



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS

FACULTAD DE CONTADURÍA, ADMINISTRACIÓN E INFORMÁTICA
MAESTRÍA EN OPTIMIZACIÓN Y CÓMPUTO APLICADO

**“Detección de rostros con aplicaciones en la
educación”**

T E S I S

Que para obtener el Grado de
Maestría en Optimización y Cómputo Aplicado

Presenta

JUAN CARLOS BONILLA ROBLES

Director de Tesis

DR. JOSÉ ALBERTO HERNÁNDEZ AGUILAR

Co-Director

DR. GUILLERMO SANTAMARÍA BONFIL

Revisores:

DR. JOSÉ ALBERTO HERNÁNDEZ AGUILAR

DR. GUILLERMO SANTAMARÍA BONFIL

DR. FEDERICO ALONSO PECINA

DR. JOSÉ CRISPÍN ZAVALA DÍAZ

DR. MARTÍN GERARDO MARTÍNEZ RANGEL



CUERNAVACA, MORELOS

MAYO 2022/MARZO 2022



CARTA CERTIFICADA DE NO PLAGIO

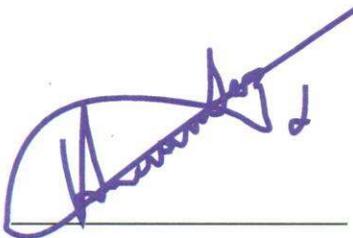
A QUIEN CORRESPONDA,

Siendo las 12 :00 horas del día 31 de marzo de 2022 en las instalaciones de la Facultad de Contaduría, Administración e Informática de la Universidad Autónoma del Estado de Morelos, declaramos los abajo firmantes, que el trabajo de investigación Detección de rostros con aplicaciones en la educación, desarrollado por el estudiante Juan Carlos Bonilla Robles, de la generación 2018-2020 de la Maestría en Administración de Organizaciones.

1. No tiene plagio.
2. Las citas de otros autores han sido debidamente identificadas en el trabajo, por lo que no se ha asumido como propias las ideas vertidas por terceros, ya sea de fuentes encontradas en medios escritos como en Internet.
3. No ha sido presentado anteriormente para obtener algún grado académico o título.

Sabemos que este compromiso de autenticidad y no plagio puede tener connotaciones éticas y legales. Por ello, en caso de incumplimiento de esta declaración, el Director de Tesis, Co - director y el estudiante se someten a lo dispuesto en las normas académicas que dictamine el Comité de Ética de la Universidad Autónoma del Estado de Morelos.

Se firma la presente carta por:



José Alberto Hernández Aguilar

Director de Tesis

Guillermo Santamaría B.

Guillermo Santamaría Bonfil

Co- Director de Tesis



Juan Carlos Bonilla Robles

Estudiante



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento firmado electrónicamente de conformidad con el ACUERDO GENERAL PARA LA CONTINUIDAD DEL FUNCIONAMIENTO DE LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS DURANTE LA EMERGENCIA SANITARIA PROVOCADA POR EL VIRUS SARS-COV2 (COVID-19) emitido el 27 de abril del 2020.

El presente documento cuenta con la firma electrónica UAEM del funcionario universitario competente, amparada por un certificado vigente a la fecha de su elaboración y es válido de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DE ESTADO DE MORELOS emitidos el 13 de noviembre del 2019 mediante circular No. 32.

Sello electrónico

GUILLERMO SANTAMARÍA BONFIL | Fecha:2022-04-29 11:44:10 | Firmante

jvEAlbzdWbmKHk6+smeDADCSdYMdcxcTV/cyHlxqrM4FkC25JJuZ6UackelwVwO8ZXQkjy8Qgot/itayOd3a7LN9uh9qUjR18LIXPYTAfZo/UmjPbABqQaUQrO4oOhYmhv8oQQD5JPfwdW6BjsFdU33RdgbjvrNCJZRZ60Aug6Ko67ooHtJ5PzT0FuX42OGFuRye1q5xO+WFFfA7LLf7KAuUnoofDc+GUfruC7LetPdzGrVPZ+UGiEOv0joC1lgWeXxYw2rOpCca0mDNU5R8dpw8LWBPdNDP5T+XHJzA5Rbme2vrt/VQCLubBRZoQXyfvK33W3Y/ZBObpFJ+pzlfg==

JOSE ALBERTO HERNANDEZ AGUILAR | Fecha:2022-04-29 11:47:30 | Firmante

bk1KaRx52LoDAyBQWILEWdTxmwtR//NojzoHckoDvbMy30LAFF/OGwFKkocv8eTuH6JNRKHCjR9pUZDzpPL+GXK5ExN7TOA4iYyOdhvOsBiqZS6Gz8Ldh/XrWXilt7IKXwpM6T1BYzXNpBtR4IYwmAOYooCgg16kpiVinPZKmTuOwpWjzRk0MZAhr9EbSFZHOSN3SkSnP7EdTRsk0RFcsnoKHlb4by155SVG/hBLrYxlTdVomfFc4dvQUku4vhfSbprfwAbclBVcEmqoC5WN8XZ33+Cvp3IZ+zDw01gqQs9m/dUI95lpMmbvdJP79/qfKdCdy83MJ5W5NTAWLITKA==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o escaneando el código QR ingresando la siguiente clave:



[g3tR6BlxZ](#)

<https://efirma.uaem.mx/noRepudio/feottFSdnsULTWgnZrYFc5okgwpSjdBD>



Cuernavaca, Morelos, a 29 de marzo de 2022

CERTIFICACIÓN DE AUTORÍA

Yo, Juan Carlos Bonilla Robles, certifico que la Disertación titulada, Detección de rostros con aplicaciones en la educación, la cual presento como requisito para optar por el grado de Maestro en Optimización y Cómputo Aplicado en la Facultad de Contaduría, Administración e Informática de la Universidad Autónoma del Estado de Morelos en el país México, es el producto de mi labor investigativa.

Asimismo, doy fe de que este trabajo ha observado las normas establecidas en el Reglamento de la Universidad y del posgrado de la Universidad Autónoma del Estado de Morelos para su realización.

Con lo anterior, deslindo a la institución de toda acción que genere plagios y asumo toda responsabilidad.



Juan Carlos Bonilla Robles

10034117

*“Un hombre que se atreve a perder una hora no ha descubierto el valor
de la vida.”
Charles Darwin.*

Agradecimientos

Esta tesis está dedicada:

A mis padres por el apoyo incondicional a lo largo de mi preparación profesional, este logro es de ustedes.

También quiero expresar mis agradecimientos a mis asesores, por su apoyo y tiempo compartido para en el desarrollo de este trabajo de investigación .

J. Carlos Bonilla Robles

Resumen

El e-learning ha cobrado mayor importancia, especialmente en la actualidad, en el contexto de la pandemia de COVID. En este tipo de aplicaciones educativas, es de suma utilidad aplicar técnicas de detección de rostros para apoyar a los profesores en línea. No solo para la automatización del pase de lista y para la supervisión (proctoring) en las evaluaciones en línea, sino también para identificar las emociones académicas, el compromiso de aprendizaje o el aburrimiento para realizar la tarea de adaptación automática. En esta investigación, discutimos la aplicación de filtros Haar y clasificador Adaboost (Viola y Jones [2001](#)) para la detección de rostros, con el fin de facilitar el conteo y supervisión en las actividades de educación en línea. Para ello, analizamos 1,100 imágenes positivas (rostros) y 1,100 imágenes negativas (sin rostros) para entrenar un modelo; obtenemos nuestro propio archivo Myhaar.xml y lo comparamos con el archivo haarcascade_frontalface_default.xml predeterminado de OpenCV, para esta prueba usamos 150 imágenes positivas y 150 imágenes negativas recolectadas de diferentes videoconferencias del mundo real. Los resultados muestran que la precisión balanceada de nuestra propuesta es mejor con un (87 % vs 82 %) que la clasificación frontal predeterminada de OpenCV. La principal contribución de este trabajo es la aplicación de una técnica clásica y de bajo costo para la detección de rostros en entornos educativos en línea.

Palabras clave: Visión Computacional, Filters Haar, Adaboost, enseñanza en línea.

Abstract

E-learning has grown in importance particularly nowadays under the COVID pandemic context. In this type of educational applications, it is extremely useful to apply face detection techniques to support online teachers. Not only for the automation of roll call and for proctoring (supervision functions) in online assessments, but also to identify academic emotions, learning engagement, or boredom to carry out automatic adaptive task. In this research, we discuss the application of Haar filters and Adaboost classifier (Viola y Jones [2001](#)) for the detection of faces, in order to facilitate the counting and proctoring in online education activities. For this purpose, we analyzed 1,100 positives images (faces) and 1,100 negative images (no faces) to train a model; we obtain our own Myhaar.xml file and compare it with the default frontal haarcascade_frontalface_default.xml file of OpenCV, for this test we use 150 positive images and 150 negative images collected from different real world video conferences. Results show the balance accuracy of our proposal is better (87% vs 82%) than the default frontal classification of OpenCV. The main contribution of this paper is the application of a classic, low-cost technique, for the detection of faces in online educational settings.

Keywords: Computer vision, Haar Filters and Adaboost, online teaching.

