

Recopilación y análisis de datos para la implementación de un sistema que ayude a la predicción de intenciones de robo en personas

Juan Carlos Sánchez Navarro, Blanca Estela Pedroza Méndez,
José Federico Ramírez Cruz, Rubén Xochitiotzi Cuatecontzi,
Abel Martínez Gorospe

Instituto Tecnológico Nacional de México / Campus Apizaco,
Tlaxcala, México

{m19371377, blanca.pm, federico.rc, m19371381,
m19371369}@apizaco.tecnm.mx

Resumen. Con el paso de los años, los robos a casa habitación, empresas y establecimientos, han ido en incremento, por lo que muchas instituciones buscan contrarrestar esa situación, ya que esto afecta a la integridad de las personas que son víctimas. Es evidente que no es fácil detectar las intenciones negativas de un individuo o de una persona que desea cometer un robo, sin embargo, existen trabajos que están enfocados a desarrollar sistemas que ayuden a este fin. En este artículo se analiza el cómo recopilar características para predecir intenciones de robo en personas, traspasando el conocimiento que algunos expertos en el tema han obtenido de manera empírica o psicológica. Con base al enfoque planteado, se puede generar información, a través de patrones obtenidos de las expresiones faciales de un sujeto y predecir emociones durante un intervalo de tiempo. Los resultados obtenidos muestran que al momento de cometer un robo las personas sienten miedo, sorpresa y por alguna razón felicidad, pero casi nunca sufren un disgusto. A partir de esta información se podría conocer la probabilidad de que algún individuo tenga intenciones de cometer un robo. Así mismo, a partir del análisis realizado, se propone una metodología para generar conjuntos de datos, a través de la detección de emociones por medio de micro expresiones, para posteriormente usar un algoritmo de aprendizaje automático no supervisado, como podría ser DBSCAN para predicción y agrupamiento de clústeres para un correspondiente análisis.

Palabras clave: Predicción de robos, reconocimiento facial de emociones, aprendizaje automático supervisado, aprendizaje automático no supervisado.

Data Collection and Analysis for the Implementation of a System for the Prediction of Robbery Intentions in People

Abstract. Over the years, robberies from homes, businesses and establishments have been on the increase, so many institutions seek to counteract this situation, since this affects the integrity of the people who are victims. It is evident that it is not easy to detect the negative intentions of an individual or a person who wishes to commit a robbery, however, there are works that are focused on

developing systems that help to this end. This article analyzes how to collect characteristics to predict robbery intentions in people, transferring the knowledge that some experts on the subject have obtained empirically or psychologically. Based on the proposed approach, the information can be generated through patterns obtained from the facial expressions of a subject and predict emotions during a time interval. The results currently obtained show that at the time of committing a robbery, people feel fear, surprise and for some reason happiness, but they almost never experience an upset. From this information, the probability that an individual has intentions to commit a robbery could be known. Likewise, based on the analysis carried out, a methodology is proposed to generate data sets, through the detection of emotions through micro expressions, to later use the unsupervised machine learning algorithm such as DBSCAN for prediction and grouping of clusters for a corresponding analysis.

Keywords: Theft prediction, facial emotion recognition, supervised machine learning, unsupervised machine learning.

1. Introducción

El saber si una persona tiene intenciones de realizar un acto ilícito es una tarea difícil, y aunque algunos tengan la capacidad de detectar esto, de manera empírica, no muchos cuentan con esta habilidad. Es por ello, que en este artículo se realiza un análisis de diversos algoritmos que pueden ayudar a generar una metodología para realizar un sistema capaz de predecir intenciones de robo en personas con base a sus patrones.

A partir de esta premisa, la idea de un análisis para crear un sistema, ayudaría a la toma de decisiones, con base a la detección de robos, lo cual, significaría una mejora en la calidad de vida, tanto de un consumidor, trabajador y/o dueño de algún establecimiento. Para ello, la pregunta de investigación es: ¿cómo realizar un sistema computacional capaz de procesar datos y transformarlos en información que permita predecir robos antes de ser cometidos o durante la acción?

Para resolver esta pregunta, es imprescindible conocer el área de impacto donde surge esta idea, la cual pertenece al campo de la seguridad pública o privada, donde el obtener soluciones cada vez más inteligentes es de suma importancia para resolver temas subsecuentes, como son los robos.

Por tanto, es importante saber definir que es un robo, y existiendo diferentes definiciones de acuerdo con la cultura y al contexto que aborda este tema, se puede definir como “apropiarse de algo ajeno por medio de la fuerza o por intimidación” [1]. La fuerza o intimidación que se maneja en la definición anterior puede tener graves consecuencias hacia una persona, ya sea una lesión pequeña o incluso la muerte.

