



ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ciencias Naturales y Matemáticas

Detección de movimiento en videos de cámara de vigilancia con
fondo fijo usando técnicas estadísticas robustas

PROYECTO INTEGRADOR

Previo la obtención del Título de:

INGENIERO EN ESTADÍSTICA

Presentado por:

Kevin Ricardo Quintero León

Martha Julissa Tomalá Méndez

GUAYAQUIL - ECUADOR

Año: 2022

DEDICATORIA

El presente proyecto de grado lo dedico principalmente a Dios por ser el proveedor de sabiduría y fuerzas para culminar este proceso de obtener uno de los anhelos más deseados por los estudiantes universitarios, el título de grado. Y a mis padres por su amor, trabajo y sacrificio en todos estos años.

Kevin Ricardo Quintero León

DEDICATORIA

A Dios, quien me da la sabiduría, vida y fortaleza para culminar esta importante etapa en mi vida. A mis padres por confiar en mí y a pesar de sus adversidades apoyarme siempre.

Martha Tomalá Méndez

AGRADECIMIENTOS

Expreso mi gratitud a Dios, quien siempre a colmando de bendición y sabiduría mi vida y la de mi familia.

Mi profundo agradecimiento a mis padres, Fernando Torres y Nelly León, porque también han sufrido conmigo durante todos estos años en los cuales he dado todo de mí para llegar a la recta final, su amor y apoyo incondicional me han ayudado para culminar con éxito esta hermosa etapa. A mi hermana Fiorella Torres por darme motivos para ser alguien mejor como hermano mayor.

A la amada institución, ESPOL, por su excelente formación académica, la cual fue muy dura pero necesaria para llegar a la meta. A todos los profesores con los que he cursado en sus materias, cada uno me ha dejado una enseñanza distinta e importante, a mi tutor de tesis por contagiar su entusiasmo, brindarnos su apoyo y conocimiento en este proyecto de investigación.

Finalmente, agradecer a mi pareja por ayudar a levantarme cuando he querido tirar la toalla, a mi compañera de tesis por su tenacidad y esfuerzo en este proyecto, a mis colegas y amigos de la carrera por siempre entusiasarme con la idea de graduarnos junto y llegar a la luna. *Be strong.*

Kevin Ricardo Quintero León

AGRADECIMIENTOS

A Dios, por nunca dejarme sola en cada adversidad y reto Josué 1:9, darme la sabiduría necesaria para cumplir esta etapa y por ayudarme a no darme por vencida.

A mis padres Martha y Oswaldo por apoyarme en cada instante de la carrera y confiar a ojos cerrados en mí. A mi hermana Inés María por estar ahí cuando más la necesitaba.

A mi querida ESPOL, por brindarme una buena formación académica, a mi tutor PhD. Holger Cevallos por su contribución en este proyecto así también por sus enseñanzas que fueron importantes para la elaboración del presente trabajo.

A mi compañero de proyecto integrador, gracias por la paciencia y entrega en este proyecto. Sin ti esto no hubiese sido posible.

A mis amigos de la carrera Kevin, Samantha y Ricardo gracias por estar ahí haciendo más amena y menos compleja esta etapa, al fin llegamos a la luna.

Martha Tomalá Méndez

DECLARACIÓN EXPRESA

“Los derechos de titularidad y explotación, me corresponde conforme al reglamento de propiedad intelectual de la institución; Yo, Kevin Ricardo Quintero León doy mi consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”



Firmado electrónicamente por:
**KEVIN RICARDO
QUINTERO LEON**

Kevin Ricardo Quintero León

DECLARACIÓN EXPRESA

“Los derechos de titularidad y explotación, me corresponde conforme al reglamento de propiedad intelectual de la institución; Yo, Martha Julissa Tomalá Méndez doy mi consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”



Firmado electrónicamente por:
**MARTHA JULISSA
TOMALA MENDEZ**

Martha Julissa Tomalá Méndez

EVALUADORES



Firmado electrónicamente por:
**SANDRA LORENA
GARCIA BUSTOS**

Ph.D. Sandra García Bustos
PROFESOR DE LA MATERIA



Firmado electrónicamente por:
**HOLGER GEOVANNY
CEVALLOS
VALDIVIEZO**

Ph.D. Holger Cevallos Valdiviezo
PROFESOR TUTOR

RESUMEN

Ecuador en los últimos años ha pasado por un índice de robos y violencia en aumento. Lo que ha provocado que las personas no se sientan seguras en el país y no tengan una buena calidad de vida. Por lo cual es necesario crear nuevas herramientas que ayuden a cerrar la brecha de inseguridad del país. Este proyecto creó una implementación que es capaz de detectar intrusos a través de técnicas estadísticas robustas, sin necesidad de sensores de movimiento, solo usando los píxeles por segundo que tiene cada imagen que compone el video de seguridad. Utilizando el lenguaje de programación R y Python se estudió 4 videos de seguridad reales del Ecuador donde se aplicó el método de aplanamiento dimensional para el procesamiento de imágenes mediante escala RGB y de grises. Para el estudio de los datos se usó un método no supervisado de reducción de dimensionalidad, la técnica de análisis de componentes principales robusta ROBPCA de Hubert debido a su bajo coste computacional. En los hallazgos de este estudio se encontró mediante una tabla de confusión que la precisión de la implementación en todos los videos estudiados supera el 80%, también se realizaron varias pruebas de hipótesis comparando la proporción de verdaderos positivos y negativos de ambas escalas, de lo cual se obtuvo un valor p mayor a 0,05 en todos los casos, con esto se concluye que la implementación tiene una buena precisión detectando movimiento independientemente de la escala. Una consideración importante de este proyecto es que los tiempos de detección utilizando la implementación mediante escala RGB difiere el doble que utilizando escala de grises.

Palabras claves: Intrusos, técnicas robustas, análisis de componentes principales, cámaras de video vigilancia, aplanamiento, escala RGB, escala de grises.

ABSTRACT

In recent years, Ecuador has experienced an increasing rate of robberies and violence. This has caused that people do not feel safe in the country and do not have a good quality of life. Therefore, it is necessary to create new tools to help close the gap of insecurity in the country. This project created an implementation that can detect intruders through robust statistical techniques, without the need for motion sensors, just using the pixels per second that has each image that makes up the security video. Using the R programming language and Python, 4 real security videos from Ecuador were studied where the dimensional flattening method was applied for image processing using RGB and grayscale. An unsupervised dimensionality reduction method, Hubert's ROBPCA robust principal component analysis technique, was used to study the data due to its low computational cost. In the findings of this study, it was found through a confusion table that the accuracy of the implementation in all the videos studied exceeds 80%, also several hypothesis tests were performed comparing the proportion of true positives and negatives of both scales, from which a p-value greater than 0.05 was obtained in all cases, with this it is concluded that the implementation has a good accuracy detecting motion regardless of the scale. An important consideration of this project is that the detection times using the implementation using RGB scale differs twice as much as using grayscale.

Keywords: Intruders, robust techniques, principal component analysis, video surveillance cameras, flattening, RGB scale, grayscale.

ÍNDICE GENERAL

RESUMEN	9
ABSTRACT	10
ABREVIATURAS	14
SIMBOLOGÍA	15
ÍNDICES DE FIGURAS	16
ÍNDICE DE TABLAS	19
CAPÍTULO 1	20
1. Introducción	20
1.1 Descripción del problema	21
1.2 Objetivos	22
1.2.1 Objetivo General	22
1.2.2 Objetivos Específicos	22
1.3 Marco Teórico	22
1.3.1 Técnica de aplanamiento	22
1.3.2 Métodos Robustos	22
1.3.3 Componentes Principales (Robustos)	23
1.3.4 Detección de datos atípicos	24
1.3.5 Criterio de selección de las componentes principales por Hubert (2005)	26
1.3.6 Estado del Arte	26
CAPÍTULO 2	28
2. METODOLOGÍA	28
2.1 Digitalización de imágenes	28
2.1.1 RGB	28
2.1.2 Escala de grises	29
2.2 Aplanamiento	29
2.3 Análisis de componentes principales robustas	30

2.3.1	ROBPCA	31
2.4	Detección de observaciones atípicas	31
2.4.1	Cálculo de puntos de corte.....	31
2.4.2	Mapa de valores atípicos	32
2.5	Implementación.....	32
CAPÍTULO 3		34
3.	Resultados	34
3.1	Análisis del video de seguridad patio de empresa	36
3.1.1	Análisis del video de seguridad del patio principal de la empresa mediante la técnica de escala RGB	36
3.1.2	Análisis del video de seguridad del patio principal de la empresa mediante la técnica de escala de grises	39
3.1.3	Prueba de hipótesis diferencia de proporciones de las técnicas del aplanamiento para el video de patio de empresa	42
3.2	Análisis del video de la garita de la empresa	43
3.2.1	Análisis video de seguridad de la garita de la empresa con la técnica de escala RGB	43
3.2.2	Análisis video de seguridad de la garita de la empresa con la técnica de escala de grises	45
3.2.3	Prueba de hipótesis diferencia de proporciones de las técnicas del aplanamiento para el video de garita	49
3.3	Análisis video de seguridad del segundo patio de la empresa	50
3.3.1	Análisis video de seguridad del segundo patio de la empresa con la técnica de escala RGB	50
3.3.2	Análisis video de seguridad del segundo patio de la empresa con la técnica de escala de grises	53
3.3.3	Prueba de hipótesis diferencia de proporciones de las técnicas del aplanamiento para el video del segundo patio de empresa.....	56
3.4	Análisis video de seguridad del portal de una casa.....	57

3.4.1	Análisis del video del portal de una casa con la técnica de escala RGB..	57
3.4.2	Análisis video casa con la técnica de la escala de grises	60
3.4.3	Prueba de hipótesis diferencia de proporciones de las técnicas del aplanamiento para el video de la casa	63
3.4.4	Dashboard de visualización	63
CAPÍTULO 4		66
4.	Conclusiones y recomendaciones.....	66
4.1	Conclusiones	66
4.2	Recomendaciones	67
5.	Referencias	68

ABREVIATURAS

ACP	Análisis de componentes principales
MDI	Ministerio del interior
LDA	Linear discriminant analysis (Análisis de discriminante lineal)
LTS	Least Trimmed Squares (Mínimos cuadrados recortados)
MCD	Minimum covariance determinant (Determinante de covarianza mínima)
RGB	Red, green, blue (Rojo, verde y azul)
CYM	Cyan, yellow, magenta (Cian, amarillo, magenta)
1-D	Una dimensión

SIMBOLOGÍA

p	Número de variables de la matriz de datos
q	Número de imágenes
k	Número de componentes principales
S_0	Matriz de varianzas y covarianzas inicial
l_i	Vector propio correspondiente al i -ésimo valor propio
P_{pq}	Matriz de vectores propios de dimensión $p \times q$
$'u$	Matriz de centralidad robusta
T_{nk}	Matriz de puntuaciones de dimensión $n \times k$
SD_i	Matriz de distancias de puntuación
OD_i	Matriz de distancias ortogonales

ÍNDICES DE FIGURAS

Figura 1. Valores atípicos en un subespacio ACP	24
Figura 2. Modelo de color RGB y CYM	28
Figura 3. Tiempo en segundos por método empleado para procesar imágenes y por conjunto de datos estudiado.....	36
Figura 4. Mapa de outliers del video patio de la empresa con método de escala RGB con el método de escala RGB	36
Figura 5. Imágenes captadas por la implementación como atípicas en los videos de seguridad del patio de la empresa con la escala RGB	37
Figura 6. Gráfica de distancias de puntuación del video de seguridad del patio con el método de escala RGB	38
Figura 7. Gráfica de distancias ortogonales del video de seguridad del patio con el método de escala RGB	38
Figura 8. Mapa de outliers del video patio de la empresa con método de escala de grises	39
Figura 9. Imágenes captadas por la implementación como atípicas con el método de escala de grises	39
Figura 10. Gráfica de distancias de puntuación del video de seguridad del patio con el método de escala de grises.....	40
Figura 11. Gráfica de distancias ortogonales del video de seguridad del patio con el método de escala de grises.....	41
Figura 12. Mapa de outliers del video de garita de la empresa con método de escala RGB	43
Figura 13. Imágenes captadas por la implementación como atípicas con el método escala RGB	43
Figura 14. Gráfica de distancias de puntuación del video de seguridad de la garita con el método escala RGB	44