Índice general

1. Introducción	1
1.1. Planteamiento del problema	3
1.2. Justificación	4
1.3. Objetivo general	4
1.4. Objetivos específicos	4
1.5. Hipótesis	5
1.6. Variables	5
1.7. Alcances y limitaciones	5
1.8. Estructura de la tesis	6
2. Marco teórico	8
2.1. Enfoques para la detección de rostros	10
2.1.1. Primer criterio: Detección según el escenario.	11
2.1.2. Segundo criterio: métodos de detección divididos en categorías	11
2.2. Enfoques de detección de rostros	15
2.2.1. Enfoques geométricos.	15
2.2.2. Enfoque de Aprendizaje de Máquina	16
2.2.3. Enfoques holísticos.	17
2.3. Detección de rostros mediante clasificadores en cascada y características de Haar.	17
3. Metodología	20
3.1. Construcción del dataset	21
3.2. Imagen	24
3.3. Pre-procesamiento	27

3.4. Imagen Integral	29
3.5. Extracción de Características Haar	31
3.6. Entrenamiento del Algoritmo AdaBoost	32
3.7. Clasificación en Cascada	35
3.8. Métricas de Evaluación	36
4. Experimentación y Resultados	38
4.1. Creación del clasificador en cascada	38
4.2. Ajuste de parámetros	44
4.3. Resultados de la experimentación	46
4.4. Comparación de clasificadores	47
4.5. Discusión	48
5. Conclusiones y trabajos futuros	50
A. Código fuente.	53
B. Publicación en el libro Online Learning Analytics editado por Jay Liebowitz.	58
Referencias	69

Índice de figuras

2.1. Metodología para la detección de rostros basado en el enfoque geométrico)	16
2.2. Metodología para la detección de rostros basado en enfoque aprendizaje de máquina	16
2.3. Funciones de Haar	18
3.1. Metodología para la detección de rostros.	21
3.2. Imágenes positivas.	23
3.3. Imágenes negativas.	24
3.4. Imagen binaria.	25
3.5. Imagen escala de grises.	26
3.6. Imagen a color.	27
3.7. Cálculo de la imagen integral.	31
3.8. Filtros Haar.	32
3.9. Funcionamiento del algoritmo AdaBoost.	33
3.10. Etapas del clasificador en cascada.	36
4.1. Archivo de texto bg.txt.	39
4.2. Marcado del área del rostro en imagen positiva	40
4.3. Captura de información de imágenes positivas	41
4.4. Archivo de texto info.txt	42
4.5. Proceso de entrenamiento.	44
4.6. Subconjunto de la base de datos de prueba.	45
4.7. Comparación de OpenCV vs MyHaar.	46
B.1. Descripción del libro.	59
B.2. Tabla de contenido del libro.	60

B.3. Portada del capítulo.	61
---	----

Índice de cuadros

4.1. Comparación de clasificadores OpenCV y MyHaar	48
--	----

Capítulo 1

Introducción

La detección de rostros está surgiendo como una área activa de investigación que abarca varias disciplinas tales como el procesamiento de imágenes, el reconocimiento de patrones, visión computacional y redes neuronales (Chellappa y col. [1995](#)).

La detección de rostros mediante un sistema informático es el proceso de identificar los rostros en imágenes o frames. Este proceso ha ganado mucha importancia en áreas como la seguridad, marketing, redes sociales, educación, entre muchas más (Wechsler [2009](#)).

La analítica del aprendizaje (LA-Learning Analytics), es un campo emergente que busca definir la analítica del aprendizaje, sus procesos y su potencial para avanzar en la enseñanza y el aprendizaje en la educación en línea (Elias [2011](#)). En el área de Learning Analytics, el reconocimiento facial juega un papel importante, tanto en el human-in-the-loop como en la automatización, para la personalización del aprendizaje y los sistemas que lo imparten. En las escuelas y entornos educativos, el reconocimiento facial es un paso preliminar necesario para tareas que son más complejas, como la gestión automática de la lista de asistencia, para reducir

la carga de pasar lista y evitar las asistencias falsas. En otros entornos, el reconocimiento facial se utiliza para la evaluación electrónica, para identificar intrusos durante los exámenes virtuales, en el monitoreo de seguridad escolar para identificar intrusos y otras amenazas, como objetos con forma de pistola. De manera similar, el análisis de acciones faciales, microexpresiones, seguimiento ocular y otros puntos de referencia faciales se utilizan para la detección de emociones académicas (por ejemplo, satisfacción, ansiedad, esperanza, etc.) (Wentzel [2009](#)), señales de aprendizaje y compromiso que puede ser aprovechado por los sistemas adaptativos (Andrejevic y Selwyn [2020](#)).

Si bien para el humano detectar y reconocer rostros es una tarea que no requiere de mucho esfuerzo, el problema no es así cuando se pretende resolverlo desde un punto de visión computacional (Suárez [2000](#)). Desde sus inicios han surgido distintas técnicas para realizar la detección de rostros. (cuales técnicas, poner imagen de enfoques)

Los primeros algoritmos basados en técnicas heurísticas y antropométricas surgieron en los años 80s. Estas técnicas tienen distintos enfoques; enfoque holístico o basado en la imagen: en este método se trabaja con la imagen completa en la cual se extraen características que representen al objeto a detectar, enfoque basado en rasgos faciales o características locales: en este método se buscan elementos claves que componen el rostro humano como son los ojos, nariz y boca. Por último, el enfoque híbrido, un método que combina los dos enfoques anteriores utiliza tanto características locales y globales (Guevara y col. [2008](#)).

Los rasgos faciales se han utilizado para detectar emociones como aburrimiento, confusión, deleite, compromiso, frustración, sorpresa, cuando los estudiantes participan en un aprendizaje de nivel profundo (McDaniel y col. [2007](#)) utiliza jueces humanos y análisis correlacional para clasificar

los estados emocionales. (Bosch y col. 2015) utilizan visión por computadora y técnicas de aprendizaje automático para detectar emociones, a partir de datos recopilados en un entorno del mundo real de un laboratorio de computación escolar, hasta treinta estudiantes a la vez participaron en la clase, los resultados fueron validados cruzados para asegurar la generalización a los nuevos estudiantes, el proceso de clasificación fue exitoso (AUC = .816).

1.1. Planteamiento del problema

En el contexto actual de la pandemia SARS-COV-2, es de suma utilidad aplicar técnicas de detección de rostros para ayudar a los maestros al pase de lista, funciones de supervisión (proctoring), analizar la aceptación de contenido educativo a los alumnos, entre otras actividades que se están realizando en línea y que son necesarias para mejorar la efectividad y darle mayor credibilidad al sector educativo, así como a la educación a distancia.

Debido a lo anterior muchas instituciones están incorporando el reconocimiento biométrico para este propósito. Con los avances de la tecnología, actualmente se han podido implementar sistemas capaces de resolver las distintas problemáticas, algunas de las técnicas que se emplean en los sistemas tienen un alto grado de efectividad para la detección de rostros, sin embargo el rostro humano es un objeto dinámico con alto grado de variabilidad, la iluminación, el ángulo y el tamaño de la imagen hacen que su detección sea un problema activo para abordar (Guerrero y col. s.f.).

Es por ello que en esta investigación se propone diseñar e implementar un algoritmo, basado en filtros Haar para el entrenamiento y AdaBoost para la detección de rostros derivados de evaluaciones online, y comparar los resultados obtenidos con los resultados obtenidos por parte del clasificador de rostros frontales por default de OpenCV.

1.2. Justificación

Los sistemas de detección de rostros actuales han alcanzado un alto nivel precisión, sin embargo, las condiciones de iluminación o limitaciones de detectar rostros completos y ángulos frontales hacen que la detección sea un problema activo por mejorar, es por ello que la detección de rostros sigue siendo un tema de investigación actual. Este tema de investigación corresponde al área de cómputo aplicado, en la línea de investigación de sistemas, modelado y simulación.

1.3. Objetivo general

Implementar técnicas de machine learning para la detección de rostros en imágenes o fotogramas derivado de sistemas educativos en línea.

1.4. Objetivos específicos

- Analizar los trabajos relacionados y el estado del arte.
- Analizar las técnicas de machine learning disponibles.
- Seleccionar e implementar las técnicas adecuadas de machine learning.

- Realizar los experimentos para probar el funcionamiento de los procesos.
- Analizar los resultados y realizar la comparación con literatura relacionada.

1.5. Hipótesis

Ha. Es posible mejorar los resultados obtenidos por el clasificador de OpenCV, para la detección de rostros en procesos educativos, rostros en estado salvaje (in the wild), mediante filtros Haar y Adaboost.

H0. No es posible mejorar los resultados obtenidos por el clasificador de OpenCV, para la detección de rostros en procesos educativos, rostros en estado salvaje (in the wild), mediante filtros Haar y Adaboost.

1.6. Variables

Variable Dependiente

Detección de rostros

Variable Independiente

Imágenes o fotogramas de entrada.

1.7. Alcances y limitaciones

En este proyecto de investigación se realiza un clasificador en cascada que permite la detección de rostros en imágenes o videos. Para la construcción del clasificador, se utilizan bases de datos reportadas en la

literatura que contienen imágenes de rostros humanos. También se recolectaron imágenes de rostros humanos de sesiones de videollamadas en línea.

El proyecto de investigación se centra en la detección del rostro humano. Las imágenes utilizadas son imágenes en 2 dimensiones, el ambiente se desarrolla con software de código abierto y Python como lenguaje de programación.

1.8. Estructura de la tesis

El documento está organizado de la siguiente manera: como primer capítulo en la introducción se realiza el planteamiento del problema, los objetivos, hipótesis, así como los alcances y limitaciones que tiene la investigación. El segundo capítulo como parte del marco teórico se describen trabajos relacionados con la detección de rostros en entornos educativos, se describen los criterios y los distintos enfoques para llevar a cabo la detección de rostros. En el tercer capítulo se aborda la metodología empleada para realizar la detección de rostros, desde la construcción del dataset, el preprocesamiento a las imágenes, la extracción de las características de Haar, el entrenamiento del algoritmo Adaboost, la clasificación en cascada, hasta las métricas evaluación. En el cuarto capítulo se realizan los experimentos, se comparan y discuten los resultados obtenidos. Las conclusiones y trabajos futuros se muestran en el quinto capítulo. En el apéndice A se adjunta el código fuente del proyectos de investigación y en el apéndice B se muestra la portada y descripción del capítulo 12, que forma parte del libro “Online Learning Analytics editado por Jay Liebowitz”, dicho capítulo se realizó con base en el tema de in-

investigación abordado en esta tesis. Por último se muestran las referencias bibliográficas consultadas a lo largo de este proyecto de investigación.

Capítulo 2

Marco teórico

A medida que la educación en línea se ha disparado, se requiere la detección de rostros para ayudar a contar y monitorear las actividades de educación en línea.

(Singh y col. [2014](#)) desarrollaron un sistema de control de asistencia a través de la detección y el reconocimiento facial para facilitar y mejorar el proceso de pasar lista (marcar asistencia), este proceso que realiza el docente manualmente, consume tiempo mismo que podría ser aprovechado de manera constructiva, como en la enseñanza o aclaración de dudas. Para realizar el reconocimiento facial, utilizaron el Análisis de Componentes Principales (PCA) y el sistema funciona proyectando la imagen de la cara en un espacio de características que abarca variaciones significativas entre imágenes de caras conocidas. PCA produce un conjunto de eigenfaces. Se conoce como “eigenfaces” a las características más significativas del conjunto de caras. Esto no corresponde necesariamente con características como ojos, oídos y nariz. Las eigenfaces corresponden a los eigenvectores más grandes de la covarianza de los datos de entrenamiento.