Además, es importante conocer algunos otros términos para la comprensión de este artículo. El reconocimiento facial de emociones, es un dominio que estudia la forma de analizar y reconocer los movimientos faciales y los cambios en los rasgos del rostro para con esto hacer una predicción de la emoción de alguna persona [2].

El aprendizaje automático es una rama de la inteligencia artificial, dentro de la cual, se desarrollan técnicas para que las computadoras aprendan con base a la detección de patrones en conjuntos de datos [3].

El artículo está estructurado de la siguiente manera: en la sección 2, se presenta una revisión de diversos trabajos relacionados a la detección de robos, para encontrar

algoritmos que ayuden a la recopilación de datos y a su análisis. En la sección 3, se muestra el análisis propuesto, con una tabla de resultados, que muestra algunas observaciones para la implementación de un sistema para detección de robos. Finalmente, en la sección 4, una propuesta para un sistema capaz de predecir intenciones de robo en personas y avances de recopilación de datos, y en la sección 5, se dan las conclusiones y trabajos futuros.

2. Trabajos relacionados

La idea de usar sistemas por computador para ayudar a la seguridad no es un tema nuevo, dado que existen sistemas y publicaciones científicas antiguas que tenían esta finalidad, por ejemplo, en 1998 en Taiwán predominaban los criminales que chantajeaban a la gente por medio de llamadas. Por esta situación se propuso un sistema capaz de consultar una base de datos que contenía voces de criminales y delimitar resultados, que podrían ser la voz del criminal que estaba al otro lado del teléfono [4].

Entre otros ejemplos, existen sistemas de biometría que sirven para que una persona no reconocida, no pueda tener acceso a una caja fuerte, a un smartphone, entre otros. También existen rastreadores para saber en dónde está un objeto, por ejemplo, un carro, lo cual sirve mucho en dado caso de un robo. Basado en estos sistemas desarrollados para el campo de seguridad, uno de los que impulsa de manera significativa el planteamiento de este artículo, son las cámaras con sistema de detección de rostros.

Este sistema es muy atractivo, pues puede reconocer, a través de rasgos faciales, a una o varias personas y dentro del entorno de la seguridad este reconocimiento permite asegurar el acceso a un lugar u objeto, pero ¿qué pasaría si vamos más lejos? Si en lugar de detectar una persona, detectará si esa persona desea cometer una acción, por ejemplo, un robo. Basado en esa premisa, la gran pregunta realizada es ¿Cómo predecir si una persona quiere cometer un robo?

2.1. ¿Cómo predecir cuándo un individuo tiene intenciones de robar?

Basado en como predecir si una persona tiene intenciones delictivas, se puede realizar la pregunta siguiente: ¿Qué datos se necesitan dar a un ordenador para poder hacer esto posible? Para eso se toman varias contribuciones que se han hecho a lo largo del tiempo como las de [5–8].

Con base a estas, se puede observar que los actos criminales pueden ser individuales o colectivos y que los patrones de comportamiento son de suma importancia para predecir actividades criminales, pero ¿Qué pasa si ahora se genera un enfoque relacionado solamente con atributos de un ladrón? ¿Se pueden utilizar cuestiones psicológicas para la detección de este tipo de criminales?

Para contestar estas preguntas se rescata información útil de un artículo publicado en el 2019 escrito por Yajie Su, Han Lu y Hongzhou Zhang titulado “Modelado de mapeo cualitativo del sentido de seguridad de los delincuentes en casos de robo” [9]. En dicho artículo se utiliza una relevante investigación dentro del campo de la psicología criminalística, donde el trabajo recoge la experiencia y el conocimiento de los investigadores en casos de robo, a través de entrevistas y cuestionarios, y obtiene

los principales factores que afectan la sensación de seguridad interior de los delincuentes, en todo el proceso de comisión de un delito.

Ahora bien, uno de los fundamentos para esa investigación fue la realizada por Maslow, quien propuso que, dentro de la necesidad de una persona interviene la seguridad a nivel de demanda después de las necesidades fisiológicas básicas de los seres humanos. “Una sensación de seguridad es la sensación de fortaleza o debilidad de una persona al lidiar con el miedo y la ansiedad, que se manifiesta principalmente en una sensación de certeza y control” [9].

También existe una clasificación teórica de ladrones, basada en observaciones [10] y se definen en cuatro tipos: el organizado, el desorganizado, el interpersonal y el oportunista. Dentro de los cuales se pueden ver características psicológicas y puntos básicos relacionados con sus emociones.

Conociendo esto, se puede deducir que para detectar si un individuo tiene intenciones de robar, se pueden examinar patrones psicológicos, y aun mejor, patrones emocionales de la(s) persona(s) para generar un sistema capaz de alarmar cuando esto suceda.