Figura 15. Gráfica de distancias ortogonales del video de seguridad de la garita con el método escala RGB	45
Figura 16. Mapa de outliers del video de garita de la empresa con método de escala de grises	45
Figura 17. Imágenes captadas por la implementación como atípicas con el método de escala de grises	47
Figura 18. Gráfica de distancias de puntuación del video de seguridad de la garita mediante escala de grises.....	47
Figura 19. Gráfico de distancias ortogonales del video de seguridad de la garita	48
Figura 20. Mapa de outliers del video del segundo patio de la empresa con método de escala RGB	50
Figura 21. Imágenes captadas por la implementación como atípicas por el método de escala RGB en el video de seguridad del segundo patio	51
Figura 22. Gráfica de distancias de puntuación del video de seguridad del segundo patio de la empresa por el método de escala RGB	52
Figura 23. Gráfica de distancias ortogonales del video de seguridad del segundo patio de la empresa mediante el método de escala RGB	52
Figura 24. Mapa de outliers del video del patio de la empresa mediante el método de escala de grises	53
Figura 25. Imágenes captadas por la implementación como atípicas con el método de escala de grises	54
Figura 26. Gráfica de distancias de puntuación del video de seguridad del segundo patio de la empresa mediante escala de grises	55
Figura 27. Gráfica de distancias ortogonales del video de seguridad del segundo patio de la empresa mediante escala de grises.....	55
Figura 28. Mapa de outliers del video de casa de la empresa mediante el método de la escala RGB	57
Figura 29. Imágenes captadas por la implementación como atípicas con el método de escala RGB	58

Figura 30.	Gráfica de distancias de puntuación del video de la casa mediante el método de escala RGB	59
Figura 31.	Gráfica de distancias ortogonales del video de la casa por el método de escala RGB	59
Figura 32.	Mapa de outliers del video de casa de la empresa con método de escala de grises	60
Figura 33.	Imágenes captadas por la implementación como atípicas con el método de escala de grises	61
Figura 34.	Gráfica de distancias de puntuación del video de la casa por el método de escala de grises	62
Figura 35.	Gráfica de distancias ortogonales del video de la casa por el método de escala de grises	62
Figura 36.	Primera toma del dashboard – gráfica generada por cada fotograma del video.	64
Figura 37.	Segunda toma del dashboard – gráfica generada por cada fotograma del video	64
Figura 38.	Tercera toma del dashboard – mensajes de alertas por incursión del intruso	64
Figura 39.	Cuarta toma del dashboard – alcance de la detección	65

ÍNDICE DE TABLAS

Tabla 1.	Detalle de las matrices de los videos de seguridad estudiados.....	30
Tabla 2.	Puntos de corte y cantidad de intrusos detectados por la implementación...	34
Tabla 3.	Tabla de confusión para el video de patio de empresa del método de escala RGB	37
Tabla 4.	Tabla de confusión video del patio de empresa.....	40
Tabla 5.	Prueba de hipótesis para comparar el método de aplanamiento por las dos técnicas (escala de grises y RGB).....	42
Tabla 6.	Tabla de confusión video de garita.....	45
Tabla 7.	Tabla de confusión video garita	48
Tabla 8.	Prueba de hipótesis para comparar el método de aplanamiento por las dos técnicas (escala de grises y RGB).....	49
Tabla 9.	Tabla de confusión segundo patio de empresa	51
Tabla 10.	Tabla de confusión video segundo patio de empresa	54
Tabla 11.	Prueba de hipótesis para comparar el método de aplanamiento por las dos técnicas (escala de grises y RGB).....	56
Tabla 12.	Tabla de confusión video del portal de una casa	58
Tabla 13.	Tabla de confusión video del portal de una casa	61
Tabla 14.	Prueba de hipótesis para comparar el método de aplanamiento por las dos técnicas (escala de grises y RGB).....	63

CAPÍTULO 1

1. INTRODUCCIÓN

La seguridad pública es una competencia única y propia de cualquier estado en el mundo, que comprende un sistema de acciones y medidas encaminadas al mantenimiento y restablecimiento del orden público, la protección interna y la libertad de ejercer los derechos para cualquier persona (MDI, 2019). Dada la naturaleza de los fenómenos (terrorismo, crimen organizado y violencia criminal) que pueden afectar o poner en peligro la seguridad ciudadana, corresponde al estado el diseño, implementación y evaluación de las políticas y programas públicos. Sin embargo, estos mismos fenómenos se han mantenido con el paso del tiempo evadiendo las políticas públicas por lo que ha sido necesario el uso de cámaras de vigilancia para resguardar la seguridad de cualquier entidad, manteniendo respaldo de cualquier suceso que atente contra el bienestar social. El dilema en esta solución infiere en que los sucesos son grabados y a decir verdad es posible tomar acciones pertinentes; sin embargo, surge la necesidad de poder recibir alertas cuando estos sucesos delictivos estén ocurriendo. Por ello es necesario desarrollar métodos que puedan detectar actividades inusuales consideradas sospechosas para un crimen y que las personas puedan ser alertadas.

Se han aplicado metodologías de análisis estadístico multivariante como la de reducción de dimensionalidad también conocida como análisis de componentes principales (ACP) en el escenario de aplicación enfocado a la comprensión de imágenes digitales en el espectro visible (Hena Giraldo, 2022). Algunos autores sugieren utilizar algoritmos menos complejos como es el caso del algoritmo de Viola-Jones el cual reconoce rostros y patrones de rostros de forma rápida a través de dos fases: la primera llamada clasificador en cascada y la segunda llamada entrenamiento de clasificadores basados en AdaBoost. Otros enfoques estadísticos como el análisis de discriminante lineal (LDA, por sus siglas en inglés) que se basa en encontrar relaciones lineales entre patrones o rostros de la base de conocimiento, que mejor discriminen el fotograma de prueba (Loza et al.).

Sin embargo, algunos autores sugieren los métodos robustos por sobre los métodos clásicos cuando se trata de detección de patrones en imágenes, y esto es porque al tratar variaciones dentro de un espectro visible cualquier valor por fuera de una medida

establecida puede ser considerado como valor atípico (Locantore et al., 1999). Por ello, consideran necesario utilizar PCA robusto de modo que el análisis no se vea afectado por valores atípicos, causados por imágenes de mosaicos que tienen algunas regiones faltantes. Los resultados encontrados en las estimaciones comprenden un punto de quiebre del 50%, lo que quiere decir que tiene una buena robustez global frente a valores atípicos.

A base de lo mencionado anteriormente, el presente proyecto ofrece la evaluación de una metodología robusta multivariante aplicada a variables transformadas provenientes de una matriz de diseño como resultado de la transición de video a información. Además, se propone la aplicación de un modelo de aprendizaje sin necesidad de técnicas con costos altamente computacionales o equipos altamente sofisticados para su implementación como el caso de redes neuronales para reconocimiento de imágenes (García García, 2013).

1.1 Descripción del problema

La seguridad ciudadana es un tema cada vez más relevante en Latinoamérica debido a que se ha convertido en un problema crítico (Ortega & Pino, 2021). En Ecuador desde 2021 se ha aumentado considerablemente la inseguridad. Según datos del Ministerio de Gobierno, el 2021 con respecto al 2020 terminó con un aumento de 27.9% asaltos a personas, 55% robos de vehículos, 30.4% robos de motos, 14.2% robos de domicilio y 17.3% asalto a locales comerciales. Y a pesar de estas cifras alarmantes hay pocas o nulas políticas públicas efectivas de parte del gobierno para contrastar esta problemática social que están viviendo los ecuatorianos. Este problema hace que la percepción de inseguridad de las personas sea alta, es decir, las personas diariamente tienen miedo de ser víctimas de crimen directa o indirectamente, lo cual afecta a su bienestar individual, salud mental, felicidad y calidad de vida (Manjarrés de Avile & Baca-Mejía, 2019; Tarazona & Ríos, 2021).

Por lo tanto, el presente trabajo pretende a partir de los resultados aportar en la reducción de la brecha de inseguridad de los hogares y locales comerciales. Usando un enfoque en técnicas robustas con componentes principales se desarrolla una implementación que es capaz de identificar sospechosos en tiempo real en videos de vigilancia. De esta manera, la herramienta podrá ser utilizada en estudios posteriores al

integrarla a un sistema de video vigilancia lo cual ayudará en el control y alerta de intrusos.

12 Objetivos

1.2.1 Objetivo General

Construir una técnica que identifique intrusos en videos de vigilancia de fondo fijo a través de técnicas robustas, para ayudar con los problemas de inseguridad del Ecuador.

1.2.2 Objetivos Específicos

- Desarrollar un modelo con ayuda de técnicas robustas que identifique en videos pixeles atípicos.
- Diseñar un dashboard con gráficos animados para mostrar las escenas atípicas.
- Evaluar el desempeño del modelo a través de videos con ruido para demostrar su efectividad.

13 Marco Teórico

1.3.1 Técnica de aplanamiento

La técnica del aplanamiento es una técnica que se utiliza para convertir matrices multidimensionales en matrices de una dimensión (1-D), que generalmente se usa en el aprendizaje profundo, mientras se alimenta información de matriz 1-D a los modelos de clasificación.

Los arreglos multidimensionales ocupan más memoria, mientras que los arreglos unidimensionales requieren menos memoria, que es la razón principal por la que aplanamos los arreglos de imágenes antes de procesar o alimentar la información al modelo. En la mayoría de los casos, trabajaremos con conjuntos de datos con una gran cantidad de imágenes, por lo que el aplanamiento ayuda a reducir la memoria y el tiempo para entrenar el modelo (Mukherjee, 2021).

1.3.2 Métodos Robustos

Los métodos robustos son técnicas que se crearon para reducir la influencia de valores atípicos dado que la mayoría de los métodos clásicos son altamente influenciados por estos. Así también, estos proveen herramientas para detectar y eliminar datos atípicos. Un valor atípico es una observación que está lejos de lo

que sugiere la mayoría de los datos. Es decir, cuando se desvía de más del 50% de las observaciones (Ghosh & Vogt).

1.3.3 Componentes Principales (Robustos)

Para poder reducir la dimensionalidad de los datos y tener una mejor representación de ellos se utiliza el método no supervisado de análisis de componentes principales (ACP) robusto dado que este no es sensible a observaciones atípicas porque no usa la pérdida cuadrática. Hay distintos enfoques para usar ACP robusto, el más intuitivo de ellos es emplear una matriz de dispersión robusta y calcular los vectores y valores propios (ver e.j. (Campbell, 1980; Croux & Haesbroeck, 2000; Devlin et al., 1981; Naga & Antille, 1990; Salibián-Barrera et al., 2006). Sin embargo, este método termina siendo costoso computacionalmente si se tiene una alta dimensionalidad. Así también hay otros métodos como Locantore et. al. (1999) que usa la matriz de esfera unitaria para calcular la matriz de covarianza. Maronna (2005) también propone un método para calcular la mejor aproximación de dimensión reducida al usar escala M o escala de mínimos cuadrados recortados LTS y Cevallos and Van Aelst (2019) proponen un algoritmo con ecuaciones estimativas que calcula las direcciones principales del subespacio de baja dimensión. Así también ROBPCA (Hubert et al., 2005) propone un método que mezcla el método de Stahel Donoho y el determinante de covarianza mínimo (MCD).

Dado el presente problema de alta dimensionalidad se utiliza el método de ROBPCA por su bajo costo computacional, el cual definimos a continuación.

El enfoque que toma el método ROBPCA tiende a ser más preciso dado que toma la combinación de dos métodos. Sea $X = (x_1 \dots x_n) \in \mathbb{R}^{n \times p}$ con p variables y n observaciones. El método consiste en tres pasos, el primero es transformar los datos a un subespacio que tiene como máximo una dimensión de $n - 1$, para luego construir una matriz de varianza y covarianza inicial S_0 y esta es usada para seleccionar el número de componentes principales k , lo cual produce un subespacio de dimensión k . Para luego estimar de manera robusta la matriz de dispersión y centralidad, con el cual a partir de los valores propios se calcula los vectores propios l_1, l_2, \dots, l_k .