Por otra parte (Gutierrez y col. 2017) implementaron técnicas como eigenfaces y fisherfaces para la detección de rostros, “Emotion Experience”, es un sistema que en su primer etapa realiza la detección del rostro y posteriormente reconoce el estado emocional para evaluar la experiencia de los usuarios (niños) que interactúan frente al computador mientras realizan actividades como ver fragmentos de películas o jugar un video juego. Para este proyecto, se propone analizar eigenfaces y fisherfaces. fisherfaces utiliza análisis de discriminación lineal (LDA), que funciona reduciendo la dimensionalidad de la imagen para encontrar las mejores características que permitan el reconocimiento. Tiene una buena tasa de reconocimiento, es más baja que la tasa de efectividad que eigenfaces. Con una tasa de efectividad del 97% y una tasa de error del 2.5% para eigenfaces contra una tasa de efectividad del 94% y una tasa de error del 50.5% para fisherfaces, se concluye que para este proyecto, utilizar la técnica de eigenfaces los resultados son mejores para la detección de rostros.

(Krithika y col. 2017) desarrollaron un sistema para analizar en imágenes, el comportamiento de los alumnos en entornos de aprendizaje, mediante la detección del rostros y análisis de rasgos faciales.

(López y col. 2016) crearon EmoRemSys (Emotional Recommender System) es un sistema de recomendación que tiene como objetivo hacer recomendaciones de contenido educativo, permitiéndole al usuario optimizar el tiempo de búsqueda de material de apoyo en sus necesidades académicas. El sistema consta de 3 etapas en las cuales se distribuyen las tareas y funcionalidades. En la etapa 1. se encuentra la interfaz gráfica desarrollada en Html5, Css3 y JavaScript con la que interactúa el usuario con el sistema. La etapa 2. está formada por 2 módulos, el primer módulo contiene la API SkyBiometry que permite obtener los datos so-

bre la imagen de un rostro, el segundo módulo contiene la API Apache Mahout y esta se encarga de procesar los datos obtenidos por el primer módulo. En la etapa 3. contiene los repositorios donde se encuentran los contenidos educativos con los que trabaja EmoRemSys.

SkyBiometry es la herramienta que se utiliza para detectar rostros del usuario en distintos ángulos, ubica los ojos, nariz, boca y otros puntos del rostro. Comprueba si el usuario está sonriendo, tiene los ojos abiertos, los labios cerrados o tiene lentes. Otras de las funciones de esta API es determinar el sexo y la edad del usuario.

Para evaluar la precisión de la API se utilizó la base de datos Radboud Faces Database (Langner y col. [2010](#)), la cual contiene un conjunto de imágenes con rostros de 67 modelos, hombre y mujeres de tez blanca, de nacionalidad Marroquí y Holandesa, cada modelo con 8 expresiones emocionales. Los resultados de la evaluación de la base de datos Radboud, tiene una precisión del 100 % para predecir el sentimiento a través de una fotografía.

2.1. Enfoques para la detección de rostros

No existe una taxonomía de los métodos de detección de rostros. Los métodos suelen mezclarse y superponerse. En esta investigación se discuten dos criterios de clasificación. El primer criterio, diferencia entre distintos tipos de escenarios y dependiendo de los diferentes escenarios pueden ser necesarios diferentes enfoques. El segundo criterio divide los algoritmos de detección en cuatro categorías.

2.1.1. Primer criterio: Detección según el escenario.

Entorno controlado: las fotografías o frames se toman bajo condiciones controladas, como luz, fondo, ángulo. Se pueden utilizar técnicas simple de detección de bordes para detectar rostros (Louban [2009](#)).

Imágenes en color: los colores de piel se pueden utilizar para detectar rostros. Esta detección puede debilitarse con cambios en las condiciones de iluminación. El color de la piel se puede presentar en tonalidades muy claras a muy oscuras. No es fácil establecer una tonalidad de color piel. Sin embargo, (Liu y Peng [2010](#)) desarrollaron un algoritmo robusto de detección de rostros basado en el color de la piel.

Imágenes en movimiento: los videos en tiempo real usan la detección de rostros para localizar rostros en movimiento. Actualmente la mayoría de los sistemas comerciales tienen esta función de detectar rostros en video. La detección de rostros en video es un problema latente que busca mejorar los resultados de detección con el mejor rendimiento posible (Nechyba y col. [2007](#)).

2.1.2. Segundo criterio: métodos de detección divididos en categorías

Los métodos de detección se dividen en cuatro categorías. Dichas categorías se pueden superponer, por lo que un algoritmo puede pertenecer a más de una categoría (Yang y col. [2002](#)).

Las categorías se clasifican de la siguiente manera (Yang y col. 2002):

- **Métodos basados en el conocimiento:** métodos basados en reglas que codifican nuestro conocimiento de los rostros humanos.
- **Métodos invariantes a características:** estos algoritmos intentan encontrar características invariantes de un rostros a pesar de su ángulo o posición en que se encuentren.
- **Métodos de coincidencia de plantillas:** Estos algoritmos, comparan las imágenes de entrada con patrones almacenados de rostros o características.
- **Métodos basados en apariencia:** Un método de coincidencia de plantillas cuya base de datos de patrones se aprende a partir de un conjunto de imágenes de entrenamiento.

A continuación se describiran los métodos mencionados:

Métodos basados en el conocimiento.

Estos métodos utilizan el conocimiento del rostro humano y lo traducen un conjunto de reglas. Por ejemplo un rostro suele tener dos ojos simétricamente y el área de ojos tiende a ser más oscura que el área de las mejillas. Los rasgos faciales podrían estar en la distancia entre los

ojos o la diferencia de intensidad de color entre el área de los ojos y la zona inferior. Una de las desventajas de estos métodos es la dificultad de construir un conjunto de reglas apropiado, de lo contrario podrían surgir muchos falsos positivos si las reglas fueran demasiado generales. Una solución a esta desventaja es construir métodos jerárquicos basados en el conocimiento para superar estos problemas. (Han y col. 1997) desarrollaron uno de los primeros algoritmos basado en este método.

El método basado en la morfología del rostro humano se divide en 6 pasos (Han y col. 1997):

- I. Se realiza un proceso de segmentación encontrando los píxeles análogos a los ojos y se eliminan los píxeles no deseados de la imagen.
- II. Se considera cada segmento análogo del ojo como candidato de uno de los ojos.
- III. Se ejecuta un conjunto de reglas para determinar el par de ojos.
- IV. Una vez seleccionados los ojos, el algoritmo calcula el área del rostro como un rectángulo. Los rostros potenciales se normalizan a una orientación y tamaño fijo.
- V. Las regiones del rostro se verifican utilizando una red neuronal de retropropagación.
- VI. Finalmente, se aplica una función de costo para realizar la selección final.

Para este método, se reporta una tasa de efectividad del 94%, incluso en fotografías con múltiples rostros.

Comparación de plantillas

Los métodos de coincidencia de plantillas intentan encontrar una plantilla estándar de un rostro. Un rostro se puede dividir en ojos, contornos faciales, nariz y boca. También se puede construir un modelo por medio de las aristas del rostro. Una de las limitaciones principales de estos métodos es que solo permiten rostros frontales y totales, no parciales. Otras plantillas representan el rostro como una silueta, en estas plantillas se utiliza el brillo y la oscuridad de las regiones faciales. En ambos casos los patrones estándar se comparan con las imágenes de entrada para detectar rostros. Variaciones en pose, escala o forma hacen que los resultados en la detección de rostro sean deficientes.

- **Eigenfaces:** (Sirovich y Kirby [1987](#)) desarrollaron un método utilizando Análisis de Componentes Principales (PCA). Este enfoque representa un rostro como un sistema de coordenadas. Se le denomina eigenpictures a los vectores que componen el sistema de coordenadas. Años más tarde (Turk y Pentland [1991](#)) desarrollaron un algoritmo basado en eigenfaces.
- **Redes neuronales:** las redes neuronales se han empleado para diversos tipos de reconocimiento como lo es el reconocimiento de patrones, reconocimiento de objetos, reconocimiento de caracteres, entre otros más. (Rowley y col. [1998](#)) implementaron redes neuronales para aprender patrones faciales y no faciales. (Sung [1996](#)) utilizó un enfoque diferente al implementar redes neuronales, para encontrar una función discriminante para clasificar patrones utilizando medidas de distancia. (Raphaël y col. [1997](#)) intentaron encontrar un límite óptimo entre imágenes faciales y no faciales, con

un enfoque distinto que utiliza un modelo generativo restringido.

- **Máquinas de soporte vectorial (SVM):** las máquinas de soporte vectorial son clasificadores lineales que maximizan el margen entre el hiperplano de decisión y las muestras del conjunto de entrenamiento. Un hiperplano óptimo debería minimizar el error de clasificación de los patrones de prueba invisibles. (Osuna y col. [1997](#)) implementaron este clasificador por primera vez para la detección de rostros.

2.2. Enfoques de detección de rostros

2.2.1. Enfoques geométricos.

Los métodos basados en características realizan el análisis de las propiedades y la geometría del rostro, como áreas, distancias y ángulos entre elementos de la cara. PCA (Análisis de Componentes Principales), eigenfaces y fisherfaces. Estas técnicas basadas en características geométricas dan importancia a la forma estructural de componentes faciales como la nariz, la boca y los ojos (Mehta y col. [2018](#)).

Existen algoritmos que utilizan este enfoque, por ejemplo un enfoque de modelo 3D transformable puede utilizar puntos característicos o texturas, (Blanz y Vetter [2003](#)) presentan un método para el reconocimiento facial a través de variaciones de pose, poses frontales a poses de perfil, y a través de una gama de iluminaciones, sombras y reflejos. El modelo aprende a partir de un conjunto de escaneos 3D texturizados de cabezas humanas.



Figura 2.1: Metodología para la detección de rostros basado en el enfoque geométrico)

Fuente: Imagen propia

2.2.2. Enfoque de Aprendizaje de Máquina

Este enfoque se basa en la apariencia, donde se consideran atributos como intensidades, valores de píxeles e histogramas. Después de un entrenamiento extenso con la ayuda de conjuntos de datos preetiquetados, se aplican técnicas de aprendizaje automático para detectar caras (Mehta y col. [2018](#)).



Figura 2.2: Metodología para la detección de rostros basado en enfoque aprendizaje de máquina

Fuente:Imagen propia

2.2.3. Enfoques holísticos.

Los enfoques holísticos intentan identificar los rostros como lo hace un humano, a través de poca información. Algunos algoritmos siguen esta idea y procesan los rasgos faciales de forma independiente, en estos algoritmos no se toma en cuenta la relación entre los rasgos o la relación de un rasgo con todo el rostro. Algunos enfoques tratan de deducir las características más relevantes, (Nixon [1985](#)) en su trabajo de investigación utiliza las características de los ojos.