2.2. Reconocimiento de emociones

Para crear un sistema capaz de reconocer emociones con el propósito anterior, primero se necesita saber cómo recolectar los patrones emocionales, para detectar personas con estas intenciones de robo. De esta manera, se conoce que existen sistemas computacionales basados en reconocimiento de patrones de voz, reconocimiento de patrones en imágenes (en este caso, secuencias de varias imágenes), reconocimiento de patrones cerebrales, reconocimiento de la frecuencia cardíaca, entre algunos otros, que se utilizan para el reconocimiento de emociones.

Pero bien, teniendo en cuenta que la mayoría de los lugares de aplicación en donde tendría utilidad un sistema capaz de predecir intenciones de robo en personas, ya cuentan con sistemas de cámaras, en este artículo nos enfocamos en el reconocimiento con dichas herramientas, por lo tanto, una de las mejores opciones es enfocarse en el reconocimiento de imágenes.

Ya definido lo anterior, ahora se hará el seguimiento con base en cómo se clasifican las emociones, tomando en cuenta la investigación de Paul Ekman, considerado uno de los mejores expertos del mundo en el análisis del comportamiento no verbal y la detección del engaño. Ekman demostró que Darwin estaba en lo cierto en 1969 con el libro llamado “La expresión de las emociones en los animales y el hombre”, y en 1978 presentó junto a su compañero Wallace Friesen el FACS (Facial Action Coding System), un sistema de codificación que recoge todos los movimientos expresivos del rostro, en unidades de acción (AU) [2].

En la actualidad, este sistema se utiliza en la comunidad científica internacional. Las siete emociones básicas universales que él propuso son; la sorpresa, la tristeza, el desprecio, el miedo, la ira, la alegría y el asco, y cada una tiene sus propias unidades de acción, características que facilitan su reconocimiento. Esa investigación ayudó a la creación de varios sistemas de reconocimiento de emociones [11–13].

Basándose en estas emociones principales, se entiende que se pueden utilizar para el reconocimiento de emociones en imágenes [13–16]. También se ha observado en varias investigaciones científicas que, para entrenar un modelo capaz de clasificar las

emociones dentro del campo de la visión artificial, exactamente dentro del reconocimiento de imágenes, el ocupar una red neuronal convolucional es el método ideal para recoger patrones que definen una emoción dentro de una imagen y una forma eficiente de extraer emociones de una persona es enfocarse en sus expresiones faciales, además de que esto necesita un poder de cómputo intermedio [16].

3. Elección de algoritmo clasificador

Ahora bien, para desarrollar un sistema que pueda realizar la acción que se menciona al comienzo de este artículo, se necesita utilizar algún algoritmo de aprendizaje automático para poder predecir no solo las emociones del ladrón, sino también, clasificar en grupos los conjuntos de emociones al momento de cometer un robo o al tener la intención de realizar esta acción, para ello existen diversas fuentes que ayudan a la comprensión de los métodos de aprendizaje automático como los que se presentan en [17], dónde se obtiene la clasificación de estos métodos, la cual es: aprendizaje supervisado y aprendizaje no supervisado. Entonces ¿Cuál es el tipo de aprendizaje automático adecuado para un sistema con la habilidad que se ha mencionado a lo largo de este artículo?

Aprendizaje supervisado. Los algoritmos del aprendizaje supervisado se basan en instancias (propiedades o características) que son etiquetadas para poder hacer una predicción sobre futuras instancias [18, 19].

Aprendizaje no supervisado. Los algoritmos de aprendizaje no supervisado utilizan instancias sin etiquetar para detectar patrones entre las instancias y clasificarlos para obtener predicciones [19].

Conociendo la finalidad que tiene cada uno de los tipos de aprendizaje, se puede deducir que, el algoritmo más adecuado para crear un sistema capaz de detectar intenciones de robo en personas es el aprendizaje no supervisado, puesto que aunque ya existen algunas clasificaciones para los ladrones [10], si se realiza el enfoque en las emociones que se pueden observar en expresiones faciales, podrían existir algunos grupos y/o subgrupos que no se especifican y pueden ser un diferenciador para el sistema. Además de que al existir instancias sin etiquetar el sistema podría dar grupos para ser evaluados.

Y ahora, ¿Qué algoritmo de aprendizaje no supervisado es más conveniente? Para descubrir aquello, se observan algoritmos de aprendizaje no supervisado que podrían ser candidatos óptimos para el desarrollo de un sistema como el que se ha mencionado a lo largo de este artículo.

K-medias. El algoritmo K-medias es muy utilizado puesto que es extremadamente sencillo de implementar y eficaz computacionalmente hablando, contra otros algoritmos de agrupamiento. Este algoritmo tiene la meta de particionar un conjunto de n -observaciones en k grupos, en el que cada observación pertenece al grupo con valor medio más cercano.