Se escribe la matriz de vectores propios uno al lado del otro obtenemos la matriz con columnas ortogonales P_{pk} . La matriz de centralidad robusta de dimensión $p \times 1$ es denotada por \hat{u} . La matriz de puntuaciones de dimensión $n \times k$ es definida como t^2_{ij} .

Donde t^2_{ij} es definido como:

$$T_{nk} = (X_{np} - 1_n \hat{u}') P_{pk} \quad (1)$$

X_{np} : Es la matriz de datos

\hat{u} : Vector columna de medias transpuesto

P_{pk} : Matriz generada por k-vectores propios

Los k componentes principales robustos generan una matriz de dispersión que viene dada por:

$$S = P_{pk} L_{kk} P'_{pk} \quad (2)$$


Por lo cual, L_{kk} es la matriz diagonal de los valores propios l_1, \dots, l_k .

1.3.4 Detección de datos atípicos

En este estudio para la detección de valores atípicos usamos el método de ROBPCA (Hubert et al., 2005).

Otro propósito del ACP es poder detectar valores atípicos. Hay diferentes tipos de valores atípicos dentro del subespacio como se muestra a continuación.

Figura 1. Valores atípicos en un subespacio ACP



Nota: Hubert, M., Rousseeuw, P. J., & Karlien, V. B. (2005). ROBPCA: A New Approach to Robust Principal Components Analysis. *Technometrics*.

Aquí se puede distinguir tres tipos diferentes de valores atípicos, se tiene puntos de buen apalancamiento 1 y 4 que están lejos de las observaciones pero cerca del subespacio, así también hay observaciones atípicas ortogonales como 5 la cual tiene gran distancia ortogonal pero no es atípica si se mira su proyección, el tercer tipo son las observaciones de mal apalancamiento como 2 y 3 las cuales tienen una gran distancia ortogonal y su proyección al subespacio está alejada de las observaciones normales.

Para analizar si una observación es atípica Hubert (2005) propone calcular la distancia de puntuación robusta, la cual se define de la siguiente manera.

$$SD_i = \sqrt{\sum_{j=1}^k \frac{t_{ij}^2}{l_j}} \quad (3)$$

También se usa otro método llamado distancias ortogonales que calcula la diferencia entre la proyección y la observación original.

$$OD_i = \|x_i - PPKt'\| \quad (4)$$

Donde $i = 1, \dots, p$ y t' es fila i -ésima de T_{nk} .

1.3.5 Criterio de selección de las componentes principales por Hubert (2005)

El criterio para elección del número de componentes principales k por Hubert viene dado por la siguiente fórmula que depende de la matriz diagonal de los valores propios L_{kk} . Siendo $r = \text{rango}(S_0)$, S_0 es la matriz de covarianza inicial.

$$\frac{\sum_{j=1}^k \lambda_j}{\sum_{j=1}^r \lambda_j} \approx 90\% \quad (5)$$

O que $\frac{\lambda_j}{\lambda_1} \geq 10^{-3}$.

1.3.6 Estado del Arte

Se conoce como espectro visible al área de la luz visible que el ojo humano es capaz de percibir. De esta manera si se escoge una imagen y la desfragmentamos en sus distintos niveles de colores perceptibles al ojo humano se podría reconocer variables o parámetros vinculados al reconocimiento de los elementos que constituyen la imagen, sin embargo, en la mayoría de los casos resulta complejo identificar todos estos parámetros o patrones y ante esta necesidad Emanuel Henao (2021) sugiere el uso de análisis de componentes principales enfocado a la percepción de imágenes digitales en el espectro visible. De esta manera se resolvería el famoso problema de dimensionalidad en imágenes complejas.

Se conoce que el ser humano es capaz de percibir la realidad en una minúscula fracción del espectro electromagnético, similar sucede con las imágenes. Analizar verdaderamente las variables, factores o patrones dentro de una imagen resultaría un trabajo casi imposible aún más si las imágenes presentan perturbaciones que contaminan el análisis, la percepción acabaría alterada, por ello no solo basta con realizar un análisis de componentes principales (ACP) también es importante aplicar métodos robustos (Locantore et al., 1999), esto con el fin de que nuestro análisis no sea influenciado por valores atípicos o extremos, valores por fuera de los parámetros que se desea encontrar.

Un dato atípico es una observación que se encuentra alejada de la mayoría de los datos. Este suele tratarse como una observación más, se le asigna un peso o se modifica con otro valor que esté cercano a la mayoría de los datos, así también se puede eliminar de la muestra (Ghosh & Vogt). Sin embargo, cómo saber si un dato es atípico ha sido un tema investigado por mucho tiempo, Hansen (1983) propuso que un dato es considerado atípico si al eliminarlo la estimación del estadístico cambia 10 por ciento o más, así también se puede determinar si es atípico cuando la variable tiene una distribución conocida donde se conoce el valor atípico candidato y se calcula la probabilidad de que el valor más extremo esté en alguna de las colas. Si obtenemos un valor bajo entonces tenemos un valor atípico.

En la actualidad dada la cantidad masiva de información, hay problemas de alta dimensionalidad de los datos. Esto hace que haya más probabilidad de tener datos atípicos, por ende, es necesario utilizar técnicas robustas dado que las clásicas se verían afectadas por los atípicos. Por lo cual una buena forma de reducir la dimensionalidad de manera robusta es usar ACP Robusto, en la literatura encontramos varios métodos como ACP de Maronna (Maronna, 2005), ACP esférico (Fujiki & Akaho, 2007), ROBPCA (Hubert et al., 2005), (Cevallos-Valdiviezo & Van Aelst, 2019), entre otros.

Maronna (2005) propone un algoritmo de ACP que minimiza las escalas M o LTS y utiliza la descomposición que demostró de la matriz de varianza y covarianza en base a los vectores propios. Sin embargo, cuando la dimensionalidad es alta, el algoritmo es costoso computacionalmente (Cevallos-Valdiviezo & Van Aelst, 2019; Maronna, 2005).

Cevallos y Van Aelst (2019) proponen un algoritmo que parte de la idea de Maronna al minimizar la escala LTS o M , sin embargo, no hace el uso de vectores propios si no que utiliza el método que probaron de ecuaciones estimativas lo cual da una respuesta parecida a Maronna y en altas dimensiones el costo computacional es más bajo (Cevallos-Valdiviezo & Van Aelst, 2019).

Así también Hubert propone el método ROBPCA el cual combina la búsqueda de proyecciones y el MCD, donde la búsqueda de proyecciones se utiliza para reducir la dimensionalidad y el MCD se aplica al espacio reducido (Hubert et al., 2005).

CAPÍTULO 2

2. METODOLOGÍA

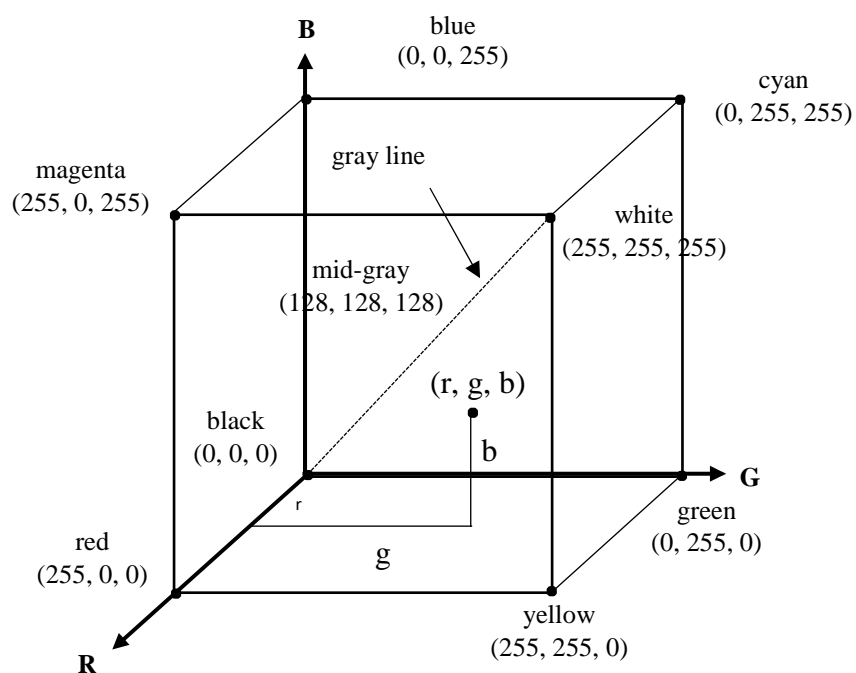
2.1 Digitalización de imágenes

El color que perciben los humanos es una combinación de características físicas. El objetivo también es facilitar la especificación de colores de alguna manera estándar y aceptable. Esencialmente, son sistemas de coordenadas y subespacios donde cada color está representado por un punto. Se empezará por el más común en la digitalización.

2.1.1 RGB

Todos los espacios de color son espacios ortogonales tridimensionales, lo que significa que los tres ejes (en este caso, las intensidades de rojo, verde y azul) son perpendiculares entre sí. La intensidad del rojo comienza en cero y aumenta en uno de los ejes. El verde y el azul en los ejes correspondientes son similares. Suponiendo una profundidad de 8 bits, cada color tiene un valor máximo de 255, lo que da como resultado una estructura cúbica. La escala de grises (puntos con valores RGB iguales) se extiende de negro a blanco a lo largo de la diagonal entre estos dos puntos (Bordese & Alini, 2007).

Figura 2. Modelo de color RGB y CYM



2.1.2 Escala de grises

Según lo detallado en la figura 2, en la recta que une el origen (black) con el valor máximo de escala (white) se encuentra ubicado el componente gris (escala de grises) debido a que los 3 componentes RGB o CYM son iguales. Según lo detallado en la sección 2.1.1, se puede comprender que cada píxel de una imagen contiene 3 valores pertenecientes a dichas componentes, pero al transformar la imagen a escala de grises solo se tiene 1 componente, esta técnica es bastante utilizada en el procesamiento de imágenes porque comprende una mejora computacional a la hora de tratar estos datos.

2.2 Aplanamiento

Siguiendo el modelo anterior (RGB) se puede comprender que la información de las imágenes viene en un cubo de matrices por sus 3 canales: rojo, verde y azul. Interpretar esta información es complicada por lo que se requiere aplicar un método de escala RGB dimensional. Dada la siguiente matriz de imagen:

$$\begin{array}{cccc}
 (r_{0,0}, g_{0,0}, b_{0,0}, 0) & (r_{0,1}, g_{0,1}, b_{0,1}, 1) & (r_{0,2}, g_{0,2}, b_{0,2}, 2) & \dots (r_{0,p}, g_{0,p}, b_{0,p}, p) \\
 (r_{1,0}, g_{1,0}, b_{1,0}, 0) & (r_{1,1}, g_{1,1}, b_{1,1}, 1) & (r_{1,2}, g_{1,2}, b_{1,2}, 2) & \dots (r_{1,p}, g_{1,p}, b_{1,p}, p) \\
 \vdots & \vdots & \vdots & \vdots \\
 (r_{n,0}, g_{n,0}, b_{n,0}, 0) & (r_{n,1}, g_{n,1}, b_{n,1}, 1) & (r_{n,2}, g_{n,2}, b_{n,2}, 2) & \dots (r_{n,p}, g_{n,p}, b_{n,p}, p)
 \end{array}$$

El correspondiente arreglo lineal que se obtiene tras la transformación es:

$$r_{0,0}, g_{0,0}, b_{0,0} \dots r_{n,0}, g_{n,0}, b_{n,0}, r_{0,1}, g_{0,1}, b_{0,1} \dots r_{n,1}, g_{n,1}, b_{n,1} \dots r_{0,p}, g_{0,p}, b_{0,p} \dots r_{n,p}, g_{n,p}, b_{n,p}$$

Tal como se explicó en el capítulo 1, la razón más importante por la cual se aplicó esta transformación es para alimentar el modelo de detección de datos atípicos.