2.3. Detección de rostros mediante clasificadores en cascada y características de Haar.

El método de detección de objetos mediante clasificadores en cascada basados en características de Haar propuesto por (Viola y Jones [2001](#)) en su artículo “Rapid Object Detection using a Boosted Cascade of Simple Features”. El cual consiste en un método clásico de detección de rostros (Ma y Bai [2016](#)).

Dicho método consta de 4 etapas (Adouani y col. [2019](#)):

1. Características similares a Haar para la extracción de características.
2. Imagen integral para calcular rápidamente las características.
3. Adaboost para seleccionar características potenciales.
4. Clasificador en cascada para descartar las no caras.

El método tiene un enfoque basado en el aprendizaje automático donde se entrena una función en cascada a partir de imágenes positivas y negativas. Las imágenes positivas corresponden a imágenes que contienen el objeto a detectar, mientras que las negativas son las imágenes que no contienen el objeto a detectar. Posteriormente este clasificador es utilizado para detectar los objetos en otras imágenes.

Para realizar una detección de rostros, lo primero que se necesita, son imágenes positivas e imágenes negativas para entrenar el clasificador. Para extraer las características del clasificador, se utilizan las funciones de Haar. Cada característica es un valor único que se obtiene al restar la suma de los píxeles del rectángulo blanco de la suma de píxeles del rectángulo negro.

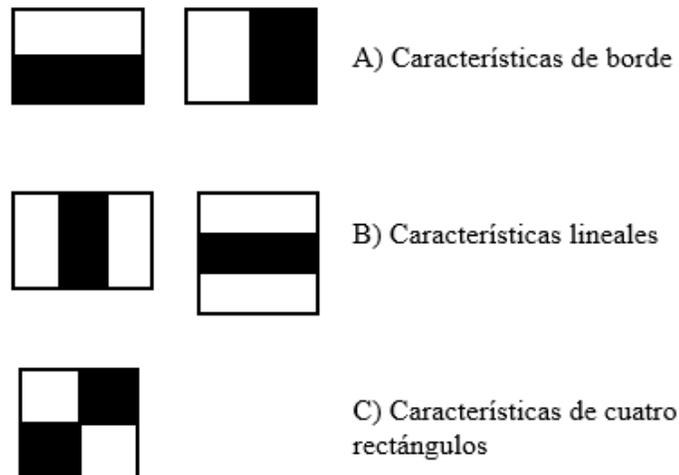


Figura 2.3: Funciones de Haar

Fuente: Imagen propia basada en (Viola y Jones [2001](#))

Se utilizan todos los tamaños y ubicaciones posibles de cada kernel para calcular las características, una ventana de 24x24 da como resultado más de 160000 funciones. Para calcular cada una de las características

de forma rápida se introduce la imagen integral, esto reduce los cálculos para un pixel dado a una operación que involucra solo cuatro píxeles.

La mayoría de las características que se calculan son irrelevantes, se implementa el algoritmo Adaboost para seleccionar las mejores. Para cada característica se encuentra el mejor umbral que clasifica los rostros en positivos y negativos. Se seleccionan las características que tienen la tasa de error mínimo. Al inicio a cada imagen se le asigna el mismo peso, después de cada clasificación se incrementan los pesos de las imágenes mal clasificadas, se vuelve a realizar el proceso, calculando nuevas tasas de error y nuevos pesos. El proceso continúa hasta que se logre la precisión requerida, la tasa de error o se obtenga el número requerido de características.

El clasificador final es la suma ponderada de los clasificadores débiles. Se le conoce como clasificadores débiles porque por sí solos no pueden clasificar la imagen, pero en conjunto forma un clasificador fuerte.

OpenCV proporciona un método de entrenamiento (Cascade Classifier Training) o modelos previamente entrenados, que se pueden leer usando el método `cv::CascadeClassifier::load`. Los modelos previamente entrenados se encuentran en la carpeta de datos en la instalación de OpenCV (Opencv.org [2020](https://www.opencv.org)).

Capítulo 3

Metodología

La metodología implementada en este trabajo de investigación se basa en la propuesta de (Viola y Jones [2001](#)). Esta metodología se divide en seis etapas, como se muestra en la Figura 3.1. En la primera etapa se recibe la imagen de entrada y se aplica el preprocesamiento. En la segunda etapa, se produce una transformación de la imagen anterior en una nueva imagen llamada imagen integral. La tercera etapa consiste en la extracción de características (feature) mediante filtros Haar, con las características obtenidas de la etapa anterior. El proceso continúa con la cuarta etapa donde se realiza el entrenamiento del algoritmo Adaboost. En la quinta etapa, un clasificador en cascada clasifica las características. Finalmente, se realiza la detección de rostros y se obtienen sus métricas de desempeño.

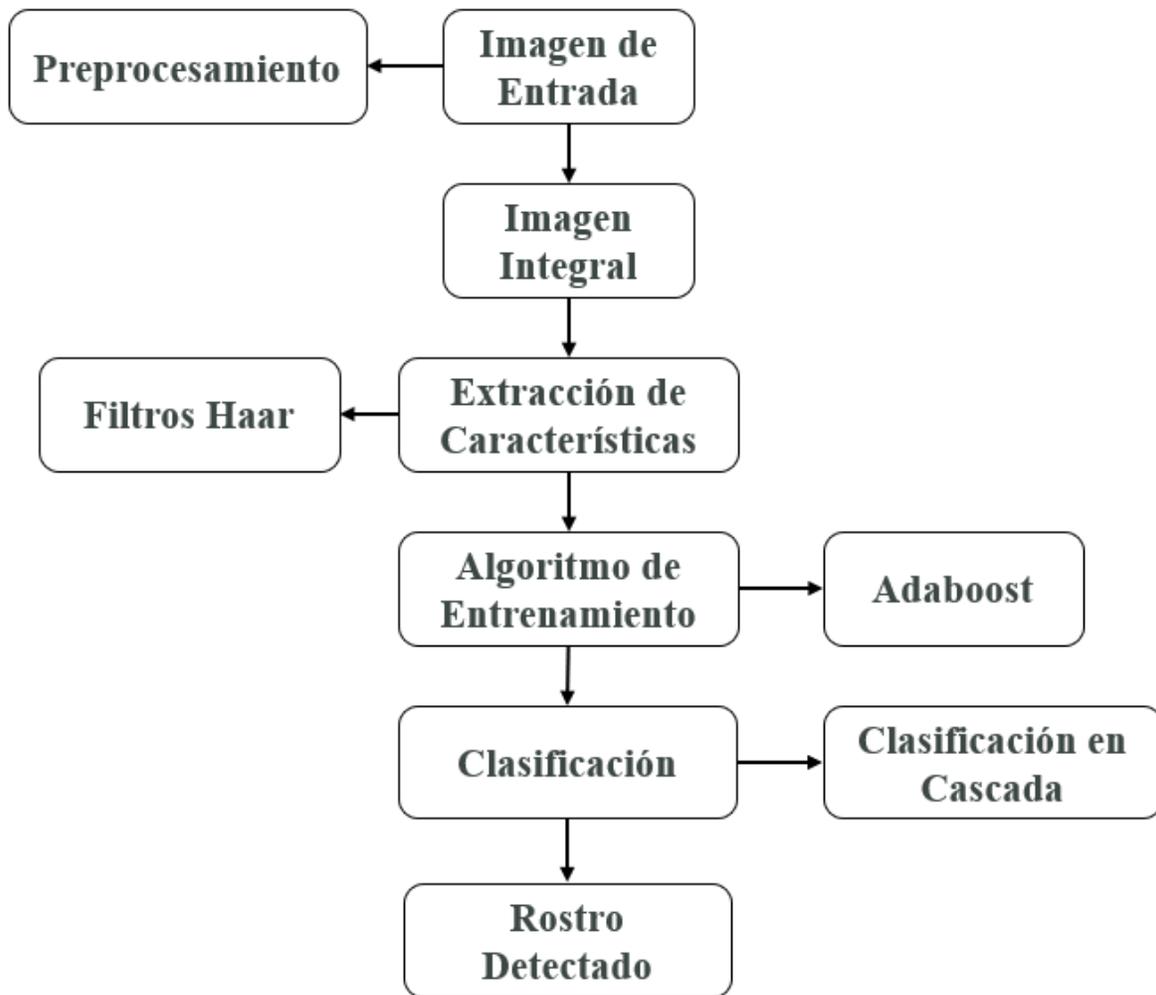


Figura 3.1: Metodología para la detección de rostros.

Fuente: Imagen propia

3.1. Construcción del dataset

La base de datos total consta de 2200 imágenes de las cuales 1,100 son positivas y 1,100 negativas. Para las imágenes positivas, utilizamos varias bases de datos disponibles en internet y, además, se recopilamos otras imágenes positivas de sesiones de video llamadas de instituciones

de educación superior. Para estas imágenes los rostros fueron recortados individualmente, considerando el rostro total, parcial, frontal o alguna otra posición, y fueron nombrados consecutivamente. Con este procedimiento se generaron 400 imágenes positivas. Para ampliar el número de muestras, se recopilan imágenes positivas de otras bases de datos publicadas y de acceso libre.

Las bases de datos utilizadas son :

LFWcrop Face Dataset (Sandipan 2018)

La base de datos consta de 1071 imágenes a escala de grises en formato .png con una resolución de 64 x 64 píxeles, el conjunto de datos contiene imágenes de rostros de hombres y mujeres. De esta base de datos se seleccionan 400 imágenes, para el proceso de selección se aplicaron los criterios de, eliminar imágenes repetidas, imágenes dañadas e imágenes con mala calidad.

Unipython Dataset (Unipython.com 2017)

Esta base de datos consta de 180 imágenes en escala de grises en formato .jpg con una resolución de 350 x 350 píxeles. Las imágenes son de hombre y mujeres las cuales pueden estar expresando alguna estado emocional (asco, enfado, feliz, miedo, sorpresa, tristeza o neutro). De esta base de datos se seleccionan 100 imágenes, para el proceso de selección se aplicaron los criterios de, eliminar imágenes repetidas, imágenes dañadas e imágenes con mala calidad.

Mahdi Rezaei Dataset (Rezaei 2013)

Esta base de datos consta de 200 imágenes positivas y 200 imágenes negativas, para las imágenes positivas son imágenes de hombres y mujeres, en ángulos frontales a color en formato .bmp con una resolución de 318 x 442 píxeles. Las imágenes negativas son imágenes a escala de grises en formato .jpg con una resolución de 640 x 480.

COCO Common Objects in Context (Cocodataset.org 2020)

Las imágenes negativas se obtienen de COCO Dataset. Una base de datos que consta de 5,000 imágenes a color, en formato .jpg y su tamaño varía de 250 píxeles a 640 píxeles, de las cuales se seleccionan 900 y se seleccionan sólo imágenes que no contengan el objeto a identificar (rostros).