Debido a la forma tan rápida y variada que maneja este algoritmo, es utilizado para la agrupación de documentos [20], optimización de clústeres basados en imágenes [21], análisis de conglomerados [22], además de diversas aplicaciones que van desde reconocimiento en el área educativa, hasta el ámbito empresarial para grupos segmentados [23–29].

Tabla 1. Comparación de cuál algoritmo tiene un mejor potencial para ser elegido clasificador para el sistema detector de intenciones de robo.

Algoritmo	Definición	¿Óptimo?, ¿Por qué?
Aprendizaje supervisado	Son técnicas para deducir una función a partir de datos de entrenamiento. Los datos de entrenamiento se componen de pares de objetos (generalmente vectores): un componente del par son los datos de entrada y el otro, los resultados deseados.	No, ya que no se conoce con certeza los valores y grupos deseados.
K-medias	Este algoritmo tiene el objetivo de dividir un conjunto de n observaciones en k grupos en los que cada observación pertenece al grupo con el valor medio más cercano.	Sé podría utilizar, pero, aunque es sencillo de implementar no reconoce el ruido y esto podría ocasionar fallas si no se controlan los datos.
Clustering jerárquico	Los algoritmos de agrupación jerárquica se basan en la creación de una jerarquía de agrupaciones donde cada nodo es una agrupación, que consta de agrupaciones de sus nodos secundarios.	No, puede ser un problema muy grande si aumentamos la cantidad de datos aumentando demasiado la complejidad.
DBSCAN	Este algoritmo puede encontrar cualquier forma de agrupación arbitraria sin verse afectado por el ruido. Además de eso, puedes encontrar la parte más densa de las muestras mediante centroides, dejando de lado las partes menos conocidas o ruidosas.	Sí, ya que se necesita crear k-grupos y eliminar posibles ruidos, dada la complejidad de los datos.

Clustering Jerárquico. Este algoritmo, al pertenecer al concepto de aprendizaje no supervisado sigue estando sin etiquetar previamente y solo se cuenta con variables que no son dependientes (características). A partir de esto, los algoritmos de clústeres jerárquicos se basan en la creación de una jerarquía de clústeres donde cada nodo es un clúster, que consta de clústeres de sus nodos hijos.

Como ventajas tiene que a diferencia de K-medias, en este no es necesario definir el número de clústeres que se van a formar; esto debido a que el algoritmo puede obtener el número de clústeres directamente. Además, se puede observar que es fácil de implementar y el denograma es muy útil para la interpretación de los datos.

También existen desventajas como que no es apropiado para conjuntos de datos muy grandes debido a que la complejidad aumenta y podría ser muy costoso computacionalmente hablando, y podemos agregar que podría ser difícil determinar el número correcto de clústeres por medio de un denograma.

Este algoritmo se utiliza para el procesamiento paralelo en memorias de computadora [30], segmentar información en datos de manera coherente y análisis de datos [31–33], mejorar la eficiencia de grupos de datos para su correspondiente análisis [34], sistemas de búsqueda [35] y análisis de valores atípicos [36].

DBSCAN. El algoritmo de K-medias es un método para agrupar datos de una forma no supervisada, pero ¿Qué pasa cuando se cuenta con clústeres de forma arbitraria, o

clústeres dentro de clústeres? Esta técnica y otras tradicionales podrían no compartir suficiente similitud de sus elementos en el mismo clúster, o no pertenecer a ninguno. En problemas donde fallan algoritmos como k-medias por los factores ya mencionados, se puede utilizar el agrupamiento espacial basado en densidad de aplicaciones con ruido (DBSCAN), debido a que este algoritmo puede encontrar cualquier forma arbitraria de clúster sin verse afectado por el ruido.

Además de que puede encontrar la parte más densa de las muestras por medio de centroides, haciendo a un lado partes menos densas o ruidosas. La noción de densidad puede verse como: el número de puntos dentro de un radio específico. Este algoritmo tiene múltiples aplicaciones, debido a que también puede detectar muestras que no pertenecen a ningún clúster y son solamente ruido, como en aplicaciones de estabilización en el campo de visión artificial [37], métodos de agrupación más novedosos [38–40], análisis de volúmenes grandes de datos [41], resoluciones complejas [42], entre muchas otras para análisis complejos de clustering.

Después de analizar estos algoritmos se llega a la conclusión que se muestra en la tabla 1.

4. Propuesta y avances

Con base al análisis anterior, se llegó a la conclusión de que uno de los patrones a analizar, que más predomina en un ladrón en tiempo real, son sus emociones, que pueden ser analizadas por un computador, esto con base a estudios psicológicos y criminalísticos antes mencionados. Además, se detectó que un aparato muy famoso en la actualidad son las cámaras de seguridad que cada vez son más usadas por negocios y casa habitación, las cuales se plantean como un método no invasivo y nos ayudan a un reconocimiento de emociones con base a las micro expresiones faciales, en este caso se basa en las siete emociones universales que de igual manera se menciona anteriormente.