En cambio, si se sigue el modelo de escalas grises, se tendría el siguiente arreglo matricial:

$$\begin{array}{c}
 (g^{s_{0,0}}, g^{s_{0,1}}, g^{s_{0,2}} \dots g^{s_{0,n-2}}, g^{s_{0,n-1}}, g^{s_{0,n}}) (g^{s_{1,0}}, g^{s_{1,1}}, g^{s_{1,2}} \dots \\
 g^{s_{1,n-2}}, g^{s_{1,n-1}}, g^{s_{1,n}}) \\
 \vdots \\
 (g^{s_{p,0}}, g^{s_{p,1}}, g^{s_{p,2}} \dots g^{s_{p,n-2}}, g^{s_{p,n-1}}, g^{s_{p,n}})
 \end{array}$$

Tal que: $gs = scale - gray$ y $n \times p$ son las dimensiones que puede tener una imagen.

El correspondiente arreglo lineal que se obtiene tras la transformación es:

$$g_{s0,0}, g_{s0,1}, g_{s0,2} \dots g_{0n-2}, g_{0n-1}, g_{0n} \dots , g_{sp,0}, g_{sp,1}, g_{sp,2} \dots g_{pn-2}, g_{pn-1}, g_{pn}$$

Para este estudio se utilizó la técnica del aplanamiento bajo los dos modelos: RGB y Escala de grises, de esta manera se establecerá comparativas en ambos.

23 Análisis de componentes principales robustas

Luego de obtener las matrices de pixeles $X = (x_1, x_2, x_3 \dots x_n)$ donde $X \in \mathbb{R}_{n \times p}$ las cuales provienen de la transformación por escala RGB y escala de grises de los videos de cámara de seguridad. Sin embargo, estas matrices tienen alta dimensionalidad $p \gg n$ lo cual hace inviable tratarlas sin un método no supervisado de reducción de dimensionalidad como el ACP. A continuación, se muestra las matrices con su dimensionalidad.

Tabla 1. Detalle de las matrices de los videos de seguridad estudiados

Nombre del video de seguridad	Método de transformación imagen a matriz	Descripción	Dimensión
Patio de empresa	Escala RGB	Parqueadero para personal ejecutivo de una empresa.	$n = 235, p = 61440$
	Escala de grises		$n = 235, p = 20480$
Garita	Escala RGB	Garita principal de una empresa.	$n = 700, p = 61440$
	Escala de grises		$n = 700, p = 20480$
Segundo patio de la empresa	Escala RGB	Patio de la empresa.	$n = 720, p = 61440$
	Escala de grises		$n = 720, p = 20480$
Casa	Escala RGB	Portal de una casa.	$n = 967, p = 61440$
	Escala de grises		$n = 967, p = 20480$

Nota. Esta tabla muestra la cantidad de imágenes n y variables p que se utilizarán para verificar la funcionalidad de la implementación.

Como técnica robusta se utilizó la técnica de ACP ROBPCA de Hubert dada la capacidad para manejar datos de alta dimensionalidad.

2.3.1 ROBPCA

Para usar el ROBPCA usamos la librería *rospca* que es basado en el algoritmo de (Hubert et al, 2005) mediante el software R. El cual nos da la matriz de cargas y la matriz de puntuaciones. Sin embargo, teóricamente este método consta de tres pasos principales que detallaremos a continuación. Primero se procesa la data estandarizando las variables de manera robusta por medio de la mediana y Q_n , luego utilizando descomposición de valores singulares se reduce al subespacio de las n observaciones a un subespacio que tiene como máximo una dimensión de $n - 1$ para consiguiente seleccionar el subconjunto de las h observaciones con menor atipicidad. Luego se construye una matriz de covarianza preliminar para calcular el número k de componentes lo cual produce un subespacio k -dimensional que se ajuste bien a los datos. Obtenido el subespacio se puede proyectar los datos originales al mismo para luego estimar robustamente la matriz de medias y la matriz de dispersión donde se calculan los valores propios l_1, l_2, \dots, l_k por consiguiente sus vectores propios. La matriz de distancia puntuaciones se calcula como en (3) y la matriz de distancias ortogonales como en (4). Para inicializar el algoritmo usamos un k que es seleccionado mediante el criterio de Hubert et al. (2005) explicado en la sesión anterior.

24 Detección de observaciones atípicas

2.4.1 Cálculo de puntos de corte

Luego de calcular las distancias ortogonales y de puntuación, es necesario poder identificar los puntos de cortes que ayudan a clasificar si una observación es atípica. Los puntos de corte se calculan con la ayuda de la chi- cuadrado χ^2 , en el caso del corte ortogonal se utiliza $\sqrt{\chi^2_{q,0.975}}$ debido a que las distancias de Mahalanobis de las puntuaciones normalmente distribuidas se aproximan a una χ^2 . Para el corte de puntuación se calcula $g1 * \chi^2_{g2}$ dado que esta da una buena aproximación a la distribución no conocida de las distancias ortogonales.

2.4.2 Mapa de valores atípicos

Para graficar las observaciones atípicas se usa el mapa de outliers, en el eje horizontal las distancias de puntuaciones y en el eje vertical las distancias ortogonales, donde en el primer, segundo y cuarto cuadrante se encuentran los datos atípicos es decir las imágenes que detectan intrusos.

25 Implementación

Implementación 1. Escala RGB de los datos de 3D a 1D

Entrada: nombre, ruta

1. Se accede a ruta/nombre
2. Vectorizamos los nombres de cada imagen: [file_name1.jpg, file_name2.jpg, ...]
3. Creamos un vector vacío resultado = [], dimensión = 1 * número de imágenes
4. Para cada file_name.jpg hacer:
 - i. image_path = ruta/nombre/file_name.jpg
 - ii. image = imread(image_path, 1)
 - iii. array1 = array(image)
 - iv. array2 = array1.flatten()
 - v. Guardar array2 en resultado
5. Creamos un vector vacío índices = [], dimensión = 1 * número de imágenes
6. Creamos un vector vacío name_col = [], dimensión = 1 * cantidad de pixeles
7. Para cada índice hacer:
 - i. Concatenar “imagen” + “i”, dando como resultado “imagen1”.
 - ii. Guardar cada cadena en el vector de índices.
8. Para cada name_col hacer:
 - i. Concatenar “variable” + “j” dando como resultado “variable1”,
 - ii. Guardar cada cadena en el vector name_col.
9. Guardamos el vector resultado en un dataframe llamado dataf, especificando el index = índices y columns = name_col.

Salida: retorna(dataf)

Implementación 2. Detección de intrusos

Entrada: nombre, ruta

1. Llamar a la función en Python de aplanar.
-

aplanar (nombre, ruta)

2. Calcular ACP robusto con rospca.
3. Calcular los cortes de distancia robusta y de puntuación $\sqrt{\chi^2_{q,0.975}}$ y $g1 * \chi^2_{g2}$.
4. Calcular las $OD_i \geq \sqrt{\chi^2_{q,0.975}}$ y $SD_i \geq g1\chi^2_{g2}$.
5. Calcular la $DA = OD_i \geq \sqrt{\chi^2_{q,0.975}} \cup SD_i \geq g1\chi^2_{g2}$.
6. Hacer hasta $it = n$
 - a. Si $OD_i \geq \sqrt{\chi^2_{q,0.975}}$ o $SD_i \geq g1\chi^2_{g2} = \text{True}$
 - i. $\text{Atípicos} = it + \text{Atípicos}$
7. Para cada observación de Atípicos hacer esto
 - i. $\text{Imprimir}(\text{concat}(\text{ruta}, \text{Atípicos}_i))$

Salida: $\text{Imprimir}(\text{concat}(\text{ruta}, \text{Atípicos}_i))$,

CAPÍTULO 3

3. RESULTADOS

En esta sesión se muestran los resultados que se encontraron al analizar videos de vigilancia reales de domicilios y empresas en Ecuador con el fin de detectar intrusos a través de técnicas robustas.

En primera instancia se redujo la dimensionalidad con ACP robusto, con el cual se procedió a detectar los puntos de corte de distancias ortogonales y de puntuación para clasificar si una observación (imagen) es atípica, a continuación, se muestra las veces que se detectó a un intruso en los videos de vigilancia estudiados y sus puntos de cortes que ayudan a la clasificación.

Tabla 2. Puntos de corte y cantidad de intrusos detectados por la implementación

Video de vigilancia	$\sqrt{\chi^2_{q,0.975}}$	$g1\chi^2_{g2}$	$N(OD_i \geq \sqrt{\chi^2_{q,0.975}})$	$N(SD_i \geq g1\chi^2_{g2})$	$N(OD_i \geq \sqrt{\chi^2_{q,0.975}}) \cup N(SD_i \geq g1\chi^2_{g2})$
Patio de empresa (Escala RGB)	4,001	803,939	57	65	104
Patio de empresa (Escala de grises)	4,001	440,368	54	65	103
Garita (Escala RGB)	473,046	4,526	176	242	291

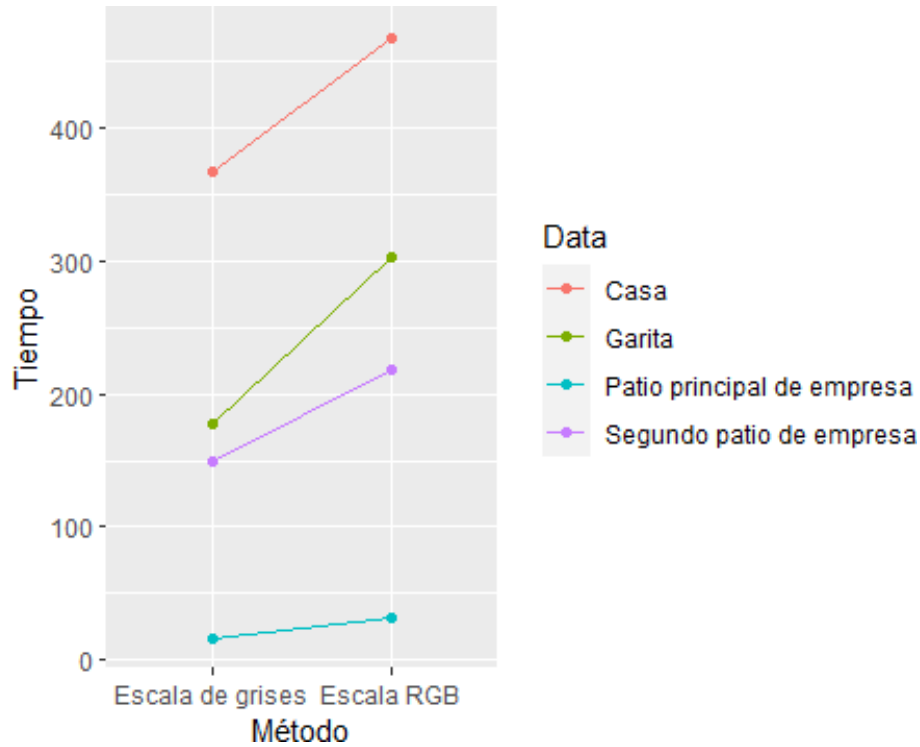
Garita (Escala de grises)	917,041	4,526	177	259	296
Patio 2 empresa (Escala RGB)	430,298	4,523	192	199	288
Patio 2 empresa (Escala de grises)	226,971	4,526	187	205	286
Casa (Escala RGB)	5.189,764	3,3381	152	245	387
Casa (Escala de grises)	2.959,464	3,338	141	244	376

Nota. Esta tabla muestra los puntos de corte y la cantidad de atípicos (intrusos) que detectó la implementación mediante el método del aplanamiento con sus dos escalas estudiadas (escala RGB y escala de grises).

En la tabla se observó que la técnica de escala de grises clasifica por poco la misma cantidad de imágenes que la escala RGB, por ejemplo, en el caso del patio de empresa se detectó atípicos con la técnica escala de grises 103 veces y con la técnica de escala RGB 104. Por lo cual se realizó una prueba de hipótesis para determinar si es significativa la diferencia de precisión en los métodos estudiados. Los puntos de corte difieren debido a que los cortes dependen del valor de componentes principales, para lo cual se usó la técnica de (Hubert et al., 2005) explicada en el capítulo 2 lo cual hace diferir en ambos casos debido a la cantidad de variables.