Figura 3.2: Imágenes positivas.

Fuente: Imagen propia



Figura 3.3: Imágenes negativas.

Fuente: Imagen propia

Las figuras 3.2 y 3.3 muestran las imágenes positivas y las imágenes negativas respectivamente, ambos conjuntos de datos preprocesados, en los siguientes puntos se describen los procesos que se llevaron a cabo.

3.2. Imagen

Una imagen es una representación de dos dimensiones (bidimensional) de una imagen a través de una matriz numérica en el sistema binario (unos y ceros), esta puede ser definida por la siguiente función:

$$f(x, y) \quad (3.1)$$

Donde (x, y) son las coordenadas espaciales (plano) y la amplitud de la función f en algún par de coordenadas (Gonzalez y Woods [1992](#)).

(Kumar y Verma [2010](#)) clasifican las imágenes en tres tipos:

Imagen binaria

Imagen que en sus píxeles únicamente contienen valores 0 y 1, interpretados como blanco y negro respectivamente o también se puede utilizar cualquier otra combinación de colores.



Figura 3.4: Imagen binaria.

Fuente:

Imagen en escala de grises

Este tipo de imágenes también son conocidas como imágenes de intensidad o nivel de grises. Estas imágenes contienen valores que van desde $[0,1]$ hasta $[0,65535]$ dependiendo de la profundidad de bits.



Figura 3.5: Imagen escala de grises.

Fuente:

Imagen en color verdadero

También se le conocen como imagen RGB, en este tipo de imágenes cada píxel se especifica por la intensidad de sus componentes o canales correspondientes RGB (Rojo, Verde, Azul). Para matrices simples o dobles su rango de valores es $[0,1]$. El tipo de datos normal para una imagen es uint8, esto indica un número entero presentado en 8 bits. Es decir, $2^8 = 256$ valores que se distribuyen en el rango de $[0, 255]$ para cada píxel. Para uint16 indica un número entero presentado por 16 bits, $2^{16} = 65536$ valores en un rango de $[0, 65535]$ para cada píxel.



Figura 3.6: Imagen a color.

Fuente:

3.3. Pre-procesamiento

Conversión de imagen RGB a imagen a escala de grises

En esta etapa de pre-procesamiento, si la imagen de entrada está en formato RGB, se procede a realizarle una conversión a escala de grises, con la finalidad de facilitar el procesamiento, la extracción de características, el almacenamiento de datos y reducción en la complejidad computacional (Raveendran y col. [2018](#)).

La conversión se realiza mediante la suma de los componentes RGB de cada píxel y se divide entre la cantidad de componentes, en este caso son 3 componentes de corresponden a Red, Green, y Blue. A continuación se muestra la representación en su ecuación matemática (Urueña y col. [2011](#)).

$$Grey_{(x,y)} = \frac{R_{(x,y)} + G_{(x,y)} + B_{(x,y)}}{3} \quad (3.2)$$

Normalización

Por normalización hacemos referencia a tener una cierta independencia de las propiedades de la imagen como el brillo y contrastes.

La finalidad de aplicar un procesamiento de normalización de histogramas en la imagen es, corregir imágenes demasiado oscuras o excesivamente claras.

Este proceso se representa con la siguiente ecuación matemática (Universidad de la República [2003](#)):

$$N(x, y) = \frac{(N^0 Niveles - 1)}{(max(I) - min(I))} \cdot I(x, y) - min(I) \quad (3.3)$$

Sea $I(x, y)$ la imagen de entrada

Donde:

- $I(x, y)$, nivel de gris de la imagen en la coordenada (x, y) .
- $min(I), max(I)$: mínimo y máximo nivel de gris en la imagen respectivamente.
- $N(x, y)$, nivel de gris de la imagen normalizada en la coordenada (x, y) .

Todas las imágenes se someten a un procesamiento previo de conversión de color a escala de grises y normalización del histograma. Para ello

se utilizaron de bibliotecas OpenCV en lenguaje Python. En esta línea de código con el método `cv2.imread` se carga la imagen.

```
img = cv2.imread('/path/image.jpg')
```

En la siguiente línea del código, convertimos la imagen RGB a escala de grises con el método `cv2.COLOR_BGR2GRAY`.

```
img_gray = cv2.cvtColor(img,cv2.COLOR_BGR2GRAY)
```

La siguiente línea de código con el método `cv2.NORM_MINMAX` normalizamos los niveles del histograma con parámetros de `[0, 255]`.

```
img_norm = cv2.normalize(img_gray,None,0,255,cv2.NORM_MINMAX)
```

3.4. Imagen Integral

La imagen integral o también llamada como tabla de área sumada, es una herramienta que se usa cuando se tiene una función que transforma desde píxeles hasta números reales $f(x, y)$, y se requiere calcular la suma de una función sobre una región rectangular de la imagen (Bradley y Roth [2007](#)).

La suma se puede calcular en tiempo lineal por rectángulo, calculando el valor de la función píxel por píxel inicialmente. Sin embargo, la imagen integral permite calcular la suma sobre múltiples ventanas rectangulares superpuestas.

Esta imagen permite extraer de forma rápida características a diferentes escalas, contiene la suma de los píxeles de la parte superior e izquierda de la imagen (Guevara y col. [2008](#)).

Para realizar el calculo de la imagen integral, se almacena en cada ubicación $I(x, y)$, la suma de todos términos $f(x, y)$ a la izquierda y arriba del píxel (x, y) .

Para cada píxel se utiliza la siguiente ecuación matemática y se realiza de forma lineal (Bradley y Roth [2007](#)).

$$I(x, y) = f(x, y) + I(x - 1, y) + I(x, y - 1) - (x - 1, y - 1) \quad (3.4)$$

En la figura 3.5 se muestra el cálculo de una imagen integral, Una vez obtenida la imagen integral, podemos calcular en tiempo constante, la suma de la función para cualquier rectángulo con la esquina superior izquierda (x_1, y_1) y la esquina superior derecha (x_2, y_2) , con la siguiente ecuación matemática.

$$\sum_{x=x_1}^{x_2} \sum_{y=y_1}^{y_2} f(x, y) = I(x_2, y_2) - I(x_2, y_1 - 1) - I(x_1 - 1, y_2) + I(x_1 - 1, y_1 - 1) \quad (3.5)$$

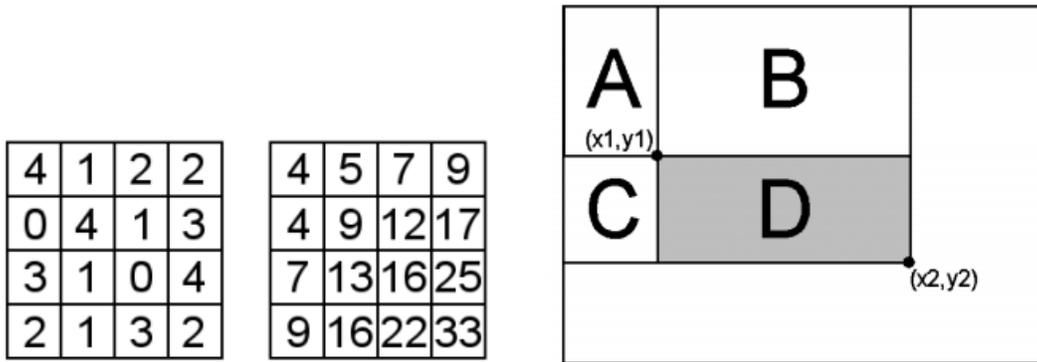


Figura 3.7: Cálculo de la imagen integral.

Fuente: Bradley y Roth [2007](#)

En la figura 3.5 muestra la entrada de los valores de una imagen simple, posteriormente como segunda imagen tenemos la imagen integral calculada, por último utilizando la imagen integral se realiza la suma de $f(x, y)$ sobre el rectángulo D, aplicando la ecuación (3.5), esto equivale a calcular la suma de sobre los rectángulos:

$$(A + B + C + D) - (A + B) - (A + C) + A \quad (3.6)$$

3.5. Extracción de Características Haar

Geraci y col. [1990](#) definen la extracción de características como un paso importante en el reconocimiento de patrones, en el cual las medidas u observaciones son procesadas, para encontrar atributos que son usados para asignar los objetos a una clase determinada. Las características en las imágenes se extraen al aplicar funciones que permitan la representación y descripción de la imagen de interés (patrones).

En este trabajo de investigación la extracción de características se realiza aplicando filtros Haar sobre la imagen. Estos filtros se calculan

sobre la imagen integral, para ello recorren toda la imagen de arriba hacia abajo y de izquierda a derecha en todas sus escalas posibles tanto horizontal como vertical, cada posición y escala posible corresponde a una característica de Haar.

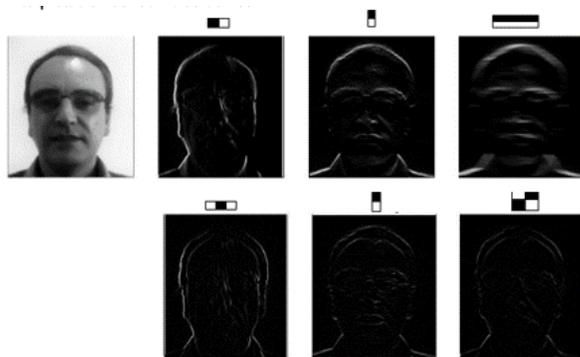


Figura 3.8: Filtros Haar.

Fuente: coursera.com, 2020

En la figura se muestra como los filtros Haar hacen una codificación con diferencia de intensidades, generando características con variaciones de contornos, puntos y líneas.

3.6. Entrenamiento del Algoritmo AdaBoost

Boosting es un algoritmo cuyo propósito es encontrar una hipótesis fuerte utilizando hipótesis simples o débiles. Adaboost es una versión mejorada de refuerzo, este algoritmo funciona ejecutando un algoritmo de aprendizaje débil en varias distribuciones de los datos de entrenamiento y luego combinando los clasificadores producidos por el aprendizaje débil en un solo clasificador fuerte (Freund, Iyer y col. 2003). Debido a su alta tasa de efectividad, rápido desempeño y baja complejidad en su implementación, lo convierten en uno de los más populares y efectivos en

el área de visión por computadora y reconocimiento de patrones (Viola, Jones y col. [2001](#)).

AdaBoost es un algoritmo que se clasifica como un algoritmo de enfoque de aprendizaje automático (machine learning), se basa en crear una regla de predicciones altamente precisas, combinando varias reglas de predicciones relativamente débiles e inexactas (Schapire [2013](#)).