Para recopilar los patrones se utiliza el reconocimiento facial de emociones que, para este sistema, se desarrolla con apoyo de la biblioteca gratuita de código abierto para el procesamiento de imágenes en tiempo real la cual es OpenCV2, la biblioteca de aprendizaje automático llamada Tensorflow y el lenguaje de programación Python, En la fig. 1. se pueden observar algunas imágenes cuando está trabajando el algoritmo.

Ahora bien, esos patrones actualmente se están recogiendo de videos de sujetos cometiendo algún robo, los cuales se analizan antes y durante dicha acción, y se calcula el porcentaje de tiempo de cada emoción principal (enojado, disgustado, temeroso, feliz, neutral, triste y sorprendido) durante cada video.

Por ejemplo: si durante un video donde el total de veces del conjunto de todas las emociones analizadas da un total de 100 y en ese mismo video se obtiene que 72 veces se encontró que el sujeto estuvo temeroso, entonces se calcula el promedio que tuvo esa emoción contra el total de todas que fue 100, y se obtiene el valor de 0.72 que este proceso se repite hasta hacerlo con cada emoción, para almacenar estas características en un CSV (delimitado por comas). En la Fig. 2. Se pueden observar algunos datos que ha encontrado al analizar las emociones con base al rostro de individuos al cometer un robo.




Fig. 1. Reconocimiento de emociones con base en micro expresiones faciales en tiempo real, al momento de recopilar características de una persona robando.

Dentro de la fig. 2. haciendo su correspondiente análisis, se observa que; las personas al momento de llevar a cabo un robo presentan un miedo, en la mayoría de los casos con un concreto toque de satisfacción (por alguna razón que podría ser al obtener lo que ellos querían), y en algunos otros casos miedo con vergüenza. En casos muy concretos toques de enojo y estado neutral.

Además, se observa que la emoción que menos predomina es el disgusto. Actualmente se cuenta con 100 datos que ya han sido analizados por expertos en el campo de la psicología para comparar los resultados obtenidos en cada video contra lo que ellos piensan que pasa emocionalmente por la mente del ladrón.

Pero para pasarlos por el clasificador DBSCAN (el cual por el análisis mostrado en la sección 4 se propone utilizar) y compararlo contra otros clasificadores, se necesitan más datos para lograr un desempeño notable a ser evaluado, por eso actualmente se siguen recopilando datos.

Y, ahora bien, teniendo un conjunto de datos más grande y analizándolo con el algoritmo DBSCAN, se podrían observar los clústeres que este formaría, para ser analizados dentro del campo de la psicología criminalística. Además, como principalmente se pensó, el poder hacer que un computador prediga con cierta exactitud si una persona tiene intenciones de robar en tiempo real o por un video ya grabado.

5. Conclusiones y trabajo a futuro

La creación de un sistema capaz de predecir si un individuo tiene intenciones de cometer un robo es una tarea difícil, por lo que un análisis como el que se realiza en este artículo es importante para tener resultados óptimos. Se observa que, con esta metodología planteada se tendría un medio no invasivo como lo es el reconocimiento facial de emociones a través de secuencias de imágenes que, pueden ser obtenidas

	0	1	2	3	4	5	6
0	4.178273	0.000000	72.144847	13.927577	3.899721	4.735376	1.114206
1	8.391608	0.000000	35.664336	27.272727	15.384615	11.188811	2.097902
2	1.650165	0.000000	39.273927	39.603960	9.240924	6.930693	3.300330
3	0.488998	0.000000	42.909535	30.562347	19.804401	5.990220	0.244499
4	2.685950	0.000000	45.247934	13.016529	8.884298	29.958678	0.206612
5	0.000000	0.000000	95.597484	0.000000	3.773585	0.000000	0.628931
6	14.000000	0.000000	30.000000	30.000000	12.000000	12.000000	2.000000
7	0.000000	0.000000	27.702703	6.756757	38.851351	26.689189	0.000000
8	0.387597	0.000000	39.631783	3.294574	35.658915	12.209302	8.817829
9	5.042017	0.420168	49.159664	26.890756	3.781513	3.781513	10.924370
10	1.657459	0.000000	59.668508	11.602210	7.734807	3.314917	16.022099
11	1.255230	0.000000	35.564854	43.096234	2.510460	7.112971	10.460251
12	9.691630	0.000000	61.674009	24.229075	2.202643	0.881057	1.321586
13	0.000000	0.000000	41.176471	12.745098	14.705882	31.372549	0.000000
14	2.064897	0.000000	44.100295	7.227139	6.342183	11.061947	29.203540
15	3.482587	0.000000	22.885572	6.965174	27.860697	38.805970	0.000000
16	2.040816	0.000000	33.163265	26.275510	11.734694	18.622449	8.163265
17	3.500000	0.000000	47.750000	2.750000	4.500000	41.000000	0.500000
18	4.697500	0.000000	53.125000	26.562500	9.375000	6.250000	0.000000
19	0.543478	0.000000	57.608696	5.978261	22.826087	10.869565	2.173913
20	0.000000	0.000000	45.531915	31.489362	5.957447	16.170213	0.851064
21	4.545455	0.000000	59.090909	9.090909	13.636364	13.636364	0.000000
22	3.896104	0.000000	42.424242	30.303030	6.493506	13.852814	3.030303
23	0.608519	0.000000	58.215010	22.312373	6.085193	11.561866	1.217039
24	4.564315	0.000000	39.834025	47.302905	3.319502	4.149378	0.829876
25	0.000000	0.000000	33.450704	54.577465	11.619718	0.352113	0.000000
26	0.943396	0.000000	28.301887	35.849057	23.584906	9.433962	1.886792
27	1.282051	0.000000	28.205128	57.692308	3.846154	6.410256	2.564103
28	0.865266	0.000000	24.351051	32.385661	27.194067	13.597033	1.606922
29	0.788955	0.000000	82.840237	11.045365	3.550296	1.183432	0.591716
30	0.000000	0.000000	45.302013	26.174497	16.442953	11.409396	0.671141
31	0.000000	0.000000	30.000000	23.636364	12.727273	32.727273	0.909091

