (24) horas de producido el hecho punible. El agente es encontrado dentro de las veinticuatro (24) horas después de la perpetración del delito con efectos o instrumentos procedentes de aquel o que hubieren sido empleados para cometerlo o con señales en sí mismo o en su vestido que indiquen su probable autoría o participación en el hecho delictuoso.

El protocolo está dividido en 2 procedimientos y 14 sub-procedimientos, los cuales tienen como responsables a la Policía Nacional del Perú (1-11) y Ministerio Público y Policía Nacional (12-14).

La presente investigación busca mejorar el sub-procedimiento número 1 ante la detección de flagrancia: Cuando el efectivo policial advierta a través de sus sentidos que está ante un hecho que configura flagrancia delictiva, procederá a la detención de la o las personas que se encontraren en el lugar.

“Las cámaras son elementos tecnológicos que complementan las acciones de patrullaje, el cual debe realizarse en coordinación entre serenos y policías. En casi todas las centrales de monitoreo de cámaras de seguridad que tienen los municipios hay un policía que avisa a la Central 105

cuando se ha reportado un crimen o asalto” pero se deben tomar en cuenta dos dificultades principales. Las cámaras instauradas, las cuales sirven para prevención de delito, tienen una definición promedio de 720pp, la cual se debe tener en cuenta al momento de entrenar los algoritmos de redes neuronales.

B. Identificación de objetos que interactúan en un delito efectuado bajo la modalidad de robo a mano armada.

Dentro del material analizado se pudo llegar a la identificación de los siguientes indicadores: nombre, cantidad de sujetos, sexo de los sujetos, vestimenta de los sujetos, uso de gorra, uso de lentes, uso de capucha, permanencia en los alrededores, uso de celular, posición de las manos, objetos adicionales y vehículo motorizado.

Con los indicadores principales previamente identificados se delimitó la estructura de proyecto.

El flujo principal es una constante evaluación basada en captura de cuadros, dentro de los cuales se realizarán tres procesos de identificación, que están descritos en la Fig. 1.

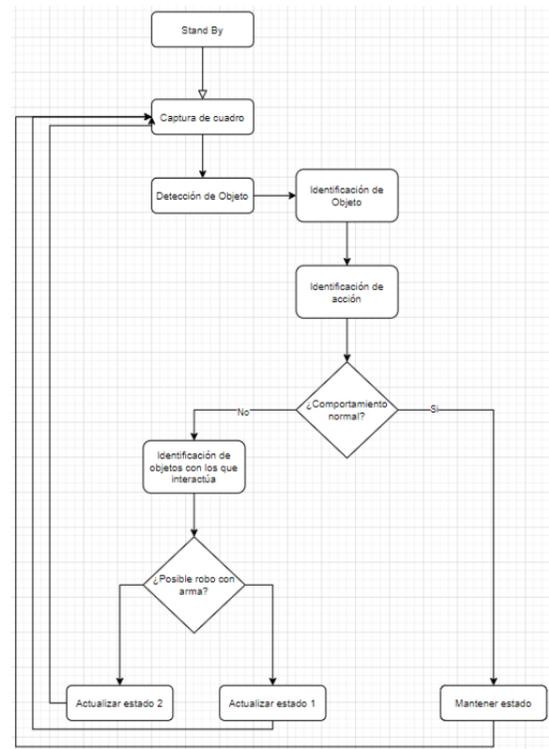


Fig. 1. Proceso de constante evaluación de cuadros

B.1 Captura de cuadro

Para la captura de cuadro se configuró una entrada estándar de video (puerto serial), por motivos de prueba se adaptó también la lectura a través de canal de streaming (con url de video). La captura está en la estructura de un loop el cual se mantiene operando mientras exista una entrada o el usuario presione el número de salida “0”.

Para la detección se utilizó la API de OpenCV en Python, debido a que es una biblioteca de funciones de programación dirigida principalmente a la visión por computadora en tiempo real.