Para analizar ambas técnicas, también se revisó los tiempos de ejecución como se muestra en la figura 3 donde se mostró que cuando se utiliza la técnica de escala RGB la implementación se demora aproximadamente el doble en comparación con la técnica de escala de grises dado que en la técnica de escala de grises utilizó menos variables que en la técnica de escala RGB como se mostró en la tabla 1.

Figura 3. Tiempo en segundos por método empleado para procesar imágenes y por conjunto de datos estudiado




Nota. El gráfico representa el tiempo (segundos) estimado por escala implementada en las cuatro datas utilizadas.

3.1 Análisis del video de seguridad patio de empresa

3.1.1 Análisis del video de seguridad del patio principal de la empresa mediante la técnica de escala RGB

Se revisó los resultados de la detección de datos atípicos mediante el uso de un mapa de outliers como se muestra en la fig. 4 donde se mostró que la implementación detecta varias imágenes como atípicas en los cuadrantes primero, segundo y cuarto que clasifican los tipos de datos atípicos de mal apalancamiento (distancia ortogonal alta y distancia de puntuación alta), ortogonal (distancia ortogonal alta) y de buen apalancamiento (distancia de puntuación alta) respectivamente. Detectando en total 104 imágenes como atípicas, es decir se detectó 104 veces que aparece un intruso.

Figura 4. Mapa de outliers del video patio de la empresa con método de escala RGB con el método de escala RGB



Nota. El gráfico representa los datos atípicos clasificados en los diferentes cuadrantes del video del patio de la empresa mediante la técnica de la escala RGB.

Figura 5. Imágenes captadas por la implementación como atípicas en los videos de seguridad del patio de la empresa con la escala RGB



Nota. El gráfico muestra algunas de las imágenes captadas como atípicas en el video de patio de la empresa por el método de escala RGB.

Tabla 3. Tabla de confusión para el video de patio de empresa del método de escala RGB


Real/Modelo	No atípico	Atípico
No atípico	106	0
Atípico	25	104

Nota. Esta tabla muestra los falsos positivos y negativos del modelo ejecutado con el fin de calcular la precisión mediante el método de escala RGB.

En la fig. 5 se mostró algunas imágenes que retorna la implementación como atípicas, y se observó que detecta con 89% de


precisión los momentos donde aparece un intruso como se observa en la tabla 3, así también se obtiene 106 imágenes como verdaderos negativos y 104 como verdaderos positivos. Lo cual ayuda a comprobar la efectividad de la implementación. En la fig. 6 y fig. 7 se muestra el comportamiento de las imágenes, dada las medidas de distancia ortogonal (4) y distancia de puntuación (3), lo cual muestra las observaciones por encima de los cortes de puntuación y ortogonal detallados en la tabla 2.

Figura 6. Gráfica de distancias de puntuación del video de seguridad del patio con el método de escala RGB



Nota. La gráfica representa las 235 imágenes que componen el video de seguridad con sus distancias de puntuación para el método de escala RGB así también las 65 imágenes por encima del corte de distancias de puntuación.

Figura 7. Gráfica de distancias ortogonales del video de seguridad del patio con el método de escala RGB




Nota. La gráfica representa las 235 imágenes que componen el video de seguridad con sus distancias ortogonales para el método de escala RGB así también las 57 imágenes por encima del corte de distancias ortogonales.

3.1.2 Análisis del video de seguridad del patio principal de la empresa mediante la técnica de escala de grises

Se revisó los resultados de la detección de datos atípicos mediante el uso de un mapa de outliers con la técnica de lectura de imágenes de conversión a escala de grises como se muestra en la fig. 8 donde se mostró que la implementación detecta varias imágenes como atípicas en los cuadrantes primero, segundo y cuarto que clasifican los tipos de datos atípicos de mal apalancamiento (distancia ortogonal alta y distancia de puntuación alta), ortogonal (distancia ortogonal alta) y de buen apalancamiento (distancia de puntuación alta) respectivamente. Detectando en total 103 imágenes como atípicas, es decir se detectó 103 veces que aparecía un intruso.

Figura 8. Mapa de outliers del video patio de la empresa con método de escala de grises



Nota. El gráfico representa los datos atípicos clasificados en los diferentes cuadrantes del video del patio de la empresa captado mediante la técnica de escala de grises.

Figura 9. Imágenes captadas por la implementación como atípicas con el método de escala de grises



Nota. El gráfico muestra algunas de las imágenes captadas como atípicas en el video de patio de la empresa por el método de escala de grises.


En la fig.9 se mostró algunas imágenes que retorna la implementación como atípicas, y se observó que detecta con una precisión del 88% los momentos de los videos donde aparece un intruso lo cual se detalla en la tabla 4 así también se obtiene 106 imágenes como verdaderos negativos y 103 como verdaderos positivos. Esto ayuda a comprobar la efectividad de la implementación planteada. En la fig. 10 y fig. 11 se muestra el comportamiento de las imágenes dadas las medidas de distancia ortogonal (4) y distancia de puntuación (3), lo cual muestra las observaciones por encima de los cortes de puntuación y ortogonal detallados en la tabla 2.

Tabla 4. Tabla de confusión video del patio de empresa

Real/ Modelo	No atípico	Atípico
No atípico	106	0
Atípico	26	103

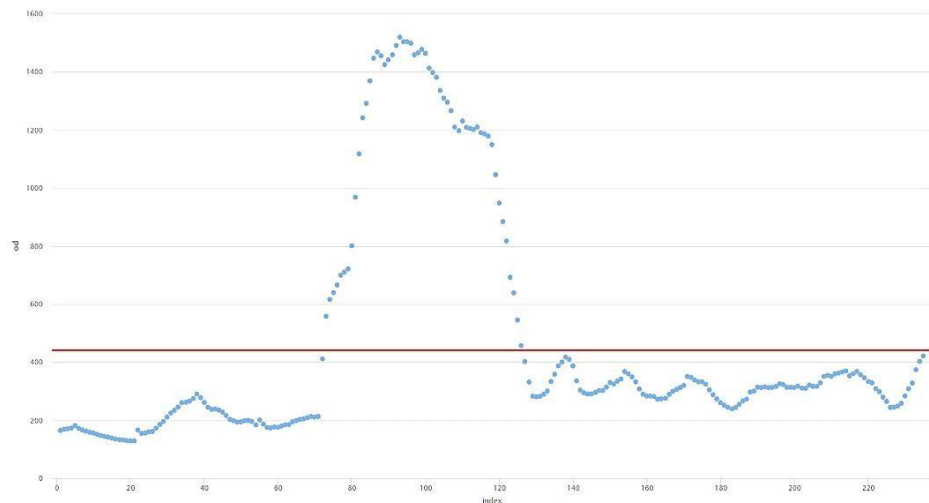
Nota. Esta tabla muestra los falsos positivos y negativos del modelo ejecutado con el fin de calcular la precisión mediante el método de escala de grises.

Figura 10. Gráfica de distancias de puntuación del video de seguridad del patio con el método de escala de grises



Nota. La gráfica representa las 235 imágenes que componen el video de seguridad con sus distancias de puntuación para el método de escala de grises así también las 65 imágenes por encima del corte de distancias de puntuación.

Figura 11. Gráfica de distancias ortogonales del video de seguridad del patio con el método de escala de grises



Nota. La gráfica representa las 235 imágenes que componen el video de seguridad con sus distancias ortogonales para el método de escala de grises así también las 54 imágenes por encima del corte de distancias ortogonales.

3.1.3 Prueba de hipótesis diferencia de proporciones de las técnicas del aplanamiento para el video de patio de empresa

Se planteó la siguiente hipótesis donde se revisó si la precisión de la escala de grises es igual que la escala RGB donde $\hat{\pi}_{Grises} = \frac{VP+VN}{n_1}$

$$\frac{106+103}{235} = 0,88 \text{ y } \hat{\pi}_{RGB} = \frac{VP+VN}{n_2} = \frac{106+104}{235} = 0,89.$$

Sea VP la cantidad de imágenes como verdaderos positivos en la tabla 3 y 4 así también VN la cantidad de imágenes clasificados como verdaderos negativos. Para el valor de $\pi = \frac{Total VP+VN}{n_1+n_2} = \frac{106+103+106+104}{235+235} = \frac{419}{470} = 0,89$. Dado que $n > 30$ se asume normalidad.

Tabla 5. Prueba de hipótesis para comparar el método de aplanamiento por las dos técnicas (escala de grises y RGB)

Hipótesis		$H_0: \pi_{Grises} = \pi_{RGB}$ $H_1: \pi_{Grises} \neq \pi_{RGB}$	
Prueba estadística		$z_0 = \frac{\hat{\pi}_{Grises} - \hat{\pi}_{RGB}}{\sqrt{\hat{\pi}(1-\hat{\pi})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}$	
Valor del estadístico	$z_0 = 9,8 \times 10^{-31}$	Valor p	$p = 1$


Nota. Tabla de prueba de hipótesis para la diferencia de proporciones donde se compara la precisión del método de aplanamiento para las dos técnicas escala de grises y RGB.

Luego de realizar la prueba de hipótesis para comparar las precisiones de las técnicas de escala de grises y RGB se obtuvo el valor p mayor que 0,05 como se muestra en la tabla 5 por lo que no hay suficiente evidencia estadística para rechazar la hipótesis nula, es decir la precisión de escala de grises es igual a la precisión de la escala RGB.

3.2 Análisis del video de la garita de la empresa

3.2.1 Análisis video de seguridad de la garita de la empresa con la técnica de escala RGB

Figura 12. Mapa de outliers del video de garita de la empresa con método de escala RGB



Nota. El gráfico representa los datos atípicos clasificados en los diferentes cuadrantes del video de garita mediante método escala RGB.


Se revisó los resultados de la detección de datos atípicos mediante el uso de un mapa de outliers como se muestra en la fig. 12 donde se mostró que la implementación detecta varias imágenes como atípicas en los cuadrantes primero, segundo y cuarto que clasifican los tipos de datos atípicos de mal apalancamiento (distancia ortogonal alta y distancia de puntuación alta), ortogonal (distancia ortogonal alta) y de buen apalancamiento (distancia de puntuación alta) respectivamente. Detectando en total 291 imágenes como atípicas en el video de seguridad de la garita de la empresa.

Figura 13. Imágenes captadas por la implementación como atípicas con el método escala RGB



Nota. El gráfico muestra algunas de las imágenes captadas como atípicas en el video de garita por el método de escala RGB.

Figura 14. Gráfica de distancias de puntuación del video de seguridad de la garita con el método escala RGB



Nota. La gráfica representa las 700 imágenes que componen el video de seguridad de la garita con sus distancias de puntuación para el método de la escala RGB así también las 242 imágenes que superan el corte de las distancias de puntuación.

En la fig. 13 se mostró algunas imágenes que retorna la implementación como atípicas en el video de la garita principal de la empresa, y se observó que detecta con 99,71% de precisión lo cual se detalla en la tabla 6 así también se obtiene 407 imágenes como verdaderos negativos y 291 como verdaderos positivos. Esto ayuda a comprobar la efectividad de la implementación planteada. En la fig. 14 y fig. 15 se muestra el comportamiento de las imágenes dada las medidas de distancia


ortogonal (4) y distancia de puntuación (3), lo cual muestra las observaciones por encima de los cortes de puntuación y ortogonal detallados en la tabla 2 en video garita por método de escala RGB.

Tabla 6. Tabla de confusión video de garita

Real/Modelo	No atípico	Atípico
No atípico	407	0
Atípico	2	291

Nota. Esta tabla muestra los falsos positivos y negativos del modelo ejecutado con el fin de calcular la precisión mediante el método de escala RGB.


Figura 15. Gráfica de distancias ortogonales del video de seguridad de la garita con el método escala RGB



Nota. La gráfica representa las 700 imágenes que componen el video de seguridad de la garita con sus distancias ortogonales para el método de escala RGB así también las 176 imágenes que superan el corte de las distancias ortogonales.