Fig. 2. Muestra de datos obtenidos con base al análisis de emociones por medio de la detección de micro expresiones faciales, donde la columna 0 es enojado, la 1 es disgustado, la 2 es temeroso, la 3 es feliz, la 4 es neutral, la 5 es triste y la 6 es sorprendido.

fácilmente en cámaras de seguridad o cualquier otra, con una resolución aceptable para reconocer estos patrones en un intervalo de tiempo que deberá ser probado, el cuál como resultado detectaría un acto delictivo como el robo.

Además, se puede concluir que, el buen análisis de un algoritmo de clasificación eficiente para la detección de intenciones de robo en personas, el cual por medio del estudio mostrado en este artículo es DBSCAN, en combinación a un conjunto de datos de entrenamiento apropiado, puede presentar resultados interesantes en el campo de la criminología y la psicología para un estudio correspondiente.

Finalmente, el análisis para encontrar una metodología adecuada para la creación de un sistema para la predicción de intenciones de robo en personas ha servido para realizar un sistema de estas capacidades, el cual ya está en fase de desarrollo. Y también se espera que este artículo puede servir de inspiración para que más gente involucrada en el ámbito científico y tecnológico se involucre en este tema, que es importante para el campo de la seguridad para cada individuo y/o institución.

Agradecimientos. Se le agradece al Consejo Nacional de Ciencia y Tecnología (CONACyT) y al Tecnológico Nacional de México Campus Apizaco, por el apoyo brindado para la realización de esta investigación.

Referencias

1. Cook, P. J.: Robbery violence. The journal of criminal law and criminal, vol. 78, no. 2, pp. 357–376 (1987) doi:10.2307/1143453
2. Alvarez, V. M., Velazquez, R., Gutierrez, S., Enriquez-Zarate, J.: A method for facial emotion recognition based on interest points. International Conference on Research in