AdaBoost fue el primer algoritmo de boosting implementado por (Freund y Schapire [1997](#)), actualmente sigue siendo uno de los algoritmos más utilizados y estudiados en diversos áreas de aplicación. El algoritmo funciona ejecutando repetidamente un algoritmo de aprendizaje débil en varias distribuciones sobre los datos de entrenamiento, y luego se combinan los clasificadores producidos por el aprendizaje débil en un clasificador compuesto (Freund, Schapire y col. [1996](#)).

El algoritmo de AdaBoost utiliza todo el conjunto completo de entrenamiento para entrenar a aquellos clasificadores débiles, donde las muestras de entrenamiento están ponderadas en cada iteración y crea un clasificador robusto que aprende de los errores de los clasificadores débiles.

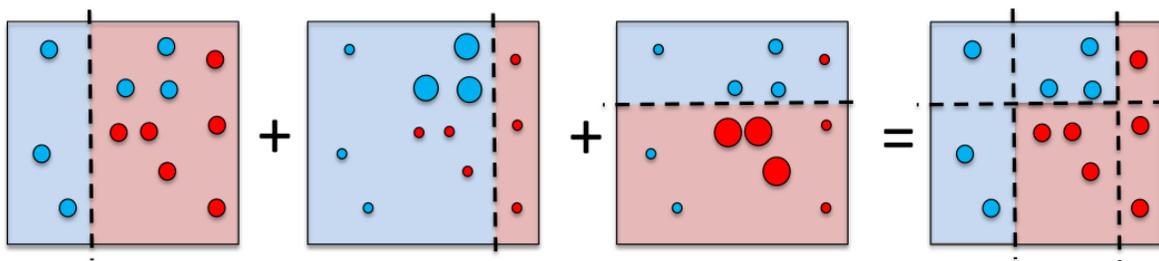


Figura 3.9: Funcionamiento del algoritmo AdaBoost.

Fuente: Imagen propia basada en (Marsh [2016](#))

En la imagen anterior representa un conjunto de entrenamiento de dos clases diferentes círculos rojos y círculos azules, a todas las muestras del conjunto de entrenamiento se les asigna el mismo peso. En la primer iteración se traza una frontera de decisión sobre el conjunto de entrenamiento, el cual intenta clasificar las muestras de las dos clases. En una segunda iteración se asignan pesos más grandes a las muestras clasificadas erróneamente y se disminuyen los pesos de las muestras clasificadas correctamente. En la tercera iteración la frontera de decisión se centrará en las muestras que tienen pesos más grandes y nuevamente se asigna un peso mayor a las muestras mal clasificadas. En este ejemplo el proceso solo consta de tres iteraciones por lo que el resultado final es la combinación de los clasificadores débiles y dando como resultado un clasificador robusto, como se observa en la Figura 3.4.

A continuación se muestra el pseudocódigo del algoritmo AdaBoost:

1. Ajuste del vector de peso w para que los pesos sean uniformes, donde: $\sum_i w_i = 1$.
2. Para j en las iteraciones de boosting m , se realiza lo siguiente:
 - a) Entrena un clasificador débil ponderado: $C_j = \text{train}(X, y, w)$.
 - b) Predice etiquetas de clase: $\hat{y} = \text{predict}(C_j)$
 - c) Calcula la tasa de error ponderado: $\epsilon = w \cdot (\hat{y} \neq y)$.
 - d) Calcula el coeficiente: $\alpha_j = 0.5 \log \frac{1 - \epsilon}{\epsilon}$.
 - e) Actualiza pesos: $w := w \times \exp(-\alpha_j, \times \hat{y} \times y)$.
 - f) Normaliza los pesos para sumar a 1: $w := w / \sum_i w_i$.
3. Calcula la predicción final: $\hat{y}(\sum_{j=1}^m (\alpha_j \times \text{predict}(C_j, X))) > 0$.

3.7. Clasificación en Cascada

La base principal para detección de rostros son las características de Haar. Estas características no utilizan los valores de intensidad, utilizan el cambio de los valores de contrastes entre grupos de píxeles de rectángulos adyacentes, estas variaciones de contrastes se utilizan para determinar las áreas claras y oscuras relativas. Las características de Haar se forman de dos o tres grupos adyacentes con variaciones de contrastes, estas características de Haar tienen la propiedad de ser escalables fácilmente, disminuyendo o aumentando el tamaño de los grupos de píxeles a examinar. El objetivo de este proceso es permitir que las funciones se utilicen para detectar los rostros de varios tamaños (P. I. Wilson y John Fernandez [2006](#)).

Calcular una característica puede ser eficiente y rápido, no factible cuando se tiene que calcular las características de una subventana de 24x24, dando lugar a más de 180,000 posibles características. Sin embargo solo se necesita una pequeña cantidad de funciones para determinar si existe un rostro en la subventana analizada (P. Wilson y Fernandez [2005](#)).

Como se menciona anteriormente solo se necesita una pequeña cantidad de esas características para determinar si una subventana contiene un rostro. (Menezes y col. [2004](#)). El objetivo de este proceso es seleccionar las características que distinguen a un rostro, si una subventana no contiene características que definan un rostro, son eliminadas. Posteriormente todas las subventanas que no fueron eliminadas se analizan en busca de más características que corresponda a un rostro. Dicho proceso continúa hasta alcanzar la tasa de detección deseada.

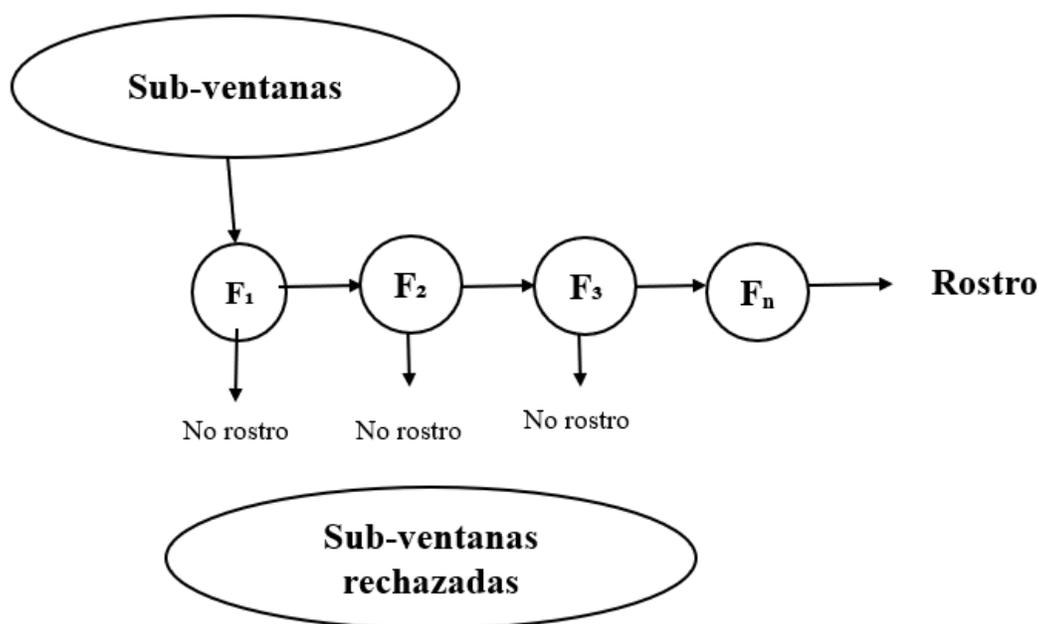


Figura 3.10: Etapas del clasificador en cascada.

Fuente: Imagen propia basada en (Cuimei y col. [2017](#))

En la imagen anterior se muestra el funcionamiento del clasificador en cascada, cada nodo es un árbol múltiple de clasificadores potenciados, entrenados para rechazar todo aquello que no corresponda a un rostro humano.

3.8. Métricas de Evaluación

Tasa de verdaderos positivos

La tasa de verdaderos positivos (TPR, también llamada sensibilidad) se calcula como $TP / TP + FN$. TPR es la probabilidad de que un resultado positivo real dé positivo.

Tasa de verdaderos negativos

La tasa de verdaderos negativos (TNR, también llamada especificidad), es la probabilidad de que un resultado negativo real dé un resultado negativo. Se calcula como $TN / (TN + FP)$.

Recall

Recall es la relación $TP / (TP + FN)$. La recuperación es intuitivamente la capacidad del clasificador para encontrar todas las muestras positivas. El mejor valor es 1 y el peor valor es 0.

Precisión equilibrada

Precisión equilibrada en cuestiones de clasificación binaria y multi-clase para abordar conjuntos de datos desequilibrados. Se define como el promedio de Recall obtenido en cada clase. El mejor valor es 1 y el peor valor es 0 cuando se establece en Falso. Se calcula como $(TPR + TNR) / 2$.

Capítulo 4

Experimentación y Resultados

4.1. Creación del clasificador en cascada

El clasificador en cascada se crea en base al artículo de (Rezaei [2013](#)), que proporciona las herramientas necesarias y un tutorial detallado paso a paso para crear el archivo .xml.

El kit de herramientas se encuentra disponible en:
<https://www.cs.auckland.ac.nz/~m.rezaei/Tutorials/Haar-Training.zip>

El proceso se divide en los siguientes pasos:

I. **Recopilación de imágenes de entrenamiento positivas y negativas.**

Se adquieren las imágenes de la base de datos previamente creada, que contiene 1100 imágenes positivas y 1100 imágenes negativas.

Las imágenes positivas son aquellas que contienen el objeto a detectar, en este caso particular, las imágenes que contienen rostros humanos, y las imágenes negativas son aquellas que no contienen el objeto a detectar.

II. Organización de imágenes negativas.

Las imágenes negativas son colocadas en la carpeta ...\\training\\negative. Dentro de la misma carpeta se encuentra un archivo por lotes llamado `create_list.bat`, al ejecutar el archivo se genera un archivo de texto con el nombre `bg.txt`, el cual se necesita más adelante y contiene el nombre más la extensión de las imágenes negativas.