3.2.2 Análisis video de seguridad de la garita de la empresa con la técnica de escala de grises

Figura 16. Mapa de outliers del video de garita de la empresa con método de escala de grises



Nota. El gráfico representa los datos atípicos clasificados en los diferentes cuadrantes del video de garita para la técnica de la escala de grises en el video de garita así también las 296 imágenes que superan el corte de las distancias de puntuación.


Se revisó los resultados de la detección de datos atípicos mediante el uso de un mapa de outliers como se muestra en la fig. 16 donde se mostró que la implementación detecta varias imágenes como atípicas en los cuadrantes primero, segundo y cuarto que clasifican los tipos de datos atípicos, de mal apalancamiento (distancia ortogonal alta y distancia de puntuación alta), ortogonal (distancia ortogonal alta) y de buen apalancamiento (distancia de puntuación alta) respectivamente. Detectando en total 296 imágenes como atípicas en el video de seguridad de la garita de la empresa, es decir se detectó 296 veces que aparecía un intruso.

Figura 17. Imágenes captadas por la implementación como atípicas con el método de escala de grises



Nota. El gráfico muestra algunas de las imágenes captadas como atípicas en el video de garita por el método de escala de grises.

Figura 18. Gráfica de distancias de puntuación del video de seguridad de la garita mediante escala de grises




Nota. La gráfica representa las 700 imágenes que componen el video de seguridad con sus distancias de puntuación para el método de blanco y negro así también las 259 imágenes que superan el corte de las distancias de puntuación.

En la fig. 17 se mostró algunas imágenes que retorna la implementación como atípicas en el video de la garita principal de la empresa, y se observó que detecta con 98,57% de precisión los momentos de los videos donde aparece un intruso lo cual se detalla en la tabla 7 así

también se obtiene 404 imágenes como verdaderos negativos y 291 como verdaderos positivos. Esto ayuda a comprobar la efectividad de la implementación planteada. En la fig. 18 y fig. 19 se muestra el comportamiento de las imágenes dada las medidas de distancia ortogonal (4) y distancia de puntuación (3), lo cual muestra las observaciones por encima de los cortes de puntuación y ortogonal detallados en la tabla 2 en video garita por método de escala de grises.

Figura 19. Gráfico de distancias ortogonales del video de seguridad de la garita



Nota. La gráfica representa las 700 imágenes que componen el video de seguridad con sus distancias ortogonales para el método de escala de grises así también las 177 imágenes que superan el corte de las distancias ortogonales.

Tabla 7. Tabla de confusión video garita

Real/Modelo	No atípico	Atípico
No atípico	404	5
Atípico	0	291

Nota. Esta tabla muestra los falsos positivos y negativos del modelo ejecutado con el fin de calcular la precisión mediante el método de escala de grises.

3.2.3 Prueba de hipótesis diferencia de proporciones de las técnicas del aplanamiento para el video de garita

Se planteó la siguiente hipótesis donde se revisó si la precisión es de escala de grises es igual que la escala RGB donde $\hat{\pi}_{Grises} = \frac{VP+VN}{n_1} = \frac{404+291}{700} = 0,98$ y $\hat{\pi}_{RGB} = \frac{VP+VN}{n_2} = \frac{407+291}{700} = 0,99$.

$$\hat{\pi}_{Grises} = \frac{404+291}{700} = 0,98 \text{ y } \hat{\pi}_{RGB} = \frac{VP+VN}{n_2} = \frac{407+291}{700} = 0,99$$

Sea VP la cantidad de imágenes como verdaderos positivos en la tabla 6 y 7 así también VN la cantidad de imágenes clasificados como verdaderos negativos. Para el valor de $\hat{\pi} = \frac{Total\ VP+VN}{n_1+n_2} = \frac{404+291+407+291}{700+700} = 0,99$.

Dado que $n > 30$ se asume normalidad.

Tabla 8. Prueba de hipótesis para comparar el método de aplanamiento por las dos técnicas (escala de grises y RGB)

Hipótesis		$H_0: \pi_{Grises} = \pi_{RGB}$ $H_1: \pi_{Grises} \neq \pi_{RGB}$	
Prueba estadística		$Z_0 = \frac{\hat{\pi}_{Grises} - \hat{\pi}_{RGB}}{\sqrt{\hat{\pi}(1-\hat{\pi})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}$	
Valor del estadístico	$Z_0 = 0,57$	Valor p	$p = 0,45$

Nota. Tabla de prueba de hipótesis para la diferencia de proporciones donde se compara la precisión del método de aplanamiento para las dos técnicas escala de grises y RGB en el video de garita.


Luego de realizar la prueba de hipótesis para comparar las precisiones de las técnicas de escala de grises y RGB se obtuvo el valor p mayor que 0,05 como se muestra en la tabla 8, por lo que no hay suficiente evidencia estadística para rechazar la hipótesis nula, es decir la precisión de escala de grises es igual a la precisión de la escala RGB en el video de garita.

3.3 Análisis video de seguridad del segundo patio de la empresa

3.3.1 Análisis video de seguridad del segundo patio de la empresa con la técnica de escala RGB

Se revisó los resultados de la detección de datos atípicos mediante el uso de un mapa outliers como se muestra en la fig. 20 donde se mostró que la implementación detecta varias imágenes como atípicas en los cuadrantes primero, segundo y cuarto que clasifican los tipos de datos atípicos de mal apalancamiento (distancia ortogonal alta y distancia de puntuación alta), ortogonal (distancia ortogonal alta) y de buen apalancamiento (distancia de puntuación alta) respectivamente. Detectando en total 288 imágenes como atípicas en el video de seguridad del segundo patio de la empresa, es decir se detectó 288 veces que aparece un intruso.

Figura 20. Mapa de outliers del video del segundo patio de la empresa con método de escala RGB



Nota. El gráfico representa los datos atípicos clasificados en los diferentes cuadrantes del video del segundo patio de la empresa mediante el método de escala RGB.

Figura 21. Imágenes captadas por la implementación como atípicas por el método de escala RGB en el video de seguridad del segundo patio



Nota. El gráfico muestra algunas de las imágenes captadas como atípicas en el video del segundo patio por el método de escala RGB.

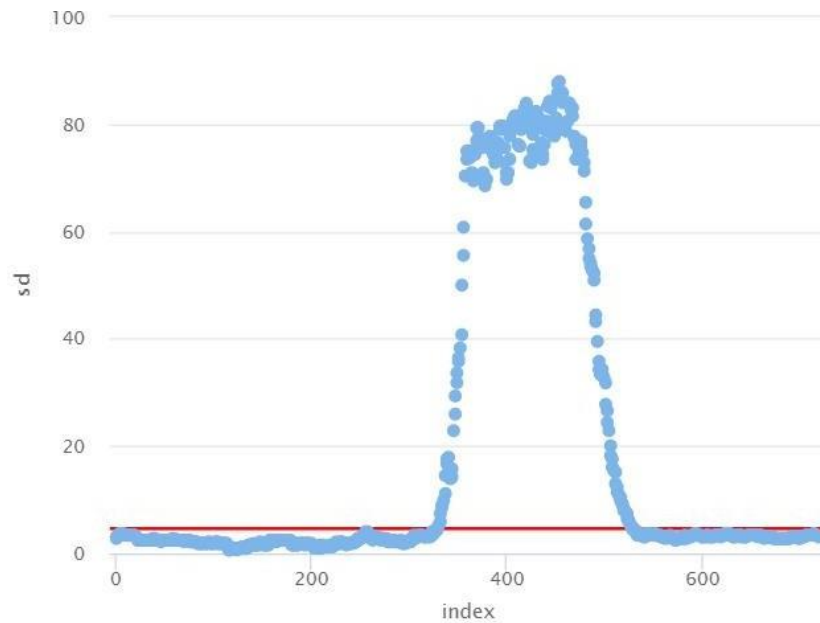
En la fig. 21 se mostró algunas imágenes que retorna la implementación como atípicas en el video del segundo patio de la empresa, y se observó que detecta con 100% de precisión los momentos de los videos donde aparece un intruso, lo cual se detalla en la tabla 9 así también se obtiene 403 imágenes como verdaderos negativos y 288 como verdaderos positivos. Esto ayuda a comprobar la efectividad de la implementación. En la fig. 22 y fig. 23 se muestra el comportamiento de las imágenes dada las medidas de distancia ortogonal (4) y distancia de puntuación (3), lo cual muestra las observaciones por encima de los cortes de puntuación y ortogonal detallados en la tabla 2 en el video del segundo patio por método de escala RGB.

Tabla 9. Tabla de confusión segundo patio de empresa

Real/Modelo	No atípico	Atípico
No atípico	432	0
Atípico	0	288


Nota. Esta tabla muestra los falsos positivos y negativos del modelo ejecutado con el fin de calcular la precisión mediante el método de escala RGB.

Figura 22. Gráfica de distancias de puntuación del video de seguridad del segundo patio de la empresa por el método de escala RGB



Nota. La gráfica representa las 720 imágenes que componen el video de seguridad con sus distancias de puntuación para el método de escala RGB así también las 192 imágenes por encima del corte de distancias de puntuación.


Figura 23. Gráfica de distancias ortogonales del video de seguridad del segundo patio de la empresa mediante el método de escala RGB



Nota. La gráfica representa las 720 imágenes que componen el video de seguridad con sus distancias ortogonales para el método de escala RGB así también las 199 imágenes por encima del corte de distancias ortogonales.

3.3.2 Análisis video de seguridad del segundo patio de la empresa con la técnica de escala de grises

Figura 24. Mapa de outliers del video del patio de la empresa mediante el método de escala de grises



Nota. El gráfico representa los datos atípicos clasificados en los diferentes cuadrantes del video del segundo patio de la empresa para la técnica escala de grises.

Se revisó los resultados de la detección de datos atípicos mediante el uso de un mapa de outliers como se muestra en la fig. 24, donde se mostró que la implementación detecta varias imágenes como atípicas en los cuadrantes primero, segundo y cuarto que clasifican los tipos de datos atípicos de mal apalancamiento (distancia ortogonal alta y distancia de puntuación alta), ortogonal (distancia ortogonal alta) y de buen apalancamiento (distancia de puntuación alta) respectivamente. Detectando en total 286 imágenes como atípicas en el video de seguridad de la garita de la empresa, es decir se detectó 286 veces que aparecía un intruso.

Figura 25. Imágenes captadas por la implementación como atípicas con el método de escala de grises



Nota. El gráfico muestra algunas de las imágenes captadas como atípicas en el video del segundo patio por el método de escala de grises.

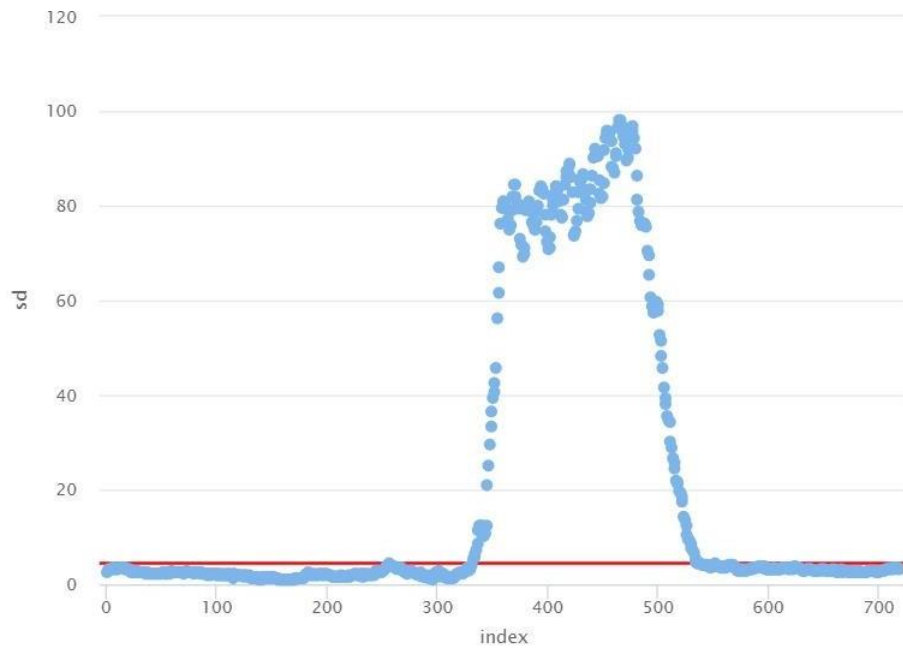
En la fig. 25 se mostró algunas imágenes que retorna la implementación como atípicas en el video del segundo patio de la empresa, y se observó que detecta con 99,7% de precisión los momentos de los videos donde aparece un intruso lo cual se detalla en la tabla 10, así también se obtiene 432 imágenes como verdaderos negativos y 286 como verdaderos positivos. En la fig. 26 y fig. 27 se muestra el comportamiento de las imágenes dada las medidas de distancia ortogonal (4) y distancia de puntuación (3), lo cual muestra las observaciones por encima de los cortes de puntuación y ortogonal detallados en la tabla 2 en el video del segundo patio por método de escala de grises.