- Intelligent and Computing in Engineering RICE, pp. 1–4 (2018) doi:10.1109/RICE.2018.8509055
3. Ahmad, M. A., Teredesai, A., Eckert, C.: Interpretable machine learning in healthcare. 2018 IEEE International Conference on Healthcare Informatics (ICHI), pp. 447–447 (2018) doi:10.1109/ICHI.2018.00095
 4. Shih, C. H., Liu, Yen, C. S., Lee, C. H., Liao, J. H., Jeng, B. S.: A fast shrinking suspicious criminal system from the voice. In: Proceedings IEEE 32nd Annual 1998 International Carnahan Conference on Security Technology, pp. 158–162 (1998) doi:10.1109/CCST.1998.723782
 5. Sathyadevan, S., Devan, M. S., Surya Gangadharan, S.: Crime analysis and prediction using data mining. In: First International Conference on Networks & Soft Computing ICNSC'14, pp. 406–412 (2014) doi:10.1109/CNSC.2014.6906719
 6. Isah, H., Neagu, D., Trundle, P.: Bipartite network model for inferring hidden ties in crime data. In: Proceedings of the 2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining, ASONAM '15, pp. 994–1001 (2015) doi:10.1145/2808797.2808842
 7. Babakura, A., Sulaiman, M. N., Yusuf, M. A.: Improved method of classification algorithms for crime prediction. In: Proceedings of 2014 International Symposium on Biometrics Security Technologies, ISBAST, pp. 250–255 (2015) doi:10.1109/ISBAST.2014.7013130
 8. Mahmud, N., Zinnah, K. I., Rahman, Y. A., Ahmed, N.: CRIMECAST: A crime prediction and strategy direction service. In: 19th International Conference on Computer and Information Technology (ICCIT), pp. 414–418 (2017) doi:10.1109/ICCITECHN.2017.7860234
 9. Su, Y., Lu, H., Zhang, H.: Qualitative mapping modeling of criminals' sense of security in theft cases. In: Proceedings of IEEE International Conference Big Data, pp. 4337–4341 (2019) doi:10.1109/BigData47090.2019.9005471
 10. Fox, B. H., Jennings, W. G., Farrington, D. P.: Bringing psychopathy into developmental and life-course criminology theories and research. *Journal of Criminal Justice*, vol. 43, no. 4, pp. 274–289 (2015) doi: 10.1016/j.jcrimjus.2015.06.003
 11. Ko, K. E., Sim, K. B.: Development of a facial emotion recognition method based on combining AAM with DBN. *International Conference on Cyberworlds*, pp. 87–91 (2010) doi:10.1109/CW.2010.65
 12. Shojaeilangari, S., Yau, W. Y., Nandakumar, K., Li, J., Teoh, E. K.: Robust representation and recognition of facial emotions using extreme sparse learning. *IEEE Transactions on Image Processing*, vol. 24, no. 7, pp. 2140–2152 (2015) doi:10.1109/TIP.2015.2416634
 13. Abanoz, H., Çataltepe, Z.: Emotion recognition on static images using deep transfer learning and ensembling. *26th Signal Processing and Communications Applications Conference*, pp. 1–4 (2018) doi: 10.1109/SIU.2018.8404346
 14. Zhang, L., Zhang, B.: Non-invasive multi-disease classification via facial image analysis using a convolutional neural network. *International Conference on Wavelet Analysis and Pattern Recognition ICWAPR'18*, pp. 66–71 (2018) doi:10.1109/ICWAPR.2018.8521262
 15. Ricardo, D., Salazar, C., Lanzarini, L.: Aplicación de detección de objetos y algoritmo de Viola Jones para el desarrollo de una base de datos en pacientes de Alzheimer. In: *14th Iberian Conference on Information Systems and Technologies CISTI*, pp. 19–22 (2019)
 16. Sergeeva, A. D., Savin, A. V., Sablina, V. A., Melnik, O. V.: Emotion recognition from micro-expressions: Search for the face and eyes. In: *8th Mediterranean Conference on Embedded Computing MECO'19*, pp. 1–4 (2019) doi:10.1109/MECO.2019.8760029
 17. Ray, S.: A Quick review of machine learning algorithms. *International Conference on Machine Learning, Big Data, Cloud and Parallel Computing COMITCon'19*, pp. 35–39 (2019) doi:10.1109/COMITCon.2019.8862451
 18. Fidler Dennis, J., Arnroth, L.: Supervised learning techniques. vol. 18, pp. 1164–1184 (2015)