B.2 Limpieza y pre procesamiento de imágenes

Para la limpieza y pre-procesamiento de imágenes se aplicaron filtros teniendo en cuenta una resolución estándar de cámaras de seguridad (720pp), los filtros fueron: filtro gaussiano, filtro cromático y filtro de superficies (cóncavo y convexo), con los cuales se obtuvo una imagen procesada en bits para su posterior tratamiento y delimitación.

B.3 Identificación de objetos

Se procedió a implementar la librería de identificación de objetos YOLOv3, adaptada para detectar un nuevo objeto arma (weapon), en este caso se consideraron como armas cuchillo, bate de béisbol y pistola generando una arquitectura como la mostrada en la Fig. 2.

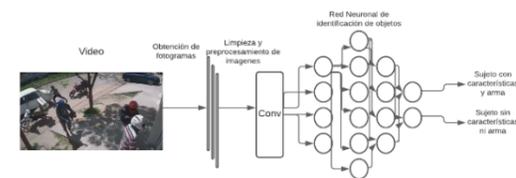


Fig. 2. Arquitectura para identificar objetos, personas con armas y aplicando la biblioteca Yolov3.

El entrenamiento se llevó a cabo con un dataset de 100 imágenes en 3 épocas con variaciones, rotaciones y transformaciones recreadas con OpenCV, con la finalidad de brindar “variedad” al entrenamiento y generar una identificación de persona que generará un potencial robo o no; entrenado el modelo, se obtuvieron resultados al 81% de precisión, con el ratio de aprendizaje mostrado en la Fig. 3.

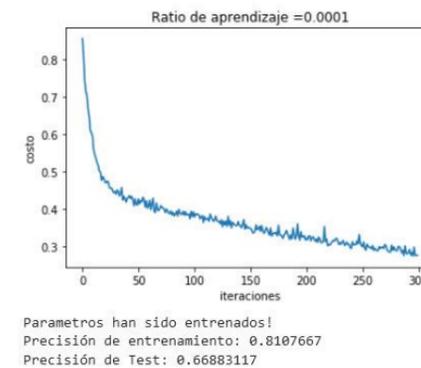


Fig. 3. Ratio de aprendizaje del modelo detectando personas con armas

C. Detección de patrón de movimiento para la identificación de delito de robo a mano armada

En los videos recopilados para el estudio de los delitos efectuados bajo la modalidad de robo con arma, se cuenta con múltiples escenarios, siendo los más comunes: Paseos peatonales, minimarkets y centros comerciales.

Se cuenta con poco tiempo para determinar si la acción que está cometiendo esta persona es o no de carácter delictivo. Por lo cual la identificación de objetos no es el punto determinante para la identificación de un suceso delictivo, sino el

movimiento que realiza el cual se puede encasillar como normal o anómalo.

Se evaluó a profundidad el escenario de un paso peatonal (pedestrian-walk).

Se concluye que el patrón de movimiento normal de una persona se determina según el escenario donde se encuentra.

Se realizó una comparativa basada en los resultados de un video y se definieron los siguientes puntos para evaluar la normalidad en un paso peatonal: permanencia y dirección, luego se implementó dentro del sistema un contador de permanencia en plano, teniendo las funciones de identificar al objeto desde que entra en el plano, y evaluar el dato de Permanencia (en segundos). Para el punto de dirección se desarrolló un flujo de tracking con una Rede Neuronal LSTM, el cual consiste en determinar la dirección del objeto basado en sus puntos anteriores, según se muestra en el siguiente código.

```

un = 50
regressor = Sequential()
regressor.add(LSTM(units=un, return_sequences=True,
input_shape=(X_train.shape[1], 1)))
regressor.add(Dropout(0.2))
regressor.add(LSTM(units=un, return_sequences=True))
regressor.add(Dropout(0.2))
regressor.add(LSTM(units=un, return_sequences=True))
regressor.add(Dropout(0.2))
regressor.add(LSTM(units=un))
regressor.add(Dropout(0.2))
regressor.add(Dense(units=1))
regressor.compile(optimizer='adam', loss='mean_squared_error')
regressor.fit(X_train, y_train, epochs=100, batch_size=32)
    
```

El algoritmo para obtener el recorrido del objeto se realizó con la imagen previamente procesada, con la finalidad de obtener un objeto tipo binario, para evitar sobrecarga.