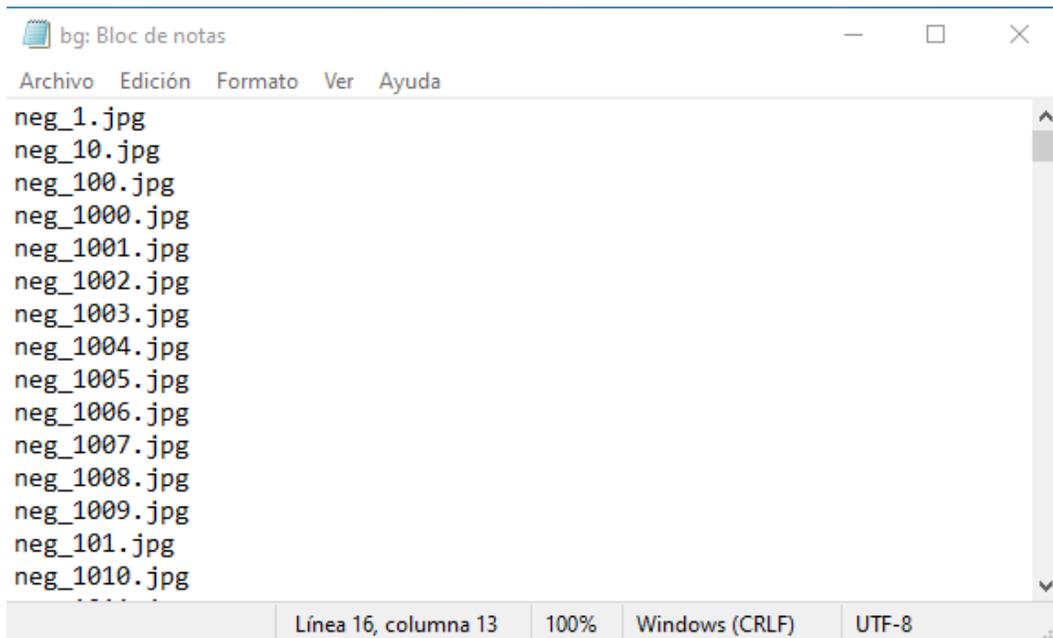


Figura 4.1: Archivo de texto `bg.txt`.

Fuente: Imagen propia

III. Recortar y marcar imágenes positivas

Como tercer paso se realiza el marcado del área donde se encuentran los rostros en las imágenes positivas, para este proceso los autores comparten la herramienta `objectmarker.exe` (Rezaei 2013), el archivo se encuentra en la carpeta `...\training\positive`. Al ejecutar el archivo se abren dos ventanas, en la primera ventana Fig.4.2 se muestra la imagen positiva, con el rostro marcado sobre un rectángulo, en la segunda ventana se muestra Fig.4.3 la información de imagen.

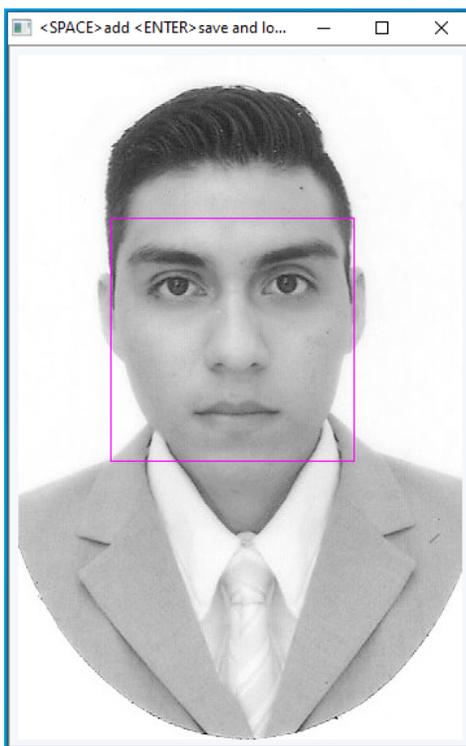


Figura 4.2: Marcado del área del rostro en imagen positiva

Fuente: Imagen propia

La información que se muestra en la segunda ventana Fig.4.3 corresponde al nombre de la imagen, el número de rostros que hay en la imagen, en este caso en particular solo hay 1 rostro por cada

imagen, la siguiente información son las coordenadas x y y donde se encuentra el rostro y por último los valores de *width* y *height* corresponde al ancho y alto del área rectangular donde se encuentra ubicado el rostro.

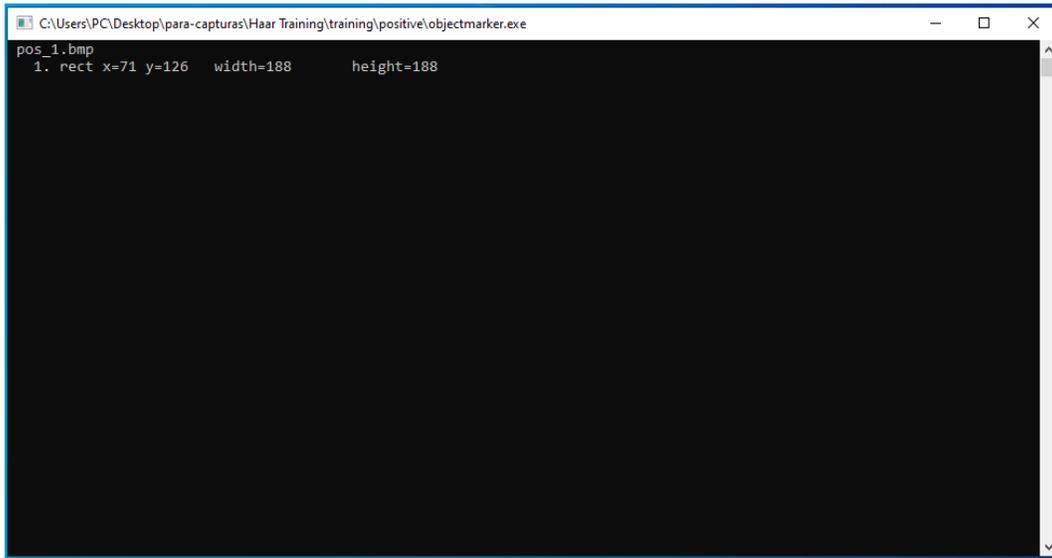


Figura 4.3: Captura de información de imágenes positivas

Fuente: Imagen propia

El proceso anterior se realizar para todas las imágenes positivas, al finalizar el proceso en la misma carpeta se genera un archivo de texto con el nombre `info.txt` y contiene la información concentrada del proceso anterior.

La estructura del archivo de texto `info.txt` queda de la siguiente forma:

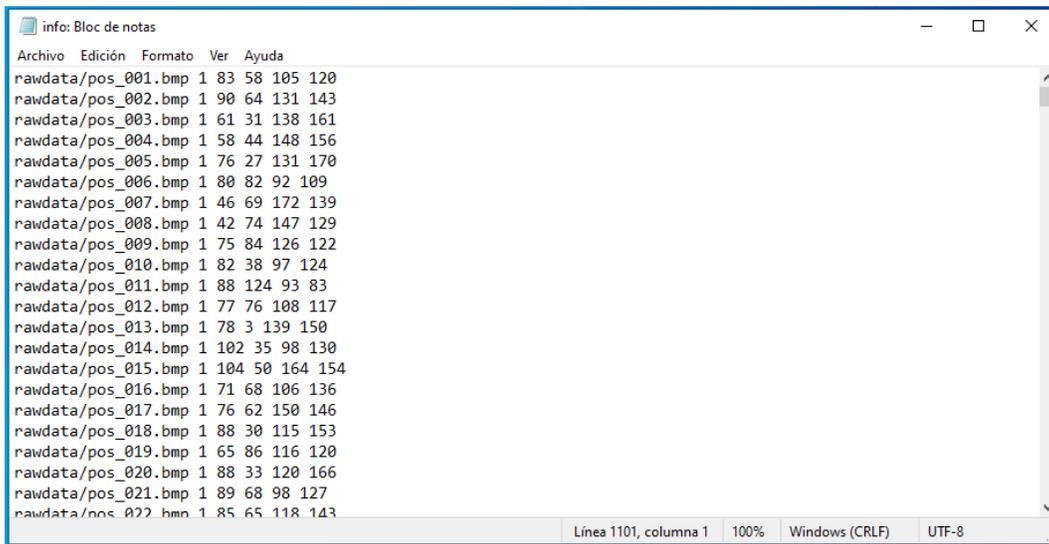


Figura 4.4: Archivo de texto info.txt

Fuente: Imagen propia

IV. Vector de imágenes positivas

En la carpeta ../training/ se encuentra un archivo llamado `samples_creation.bat`.

El archivo contiene lo siguiente:

```
createsamples.exe -info positive/info.txt -vec vector/facevector.vec -num 1100 -w 24 -h 24
```

Parámetros principales:

<code>-info positive/info.txt</code>	Ruta del archivo de imágenes positivas.
<code>-vec vector/facevector.vec</code>	Ruta del archivo vectorial de salida
<code>-num 1100</code>	Número de archivos positivos
<code>-w 24</code>	Ancho del objeto
<code>-h 24</code>	Altura del objeto

El archivo por lotes carga el archivo de tecto `info.txt`, empaqueta las imágenes del objeto en un archivo vectorial con el nombre `facevector.vec`.

Después de ejecutar el archivo por lotes, se genera el archivo `facevector.vec` en la carpeta `../training/vector`.

V. Entrenamiento Haar

En la misma carpeta que comparten los autores `../training/` se encuentra un archivo por lotes llamado `haartraining.bat` que contiene lo siguiente:

```
haartraining.exe -data cascades -vec vector/vector.vec -bg
negative/bg.txt -npos 1100 -nneg 1100 -nstages 15 -mem 1024
-mode ALL -w 24 -h 24 -nonsym
```

<code>-data cascades</code>	Ruta de almacenamiento de clasificadores.
<code>-vec data/vector.vec</code>	Ruta del archivo vectorial.
<code>-bg negative/bg.txt</code>	Ruta del archivo de imágenes negativas.
<code>-npos 1100</code>	Número de imágenes positivas.
<code>-nneg 1100</code>	Número de imágenes negativas.
<code>-nstages 15</code>	Número de etapas de entrenamiento.
<code>-mem 1024</code>	Cantidad de memoria asignada en MB.
<code>-mode ALL</code>	
<code>-w 24 -h 24</code>	Tamaño de la imagen.
<code>-nonsym</code>	Objetos no simétricos horizontalmente.

El archivo `haartraining.exe` recopila un nuevo conjunto de muestras negativas para cada etapa. Utiliza la información de las etapas anteriores para determinar cuáles de las muestras candidatas están mal clasificadas.