19. Dalal, K. R.: Analysing the role of supervised and unsupervised machine learning in IoT. International Conference on Electronics and Sustainable Communication Systems ICESC'20, pp. 75–79 (2020) doi:10.1109/ICESC48915.2020.9155761
20. Singh, V. K., Tiwari, N., Garg, S.: Document clustering using K-means, heuristic K-means and fuzzy C-means. In: Proceedings of International Conference on Computational Intelligence and Communication, pp. 297–301 (2011) doi:10.1109/CICN.2011.62
21. Chen, X., Miao, P., Bu, Q.: Image segmentation algorithm based on particle swarm optimization with K-means optimization. In: Proceedings of IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS), pp. 156–159 (2019) doi:10.1109/ICPICS47731.2019.8942442
22. Hacker, T.: Cluster analysis for the cloud parallel competitive fitness and parallel K-means for large dataset analysis. In: 4th IEEE International Conference on Cloud Computing Technology and Science Proceedings, pp. 177–184 (2012) doi: 10.1109/CloudCom.2012.6427553
23. Shah, S., Singh, M.: Comparison of a time efficient modified K-mean algorithm with K-mean and K-medoid algorithm. In: 2012 International Conference on Communication Systems and Network Technologies, pp. 435–437 (2012) doi:10.1109/CSNT.2012.100
24. Lan, X., Li, Q., Zheng, Y.: Density K-means: A new algorithm for centers initialization for K-means. In: Proceedings of 6th IEEE International Conference on Software Engineering and Service Science (ICSESS), pp. 958–961 (2015) doi:10.1109/ICSESS.2015.7339213
25. Wang, X., Jiao, Y., Fei, S.: Estimation of clusters number and initial centers of K-means algorithm using watershed method. In: 14th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES), pp. 505–508 (2016) doi:10.1109/DCABES.2015.132
26. Qi, J., Yu, Y., Wang, L., Liu, J.: K-means: An effective and efficient k-means clustering algorithm. In: Proceedings of IEEE International Conferences on Big Data and Cloud Computing (BDCloud), Social Computing and Networking (SocialCom), Sustainable Computing and Communications, pp. 242–249 (2016) doi:10.1109/BDCLOUD-SocialCom-SustainCom.2016.46
27. Shi, G., Gao, B., Zhang, L.: The optimized K-means algorithms for improving randomly-initialed midpoints. In: Proceedings of 2nd International Conference on Measurement, Information and Control, vol. 2, pp. 1212–1216 (2013) doi:10.1109/MIC.2013.6758177
28. Saboori, E., Parsazad, S.: Improving the K-means algorithm using improved downhill simplex search. In: Proceedings of 2nd International Conference on Software Technology and Engineering, vol. 2, pp. V2-350–V32-354 (2010) doi:10.1109/ICSTE.2010.5608792
29. Sebayang, F. A., Lydia, M. S., Nasution, B. B.: Optimization on purity K-means using variant distance measure. In: Proceedings of 3rd International Conference on Mechanical, Electronics, Computer, and Industrial Technology (MECnIT), pp. 143–147 (2020) doi:10.1109/MECnIT48290.2020.9166600
30. Shimizu, T., Sakurai, K.: Comprehensive data tree by actor messaging for incremental hierarchical clustering. In: 42nd Annual Computer Software and Applications Conference (COMPSAC), vol. 1, pp. 801–802 (2018) doi:10.1109/COMPSAC.2018.00127
31. Pradip, K. G., Patil, D. R.: Summarization of sentences using fuzzy and hierarchical clustering approach. Symposium on Colossal Data Analysis and Networking (CDAN), pp. 1–7 (2016) doi:10.1109/CDAN.2016.7570964
32. Rong, Y., Liu, Y.: Staged text clustering algorithm based on K-means and hierarchical agglomeration clustering. In: Proceedings of IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA), pp. 124–127 (2020) doi:10.1109/ICAICA50127.2020.9182394
33. Park, S., Park, Y. B.: Photovoltaic power data analysis using hierarchical clustering. In: International Conference on Information Networking (ICOIN), pp. 727–731 (2018) doi:10.1109/ICOIN.2018.8343214

34. Chen, T. S., Tsai, T. H., Chen, Y. T., Lin, C. C., Chen, R. C., Li, S. Y., Chen, H. Y.: A combined K-means and hierarchical clustering method for improving the clustering efficiency of microarray. In: International Symposium on Intelligent Signal Processing and Communication Systems, pp. 405–408 (2005) doi:10.1109/ispacs.2005.1595432
35. Zhang, Y., Feng, B.: A co-occurrence based hierarchical method for clustering web search results. In: Proceedings of IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology, pp. 407–410 (2008) doi:10.1109/WIIAT.2008.35
36. Rahman, M. A., Rahman, M. M., Ul-Husna, A., Haque-Mollah, M. N.: Robust hierarchical clustering for metabolomics data analysis in presence of cell-wise and case-wise outliers. In: Proceedings of International Conference on Computer, Communication, Chemical, Material and Electronic Engineering (IC4ME2), pp. 1–4 (2018) doi:10.1109/IC4ME2.2018.8465616
37. Yu, H., Zhang, W.: Stabilizing System. pp. 1297–1301 (2013)
38. Zhu, Q., Tang, X., Liu, Z.: Revised DBSCAN clustering algorithm based on dual grid. Chinese Control And Decision Conference (CCDC), pp. 3461–3466 (2020) doi:10.1109/CCDC49329.2020.9163926
39. Chen, M., Gao, X. D., Li, H. F.: Parallel DBSCAN with priority R-tree. In: Proceedings of International Conference on Information Management and Engineering, no. 3, pp. 508–511 (2010) doi:10.1109/ICIME.2010.5477926
40. Smiti, A., Elouedi, Z.: DBSCAN-GM An improved clustering method based on Gaussian means and DBSCAN techniques. In: IEEE 16th International Conference on Intelligent Engineering Systems (INES), pp. 573–578 (2012) doi:10.1109/INES.2012.6249802
41. Ohadi, N., Kamandi, A., Shabankhah, M., Fatemi, S. M., Hosseini, S. M., Mahmoudi, A.: SW-DBSCAN: A grid-based DBSCAN algorithm for large datasets. In: 6th International Conference on Web Research (ICWR), pp. 139–145 (2020) doi:10.1109/ICWR49608.2020.9122313
42. Çelik, M., Dadaşer-Çelik, F., Dokuz, A. Ş.: Anomaly detection in temperature data using DBSCAN algorithm. In: International Symposium on Innovations in Intelligent Systems and Applications, pp. 91–95 (2011) doi:10.1109/INISTA.2011.5946052