Tabla 10. Tabla de confusión video segundo patio de empresa

Real/ Modelo	No atípico	Atípico
No atípico	432	0
Atípico	2	286

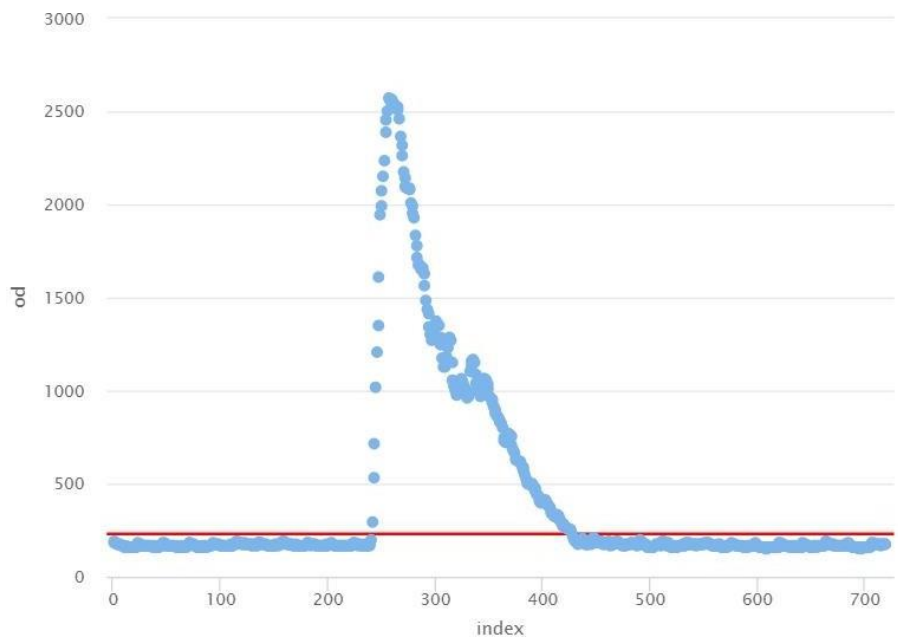
Nota. Esta tabla muestra los falsos positivos y negativos del modelo ejecutado con el fin de calcular la precisión mediante el método de escala de grises.

Figura 26. Gráfica de distancias de puntuación del video de seguridad del segundo patio de la empresa mediante escala de grises



Nota. La gráfica representa las 720 imágenes que componen el video de seguridad del segundo patio con sus distancias de puntuación para el método de escala de grises así también las 205 imágenes por encima del corte de distancias de puntuación.

Figura 27. Gráfica de distancias ortogonales del video de seguridad del segundo patio de la empresa mediante escala de grises



Nota. La gráfica representa las 720 imágenes que componen el video de seguridad con sus distancias ortogonales para el método de escala de grises así también las 187 imágenes por encima del corte de distancias ortogonales.

3.3.3 Prueba de hipótesis diferencia de proporciones de las técnicas del aplanamiento para el video del segundo patio de empresa

Se planteó la siguiente hipótesis donde se revisó si la precisión de escala de grises es igual que la escala RGB donde $\hat{\pi}_{Grises} = \frac{VP+VN}{n_1}$
 $\frac{432+286}{720} = 0,997$ y $\hat{\pi}_{RGB} = \frac{VP+VN}{n_2} = \frac{432+288}{720} = 1$

Sea VP la cantidad de imágenes como verdaderos positivos en la tabla 9 y 10 así también VN la cantidad de imágenes clasificados como verdaderos negativos. Para el valor de $\pi = \frac{Total\ VP+VN}{n_1+n_2}$
 $\frac{432+286+432+288}{720+720} = \frac{1438}{1440} = 0,998$. Dado que $n > 30$ se asume normalidad.

Tabla 11. Prueba de hipótesis para comparar el método de aplanamiento por las dos técnicas (escala de grises y RGB)

Hipótesis		$H_0: \pi_{Grises} = \pi_{RGB}$ $H_1: \pi_{Grises} \neq \pi_{RGB}$	
Prueba estadística		$z_0 = \frac{\hat{\pi}_{Grises} - \hat{\pi}_{RGB}}{\sqrt{\pi(1-\pi)\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}$	
Valor del estadístico	$z_0 = 0,50$	Valor p	$p = 0,479$

Nota. Tabla de prueba de hipótesis para la diferencia de proporciones donde se compara la precisión del método de aplanamiento para las dos técnicas escala de grises y RGB en el video de segundo patio de la empresa.


Luego de realizar la prueba de hipótesis para comparar las precisiones de las técnicas de escala de grises y RGB se obtuvo el valor p mayor que 0,05 como se muestra en la tabla 11, por lo que no hay suficiente evidencia estadística para rechazar la hipótesis nula, es decir, la precisión de escala de grises es igual a la precisión de la escala RGB en el video del segundo patio de la empresa.

3.4 Análisis video de seguridad del portal de una casa

3.4.1 Análisis del video del portal de una casa con la técnica de escala RGB


Se revisó los resultados de la detección de datos atípicos mediante el uso de un mapa de outliers como se muestra en la fig. 28 donde se mostró que la implementación detecta varias imágenes como atípicas en los cuadrantes primero, segundo y cuarto que clasifican los tipos de datos atípicos de mal apalancamiento (distancia ortogonal alta y distancia de puntuación alta), ortogonal (distancia ortogonal alta) y de buen apalancamiento (distancia de puntuación alta) respectivamente. Detectando en total 387 imágenes como atípicas en el video de seguridad de la casa, es decir se detectó 387 veces que aparece un intruso.

Figura 28. Mapa de outliers del video de casa de la empresa mediante el método de la escala RGB



Nota. El gráfico representa los datos atípicos clasificados en los diferentes cuadrantes del video de casa mediante el método de escala RGB.

Figura 29. Imágenes captadas por la implementación como atípicas con el método de escala RGB



Nota. El gráfico muestra algunas de las imágenes captadas como atípicas en el video de la casa por el método de escala RGB.


En la fig. 29 se mostró algunas imágenes que retorna la implementación como atípicas en el video de la casa y se observó que detecta con 84% de precisión los momentos de los videos donde aparece un intruso lo cual se detalla en la tabla 12, así también se obtiene 441 imágenes como verdaderos negativos y 374 como verdaderos positivos. En la fig. 30 y fig. 31 se muestra el comportamiento de las imágenes dada las medidas de distancia ortogonal (4) y distancia de puntuación (3), lo cual muestra las observaciones por encima de los cortes de puntuación y ortogonal detallados en la tabla 2 en el video de la casa por el método de escala RGB.

Tabla 12. Tabla de confusión video del portal de una casa

Real/ Modelo	No atípico	Atípico
No atípico	441	13
Atípico	139	374


Nota. Esta tabla muestra los falsos positivos y negativos del modelo ejecutado con el fin de calcular la precisión mediante el método de escala RGB.

Figura 30. Gráfica de distancias de puntuación del video de la casa mediante el método de escala RGB



Nota. La gráfica representa las 967 imágenes que componen el video de seguridad de la casa con sus distancias de puntuación para el método de escala RGB así también las 245 imágenes por encima del corte de distancias de puntuación.


Figura 31. Gráfica de distancias ortogonales del video de la casa por el método de escala RGB



Nota. La gráfica representa las 967 imágenes que componen el video de seguridad de la casa con sus distancias ortogonales para el método de escala RGB así también las 152 imágenes por encima del corte de distancias ortogonales.

3.4.2 Análisis video casa con la técnica de la escala de grises


Figura 32. Mapa de outliers del video de casa de la empresa con método de escala de grises



Nota. El gráfico representa los datos atípicos clasificados en los diferentes cuadrantes del video de la casa mediante la técnica de escala de grises.

Se revisó los resultados de la detección de datos atípicos mediante el uso de un mapa de outliers como se muestra en la fig. 32, donde se mostró que la implementación detecta varias imágenes como atípicas en los cuadrantes primero, segundo y cuarto que clasifican los tipos de datos atípicos de mal apalancamiento (distancia ortogonal alta y distancia de puntuación alta), ortogonal (distancia ortogonal alta) y de buen apalancamiento (distancia de puntuación alta) respectivamente. Detectando en total 376 imágenes como atípicas en el video de seguridad, es decir se detectó 376 veces que aparecía un intruso.

Figura 33. Imágenes captadas por la implementación como atípicas con el método de escala de grises



Nota. El gráfico muestra algunas de las imágenes captadas como atípicas en el video de la casa por el método de escala de grises.

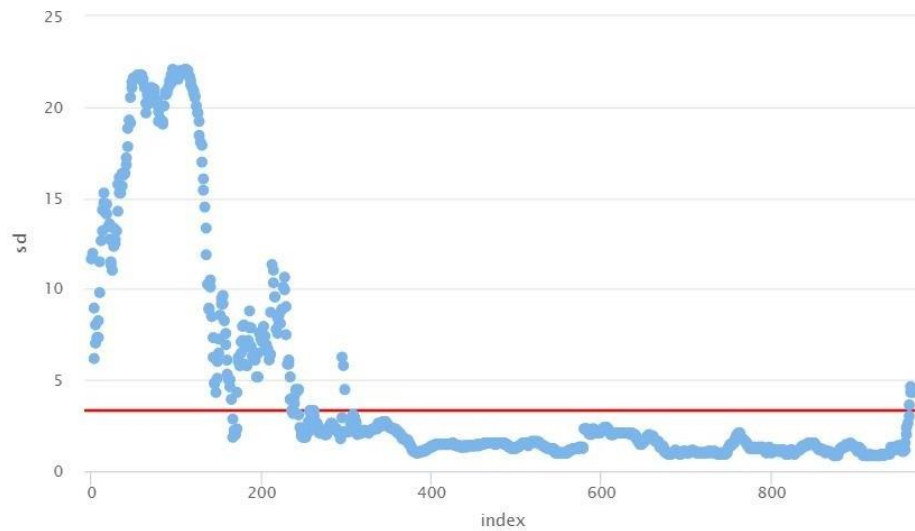
En la fig. 33 se mostró algunas imágenes que retorna la implementación como atípicas en el video de la casa. Se observó que detecta con 83% de precisión los momentos de los videos donde aparece un intruso lo cual se detalla en la tabla 13, así también se obtiene 439 imágenes como verdaderos negativos y 363 como verdaderos positivos. En la fig. 34 y fig. 35 se muestra el comportamiento de las imágenes dada las medidas de distancia ortogonal (4) y distancia de puntuación (3), lo cual muestra las observaciones por encima de los cortes de puntuación y ortogonal detallados en la tabla 2 en el video de la casa por el método de escala de grises.