D. Desarrollo y entrenamiento de las redes neuronales con entrenamiento de algoritmos genéticos

Con las variables identificadas se definió una red neuronal, la cual es de tipo recurrente LSTM, que recibe como datos de entrada el tiempo de permanencia y las direcciones que va tomando el objeto persona para identificarla como sospechosa, según se muestra en la Fig. 4.

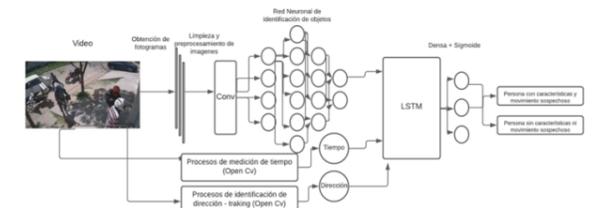


Fig. 4. Esquema con la Red Neuronal LSTM para detectar movimiento de persona sospechosa

Para esta red neuronal se optó por el entrenamiento con algoritmos genéticos, definiendo la función de evaluación basado en la precisión de la detección. La explicación de la función de evaluación se determinó con base en la permanencia de direcciones que ocupó el objeto y el tiempo que le tomó realizar sus movimientos según como se muestra en el siguiente código.

V. PRUEBAS Y RESULTADOS

Detección de patrón de movimiento para la identificación de delito de robo a mano armada

En la Fig. 5. se muestra la detección al 96.5% de exactitud, en el video de prueba expuesto a la red neuronal, del patrón de comportamiento como robo que se validaría ante la detección de un arma, este punto por evaluar se denominará intensidad, y es el determinante fundamental que toma como referencia el patrón de comportamiento, el sujeto y los objetos con los cuales interactúa para determinar la posibilidad de que vaya a cometer un delito bajo la modalidad de robo con arma.



Fig. 5. Patrón de movimiento detectado como robo en un escenario de paso peatonal

Se realizaron mediciones del tiempo de detección de la manera tradicional y utilizando el sistema según se señala en la tabla I, mostrando un nivel de confiabilidad, ante la prueba Alfa de Cronbach, mostrando un coeficiente de 0.85 que por su proximidad al 1 nos indica que las mediciones de tiempo son confiables.

TABLA I. TIEMPOS Y PRECISIÓN DE DETECCIÓN DE ACCIONES DE ROBO A MANO ARMADA

Grupo (Experimento)	Precisión	
	Tiempo (s) De Respuesta	Prueba (Accuracy)
Grupo 1 (1)	50	79.18%
Grupo 1 (2)	56	96.50%
Grupo 1 (3)	60	77.05%
Grupo 1 (4)	55	78.61%
Grupo 1 (5)	65	80.31%
Grupo 1 (6)	67	81.16%
Grupo 1 (7)	54	80.45%
Grupo 1 (8)	51	83.00%
Grupo 1 (9)	64	82.01%
Grupo 1 (10)	71	81.16%
Grupo 2 (1)	120	-
Grupo 2 (2)	125	-

```
import numpy as np
DNA = 10 # Cadena a variar
POP = 100 # Tamaño de población
CROSS = 0.8 # Probabilidad de cruce
MUTATION = 0.003 # Probabilidad de mutación
GENERATIONS = 300 # Cantidad de generaciones
UPPER_LOWER = [0, 5] # Bordes delimitantes
# Encontrar el máximo de una función
def F(t):
    return np.sin(10 * t) * t + np.cos(2 * t) * t
# Encontrar candidatos diferentes a cero para selección
def get_fitness(pred):
    return pred + 1e-3 - np.min(pred)
# Se normaliza la data en nuestros rangos
def translateDNA(pop):
    return pop.dot(2 ** np.arange(DNA)[:, -1]) / float(2**(DNA-1) *
UPPER_LOWER[1])
def select(pop, fitness):
    # La función de selección se hace basado en el rango disponible y su función de
    # evaluación
    idx = np.random.choice(np.arange(POP), size=POP,
    replace=True, p=fitness/fitness.sum())
    # Retomamos el objeto
    return pop[idx]
def crossover(parent, pop): # (CROSSOVER)
    if np.random.rand() < CROSS:
        # Seleccionamos otro individuo de la población
        i = np.random.randint(0, POP, size=1)
        # Elección de puntos
        crossing = np.random.randint(0, 2, size=DNA).astype(np.bool)
        # Cruce y obtención de hijo
        parent[crossing] = pop[i, crossing]
    return parent
def mutate(child):
    for point in range(DNA):
        if np.random.rand() < MUTATION:
            child[point] = 1 if child[point] == 0 else 0
    return child
pop = np.random.randint(2, size=(POP, DNA)) # Inicialización de cadena
for _ in range(GENERATIONS):
    # Extracción de ADN
    F_values = F(translateDNA(pop))
    fitness = get_fitness(F_values)
    print("Cadena con mayor aceptación: ", pop[np.argmax(fitness), :])
    pop = select(pop, fitness)
    pop_copy = pop.copy()
    for parent in pop:
        child = crossover(parent, pop_copy)
        child = mutate(child)
        parent[:] = child # Reemplazando valores en padre
print("Modelo finalizado")
```