Tabla 13. Tabla de confusión video del portal de una casa

Real/ Modelo	No atípico	Atípico
No atípico	439	13
Atípico	152	363

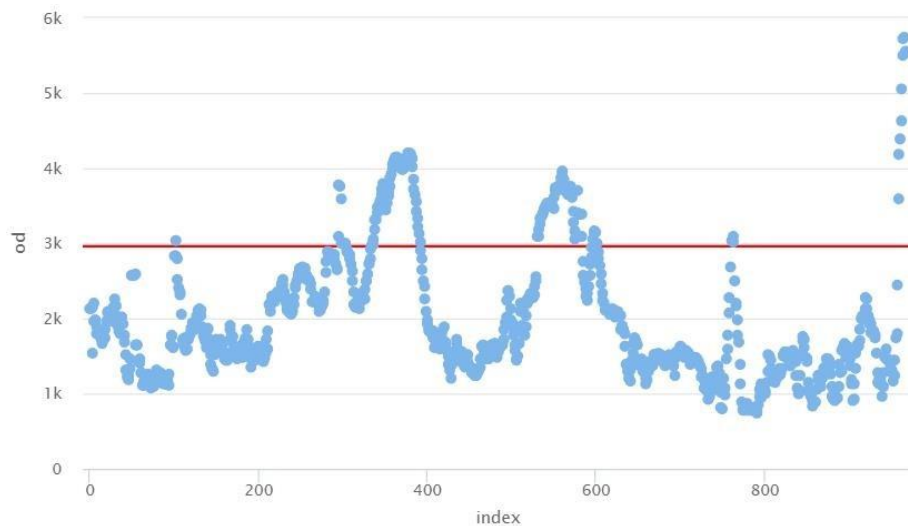
Nota. Esta tabla muestra los falsos positivos y negativos del modelo ejecutado con el fin de calcular la precisión mediante el método de escala de grises.

Figura 34. Gráfica de distancias de puntuación del video de la casa por el método de escala de grises



Nota. La gráfica representa las 967 imágenes que componen el video de seguridad de la casa con sus distancias de puntuación para el método de escala de grises así también las 244 imágenes por encima del corte de distancias de puntuación.

Figura 35. Gráfica de distancias ortogonales del video de la casa por el método de escala de grises



Nota. La gráfica representa las 967 imágenes que componen el video de seguridad de la casa con sus distancias ortogonales para el método de escala de grises así también las 141 imágenes por encima del corte de distancias ortogonales.

3.4.3 Prueba de hipótesis diferencia de proporciones de las técnicas del aplanamiento para el video de la casa

Se planteó la siguiente hipótesis donde se revisó si la precisión es de escala de grises es menor que la escala RGB donde $\hat{\pi}_{Grises} = \frac{VP+VN}{n_1} = \frac{439+363}{967} = 0,83$ y $\hat{\pi}_{RGB} = \frac{VP+VN}{n_2} = \frac{441+374}{967} = 0,84$

Sea VP la cantidad de imágenes como verdaderos positivos en la tabla 12 y 13 así también VN la cantidad de imágenes clasificados como verdaderos negativos. Para el valor de $\pi = \frac{Total\ VP+VN}{n_1+n_2} = \frac{439+363+441+374}{967+967} = \frac{1617}{1937} = 0,84$. Dado que $n > 30$ se asume normalidad.

Tabla 14. Prueba de hipótesis para comparar el método de aplanamiento por las dos técnicas (escala de grises y RGB)

Hipótesis		$H_0: \pi_{Grises} = \pi_{RGB}$ $H_1: \pi_{Grises} \neq \pi_{RGB}$	
Prueba estadística		$z_0 = \frac{\hat{\pi}_{Grises} - \hat{\pi}_{RGB}}{\sqrt{\hat{\pi}(1-\hat{\pi})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}$	
Valor del estadístico	$z_0 = 0,543$	Valor p	$p = 0,461$

Nota. Tabla de prueba de hipótesis para la diferencia de proporciones donde se compara la precisión del método de aplanamiento para las dos técnicas escala de grises y RGB en el video del portal de la casa.

Luego de realizar la prueba de hipótesis para comparar las precisiones de las técnicas de escala de grises y RGB se obtuvo el valor p mayor que 0,05 como se muestra en la tabla 14, por lo que no hay suficiente evidencia estadística para rechazar la hipótesis nula, es decir la precisión de la escala de grises es igual a la precisión de la escala RGB en el video de la casa.

3.4.4 Dashboard de visualización

Se diseñó una interfaz donde se puede observar como el modelo robusto identifica las imágenes cuando se presenta un intruso, aquellas imágenes son consideradas como atípicas.

Figura 36. Primera toma del dashboard – gráfica generada por cada fotograma del video.



Nota. En esta primera toma se puede observar que, ante la primera aparición de una persona la gráfica se dispara hacia valores muy altos indicando que existen valores atípicos o lo que nosotros llamaríamos, intrusos.

Figura 37. Segunda toma del dashboard – gráfica generada por cada fotograma del video



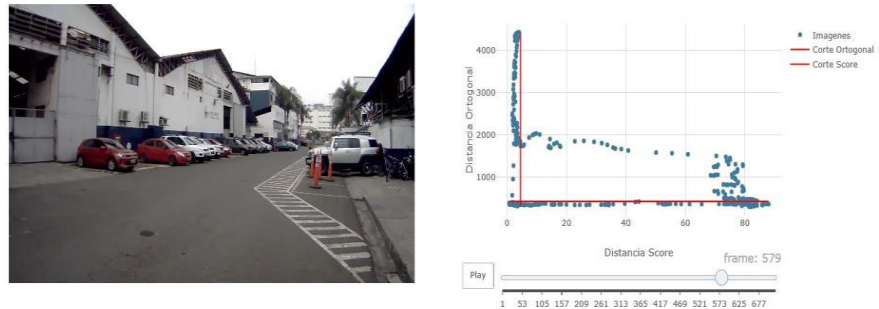
Nota. En esta segunda toma podemos observar que, el “intruso” a pesar de haberse alejado el modelo lo sigue detectando como valor atípico por lo que en la gráfica existen valores por fuera del umbral conocido como corte ortogonal y corte score.

Figura 38. Tercera toma del dashboard – mensajes de alertas por incursión del intruso



Nota. En esta tercera toma hacemos observación a la implementación que hemos hecho en el dashboard, y es que cuando el intruso incursiona en el video por primera vez se lanza un primer mensaje y así hasta cuando ya es imperceptible.

Figura 39. Cuarta toma del dashboard – alcance de la detección



Nota. En esta cuarta toma pudimos observar que cuando el intruso ya no es perceptible en el medio, los puntos vuelven al origen marcando estabilidad.

El dashboard se carga en aproximadamente 2 minutos y 45 segundos, esto se debe a que el grafico animado tarda en renderizar todos los puntos de cada fotograma, y porque se está considerando un video a color.

CAPÍTULO 4

4. CONCLUSIONES Y RECOMENDACIONES

4.1 Conclusiones

Con la finalidad de detectar intrusos en los videos de cámara de seguridad, se implementó una técnica que es capaz de detectar imágenes atípicas en los videos de seguridad a través de un estudio de pixeles. Luego de los procesos metodológicos, resultados y análisis de datos. Se concluye que:

1. La técnica empleada para detectar intrusos clasifica correctamente las veces donde aparece un intruso, alcanzando una precisión de hasta el 100% bajo ambas metodologías de procesamiento de imágenes.
2. Para el procesamiento de imágenes a datos, la técnica de aplanamiento bajo el modelo de escala RGB en los videos estudiados tiene igual precisión que bajo la técnica de escala de grises.
3. El procesamiento de imágenes a datos de la técnica del aplanamiento bajo el modelo de escala RGB tiene mayor costo computacional que el modelo de escala de grises en los videos estudiados.
4. Para la elección del modelo no supervisado robusto ACP, el método ROBPCA de Hubert tiene un bajo coste computacional cuando $p \gg n$ al usarlo en una computadora HP AMD Ryzen 5 2,10 GHz.
5. La técnica clasifica correctamente en escenarios con fondo fijo, sin embargo, cuando el fondo no es fijo el método discrimina cualquier perturbación del medio como en el caso del video de la casa, donde la grabación era irregular.
6. El método clasifica correctamente cuando hay una perturbación reciente en el medio, sin embargo, si esta perturbación es continua al pasar el tiempo el método no la detecta como atípica.
7. El método no clasifica adecuadamente cuando la perturbación no es percibida por el ojo humano, o se contrasta con el medio como en el video del segundo patio donde la persona luego de caminar unos instantes se confunde con el medio. Es decir, hay menos sensibilidad.

8. El dashboard realizado en este proyecto nos permite visualizar como el algoritmo implementado detecta al instante cuando un intruso aparece frente a la cámara y continúa detectándolo hasta una distancia perceptible por el propio ojo humano.

4.2 Recomendaciones

1. Realizar un estudio comparativo de efectividad entre los diferentes métodos de reducción de dimensionalidad robustos ACP, dado que en el presente estudio se usó únicamente ROBPCA por su bajo coste computacional.
2. El correcto funcionamiento de la implementación depende de su fondo fijo, por lo cual se debe tener cuidado del medio en el que se encuentra el video.
3. El dashboard puede ser optimizado para reducir el tiempo en el que tarda en levantarse, considerar que si el video es de mayor calidad más tardará en renderizar el gráfico por lo que es mejor utilizar un equipo con mayor rendimiento computacional.

5. REFERENCIAS

- Bordese, M., & Alini, W., Daniel. (2007). *biOps: un paquete de procesamiento de imágenes en R*.
- Campbell, N. A. (1980). Robust procedures in multivariate analysis I: Robust covariance estimation. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 29(3), 231-237.
- Cevallos-Valdiviezo, H., & Van Aelst, S. (2019). Fast computation of robust subspace estimators. *Computational Statistics & Data Analysis*, 134, 171-185.
- Croux, C., & Haesbroeck, G. (2000). Principal component analysis based on robust estimators of the covariance or correlation matrix: influence functions and efficiencies. *Biometrika*, 87(3), 603-618.
- Devlin, S. J., Gnanadesikan, R., & Kettenring, J. R. (1981). Robust estimation of dispersion matrices and principal components. *Journal of the American Statistical Association*, 76(374), 354-362.
- Fujiki, J., & Akaho, S. (2007). Spherical pca with euclideanization.
- García García, P. P. (2013). Reconocimiento de imágenes utilizando redes neuronales artificiales.
- Ghosh, D., & Vogt, A. (2012). Outliers: An evaluation of methodologies.
- Henao Giraldo, E. D. (2022). Compresión de imágenes, en el espectro visible, empleando análisis de componentes principales.
- Hubert, M., Rousseeuw, P. J., & Vanden Branden, K. (2005). ROBPCA: a new approach to robust principal component analysis. *Technometrics*, 47(1), 64-79.
- Locantore, N., Marron, J. S., Simpson, D. G., Tripoli, N., Zhang, J. T., Cohen, K. L., . . . Croux, C. (1999). Robust principal component analysis for functional data. *Test*, 8(1), 1-73.
- Loza, D., Semanate, J., & Román, P. (2014). Reconocimiento de rostros en tiempo real mediante análisis de componentes principales.
- Manjarrés de Avile, W., & Baca-Mejía, W. (2019). Victimización por crimen, percepción de seguridad y satisfacción con la vida en Colombia. *Revista de economía Institucional*, 21(41), 133-160.
- Maronna, R. (2005). Principal components and orthogonal regression based on robust scales. *Technometrics*, 47(3), 264-273.
- MDI. (2019). *Plan Específico de Seguridad Pública y Ciudadana 2019 - 2030*.

- Mukherjee, S. (2021, enero 22). Impact of Image Flattening - GeeksforGeeks. GeeksforGeeks. Recuperado 11 de septiembre de 2022, de <https://www.geeksforgeeks.org/impact-of-image-flattening/>
- Naga, R. A., & Antille, G. (1990). Stability of robust and non-robust principal components analysis. *Computational Statistics & Data Analysis*, *10*(2), 169-174.
- Ortega, K., & Pino, S. (2021). Impacto social y económico de los factores de riesgo que afectan la seguridad ciudadana en Ecuador. *Revista Espacios*, *42*, 21.
- Salibián-Barrera, M., Van Aelst, S., & Willems, G. (2006). Principal components analysis based on multivariate MM estimators with fast and robust bootstrap. *Journal of the American Statistical Association*, *101*(475), 1198-1211.
- Tarazona, A. L., & Ríos, A. R. (2021). Efectos de la inseguridad Ciudadana en el bienestar de la población. *Ciencia Latina Revista Científica Multidisciplinar*, *5*(3), 3341-3352.