Grupo 2 (3)	120	-
Grupo 2 (4)	130	-
Grupo 2 (5)	140	-
Grupo 2 (6)	150	-
Grupo 2 (7)	120	-
Grupo 2 (8)	125	-
Grupo 2 (9)	135	-
Grupo 2 (10)	145	-

* El grupo 1 son los experimentos contando con el modelo de detección, el grupo 2 es la detección por parte de personas en video vigilancia.

El nivel de normalización de los tiempos de detección con y sin el sistema se muestra en la Tabla II, donde los grados de significancia de la prueba Shapiro-Wilk son mayores a 0.05, indicándonos que los datos tienen distribución normal.

TABLA II. PRUEBA DE NORMALIZACIÓN DE LAS MEDICIONES DE TIEMPO DE DETECCIÓN

prueba	Kolmogorov-Smirnov*			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
Sistema	.219	10	.190	.933	10	.477
Tradición	.207	10	.200*	.890	10	.171

*. Esto es un límite inferior de la significación verdadera.

Al contar con una distribución normal de las mediciones de tiempos de detección en ambos grupos de mediciones, se pudo corroborar que podíamos aplicar la prueba T Student.

VI. DISCUSIÓN DE RESULTADOS

Se determinó que el accionar del cuerpo policial está ligado al monitoreo constante y un plan de confrontación temprano, el cual consiste en la distribución de unidades en los "focos" de peligro.

Asimismo, por observación esta investigación resalta que el proceso de prevención y el accionar temprano están ligados al cuerpo policial, los cuales actúan preventivamente bajo experticia, es decir cuando identifican un potencial peligro basándose en sus años de servicio. Y su accionar está justificado bajo la ley de flagrancia, siempre y cuando estos delitos cumplan los requisitos mínimos, tales como que el crimen cometido está probado de manera indubitable, es decir que no cabe duda alguna de que la persona es culpable. Gracias a esta normativa, los efectivos policiales se encargan de imponer una presencia significativa al momento de hacer frente a un delito.

Durante la recopilación de material en video se realizaron diferentes anotaciones del accionar de los criminales al momento de ejecutar un robo a mano armada. La principal anotación y la cual presentó también mayor dificultad al momento de ser plasmado en un algoritmo es el tiempo de ejecución, los robos a mano armada son de carácter rápido y violento, tienen como característica principal que la persona que lo ejecuta busca sustraer la mayor cantidad de valor material posible, sin importar si su vida o la de la víctima se encuentra en riesgo.

Adicionalmente se recopilaron las principales características (normales y anómalas) de vestimenta, desplazamiento y objetos con los que interactúan según cada escenario estudiado (paso peatonal, minimarket y centro comercial). Una vez obtenidos los datos principales se realizó el diagrama de flujo del proyecto, con la finalidad de identificar las tecnologías y herramientas que debían ser implementadas para el correcto funcionamiento de este.

Para el desarrollo del objetivo específico que buscó implementar una red neuronal para determinar la normalidad en un ambiente se optó por la API de OpenCV, por la función de limpieza de imagen de entrada, que eventualmente fue requerida no solo para la detección, sino para, el seguimiento. Esta API se implementó junto con la biblioteca Numpy, para trabajar las imágenes como vectores.

Para el presente objetivo se utilizó la librería de YOLOv3, asimismo se determinó que no era suficiente para poder detectar todos los objetos que demandaba la naturaleza del proyecto, por lo cual se adicionó un entrenamiento específico a la detección de objetos denominados arma (bate de beisbol, pistola y cuchillo). Para lograr el entrenamiento se tuvo que

utilizar también una herramienta que permita la etiquetación del dataset.

Una vez entrenada la red neuronal para el entorno de reconocimiento de armas se obtuvo un resultado de 81% en promedio al ejecutar muestra de evaluación. En la investigación: "Weapon Detection in Surveillance Camera Images" se obtuvo una eficacia final de 81%. Si bien el entrenamiento no fue arduo y no se detecta armas en variedad como lo hace la anterior investigación mencionada si se puede asegurar una efectividad alta al detectar armas, lo cual era un pilar para el desarrollo de la presente investigación.

Evaluados los escenarios comunes (Paseos peatonales, minimarkets y centros comerciales) se recopilaron videos, de los cuales se analiza el patrón de conducta normal. Una vez analizados los comportamientos según cada escenario, se seleccionó el escenario de paseo peatonal para la obtención de indicadores.

En los paseos peatonales predomina:

- Movimiento recto.
- Paso constante.
- Cantidad de individuos inferior a 3.
- Tiempo de permanencia corto.
- Sin objetos en posesión.
- Distanciamiento individual mayor a 1 metro.

Estos representan una entrada respectiva en la red neuronal, el ajuste de los pesos se hizo mediante la implementación de algoritmos genéticos y backpropagation. Para esta implementación, los videos seleccionados fueron etiquetados cada uno con su respectivo valor (comportamiento normal, comportamiento anormal).

En el caso de algoritmos genéticos, la inicialización de población fue aleatoria, la función de evaluación se determinó según los aciertos realizados basándose en los videos previamente etiquetados. Para este escenario se determinó un estancamiento a partir de las 300 generaciones, es decir los pesos no se ajustaban significativamente, por lo que se procedió a terminar las iteraciones.

La presente investigación resalta la eficacia de entrenamiento de una Red Neuronal empleando Algoritmos Genéticos, debido a que se obtuvo un resultado de aprobación favorable, con un 96.5% de exactitud en las pruebas de detección de un comportamiento anormal, mientras que el entrenamiento empleando backpropagation obtuvo un 63% de confianza en las pruebas realizadas.

Si bien la complejidad de un patrón de comportamiento normal no presenta una dificultad mayor frente a este tipo de entrenamiento, debido a la cantidad de variables y la variación corta de estas, la obtención de los indicadores si fue desafiante.

Determinados los comportamientos normales según escenario, y seleccionando al escenario de paseo peatonal para el estudio, se identificaron las acciones que determinan un robo a mano armada inminente.

Con este punto, la investigación hace énfasis en que la dificultad principal que determina la investigación no es la correcta identificación de un objeto que presente un peligro,

sino el comportamiento previo de un individuo a la manipulación de éste.

VII. CONCLUSIONES

Del estudio realizado al proceso de detección temprana y/o prevención de delito con arma se llegó a la conclusión de que los efectivos policiales necesitan una herramienta que facilite su labor al momento de ejercer sus funciones como protectores de la ley debido a que solo cuentan con dos estrategias para actuar, una preventiva y otra correctiva. La preventiva consiste en mover al cuerpo policial a los focos de delincuencia/delito, con la finalidad de imponer presencia y evitar algún cometido. La estrategia correctiva consiste en una vez identificado el acto delictivo, proceder a actuar bajo la modalidad de flagrancia, que consiste en detener a los sospechosos del delito en cuestión.

Los indicadores clave de un evento de suceso delictivo bajo la modalidad de robo con arma se trazaron basándose en la amenaza que representa el comportamiento de una persona junto con su interacción con los objetos en el entorno.

Los objetos en un delito efectuado bajo la modalidad de robo con arma que mantienen un rol determinante fueron identificados como: pistola, bate de beisbol y cuchillo. Se obtuvo un 81% de exactitud al ejecutar la muestra de evaluación.

No se situó un comportamiento de escenario estándar, los lugares estudiados fueron: paso peatonal, minimarket y centro comercial. Teniendo los mejores resultados en paso peatonal con un resultado favorable de 96.5% de precisión.

Se determinó que la acción previa ante un delito con arma es difícil de identificar por su naturaleza de corta duración (2-

3 segundos) por lo que el estado de alerta es detonado desde la identificación de comportamiento anómalo en un escenario.

REFERENCIAS

- [1] Y. Ming y C. Camp Yeakey: "A Comparative Study of the World's Most Dangerous Cities: Violence as the Ultimate Public Health Challenge, *Insights of Anthropology*", vol. 2, n° 1, pp. 67-85, (2018).
- [2] INEI: Estadísticas de Seguridad Ciudadana, Noviembre 2018 – Abril 2019, p. 39, (2019).
- [3] R. Vajhala, R. Maddineni, y P. Raj Yeruva: "Weapon Detection in Surveillance Camera Images, *Bleking Institute of Technology*", 2016.
- [4] M. Nakib, M. Sakibul Hasan, R. Tanvir Khan y J. Uddin: "Crime Scene Prediction by Detecting Threatening Objects Using Convolutional Neural Network", *IEEE Explore, Uk*, 2018.
- [5] O. Stenroos: "Object detection from images using convolutional neural networks, *Aalto University Master's Programme in Computer, Communication and Information Sciences*", 2017.
- [6] M. Grega, A. Matiolanski, P. Guzik y M. Leszczuk: "Automated Detection of Firearms and Knives in a CCTV Image, *Murali Subbarao*", 2015.
- [7] Google Cloud, Business impacts of machine learning, *Google Cloud*, 2017.
- [8] F. Sancho Caparrini: "Introducción al Aprendizaje Automático", 2017/09/23. [En línea]. Available: <http://www.cs.us.es/~fsancho/?e=75>. [Último acceso: 2019/02/18].
- [9] R. Velasquez y G. Acuña: "Entrenamiento de Redes Neuronales Recurrentes para Sistemas Dinámicos Tipo NARMAX Y NOE, *SBIC Sociedad Brasileira de Inteligencia Computacional*", 2016.
- [10] J. Gelvez Prieto: "Redes neuronales convolucionales y redes neuronales recurrentes en la transcripción automática, *Universidad Nacional de Colombia*", 2019.
- [11] Ministerio de Justicia y Derechos Humanos, Código Penal Peruano, Lima: Ministerio de Justicia y Derechos Humanos, 2016.

AUTHORS

Walter Leturia-Rodriguez



Peruano, Ingeniero de Software egresado de la Universidad Privada Antenor Orrego en 2020, apasionado en el campo de la inteligencia artificial. Actualmente cursa el máster en inteligencia artificial en la Universidad Internacional de La Rioja (UNIR) y trabaja en análisis de datos y procesamiento de imágenes morfológicas aplicadas a la resolución de problemas en el área clínica.

Luis Urrelo-Huiman



Peruano, Ingeniero de Computación y Sistemas, maestro en Ingeniería de Sistemas con mención en Ingeniería de Software, maestro en Sistemas con mención en Sistemas de Información, Doctor en Ciencias e Ingeniería. Especialista en Gestión de Proyectos Tecnológicos, Web Semántica, Big Data, Analítica e Inteligencia Artificial y Computación Paralela, consultor en despliegue de sistemas informáticos, expositor y docente a nivel de Pregrado y Posgrado.