El entrenamiento finaliza, cuando la proporción de muestras clasificadas erróneamente con respecto a las muestras de candidatos, es menor que la condición de paro.

```

C:\WINDOWS\system32\cmd.exe
Chosen number of splits: 0
Total number of splits: 0
Tree Classifier
Stage
+---+
| 0 |
+---+
0
Parent node: 0
*** 1 cluster ***
POS: 203 204 0.995098
NEG: 203 0.482185
BACKGROUND PROCESSING TIME: 0.70
Precalculation time: 5.02
+---+---+---+---+---+---+
| N | %SMP | F | ST.THR | HR | FA | EXP. ERR |
+---+---+---+---+---+---+
| 1 | 100% | - | -0.437264 | 1.000000 | 1.000000 | 0.216749 |
+---+---+---+---+---+---+
| 2 | 100% | + | -0.927444 | 1.000000 | 1.000000 | 0.216749 |
+---+---+---+---+---+---+
| 3 | 100% | - | -0.888436 | 0.995074 | 0.857143 | 0.194581 |
+---+---+---+---+---+---+

```

Figura 4.5: Proceso de entrenamiento.

Fuente: Imagen propia

VI. Creación del archivo .xml

Una vez finalizado el proceso de entrenamiento, se ejecuta el archivo por lotes `convert.bat` ubicado en la carpeta `../training/`. Este proceso genera el archivo `myhaar.xml`, el clasificador en cascada que se utiliza para la detección de rostros.

4.2. Ajuste de parámetros

Los siguientes experimentos tienen como objetivo encontrar los mejores parámetros para cada factor de escala (`scaleFactor`) y vecinos míni-

mos (minNeighbors), para los clasificadores OpenCV y el clasificador MyHaar creado en esta investigación.

El experimento de prueba del modelo se realiza con 300 imágenes, de las cuales 150 son positivas y 150 imágenes son negativas. Estas imágenes no se encuentran en la base de datos con la que se realizó el clasificador. Los parámetros utilizados son scaleFactor y minNeighbors. El primero es un parámetro que especifica cuánto se reduce el tamaño de la imagen en cada escala de imagen.

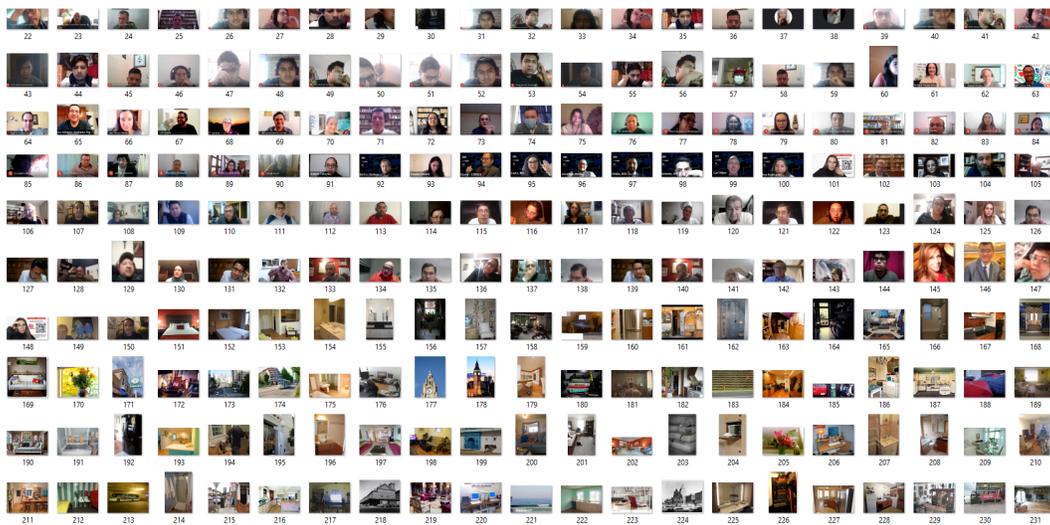


Figura 4.6: Subconjunto de la base de datos de prueba.

Fuente: Imagen propia

Los valores de scaleFactor utilizados oscilan entre [1.1, 1.9]. El segundo es un parámetro que especifica cuántos vecinos debe tener cada rectángulo candidato para retenerlo. A medida que el parámetro aumenta, se obtiene menos detección pero la efectividad de detectar un rostro aumenta. Los valores que toma son enteros en un rango de [1, 10].

4.3. Resultados de la experimentación

Al ajustar los parámetros y seleccionar los mejores para cada uno de los clasificadores a comparar, se obtienen los siguientes resultados.

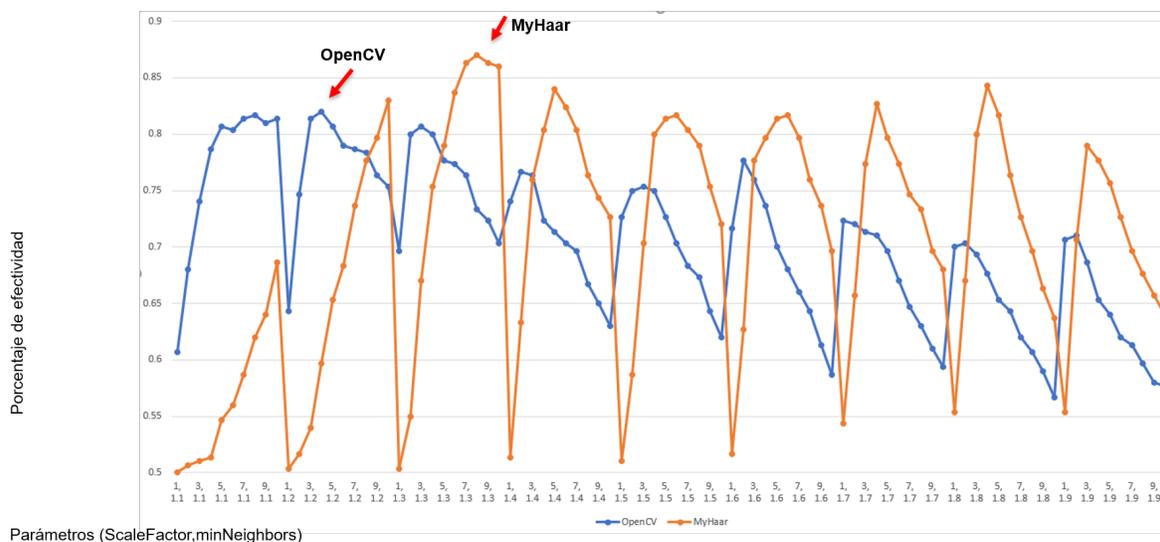


Figura 4.7: Comparación de OpenCV vs MyHaar.

Fuente: Imagen propia

En la Figura 4.1 se muestra la gráfica con los resultados obtenidos de los experimentos con el mejor ajuste de parámetros para cada clasificador. Se puede observar que gran parte de los resultados favorecen al clasificador desarrollado en esta investigación 'MyHaar', con respecto al clasificador de rostros frontales de OpenCV.

Los mejores resultados para la detección de rostros del clasificador "frontalface_default" de OpenCV son:

```
scaleFactor: 1.2, minNeighbors: 4.
```

Con estos parámetros se obtienen los siguientes resultados para 'frontalface_default':

	Positivo	Negativo
Rostro	105	9
No rostro	45	141

Los mejores parámetros para el clasificador creado en esta investigación 'MyHaar' son:

`scaleFactor: 1.3, minNeighbors: 8.`

Con estos parámetros se obtienen los siguientes resultados para 'MyHaar':

	Positivo	Negativo
Rostro	122	11
No rostro	28	139

4.4. Comparación de clasificadores

La siguiente tabla muestra los resultados de las métricas de medición mencionadas anteriormente, obtenidos en los experimentos realizados. Se obtiene una mayor tasa de efectividad con el clasificador 'MyHaar' realizado en este proyecto de investigación con respecto al clasificador 'frontalface_default' creado por OpenCV.

Cuadro 4.1: Comparación de clasificadores OpenCV y MyHaar

	TPR	TNR	Recall	BA
OpenCV	0.70	0.94	[0.94, 0.70]	82%
MyHaar	0.81	0.92	[0.92, 0.81]	87%

4.5. Discusión

Durante los primeros días de la detección de rostros, muchos de los métodos desarrollados se diseñaron con un enfoque de clasificador de conjuntos, como las populares los clasificadores en cascada y filtros de Haar. Este tipo de enfoques emplea características artesanales obtenidas de una ventana deslizante sobre una imagen, para detectar regiones faciales sobre ella (Minaee y col. [2021](#)).

Este tipo de modelo sobresale cuando la tarea implica la detección de objetos que pueden estar bien representados con características similares a manchas, como las que se encuentran comúnmente en los rostros frontales.

Los clasificadores en cascada y filtros de Haar o algoritmos de ejecución similares tienen varios inconvenientes para el reconocimiento facial, como el manejo de imágenes con objetos con múltiples escalas de varios órdenes de magnitud diferentes, variaciones en poses, oclusión facial, expresiones emocionales, iluminación y otras variantes de imagen (Minaee y col. [2021](#)). Además, este algoritmo tiene un límite superior en la mejora que puede lograr en el problema de detección de rostros, incluso cuando se dispone de conjuntos de datos más grandes.

En los últimos 10 años, los algoritmos de aprendizaje profundo han mejorado considerablemente el rendimiento de la detección de rostros a

un rendimiento similar al humano mediante el uso de redes neuronales convolucionales (CNN), Cascade-CNN y, más recientemente, arquitecturas como CNN recurrente, modelos de detección de disparo único como el algoritmo You Only Look Once (YOLO) y Feature Pyramid Networks como RetinaFace, por mencionar algunos (Minaee y col. 2021).

Estos modelos de aprendizaje profundo tienen ventajas considerables sobre los modelos clásicos, como permitir obtener características complejas, mejorar con conjuntos de datos más grandes, buenos para representar características de borde para contornos de formas, tener un tiempo de detección más corto (Murillo y col. 2017), muy parecido a la precisión de un humano (Minaee y col. 2021).

Capítulo 5

Conclusiones y trabajos futuros

Podemos concluir que el rendimiento del clasificador diseñado y desarrollado en esta investigación tiene una tasa de efectividad superior al 5% para la detección de rostros con respecto al clasificador OpenCV.

Con los resultados obtenidos podemos determinar que, es posible mejorar los resultados del clasificador de OpenCV, para la detección de rostros en procesos educativos (rostros frontales, laterales o parciales), creando un clasificador propio utilizando machine learning, por lo tanto se cumple la hipótesis planteada al inicio de este documento, de igual manera los objetivos plateados fueron alcanzados.

Por lo tanto, el trabajo futuro implica el uso de estos algoritmos de última generación para la detección de reconocimiento facial en entornos educativos en línea.

Es necesario hacer una nota final con respecto a las preocupaciones que surgen de las tecnologías de reconocimiento facial automático. Estos se relacionan con el desarrollo de conductas autoritarias, derechos civi-

les comprometidos, el uso indebido de información biométrica, conductas racistas e intolerantes dadas por conjuntos de datos racialmente sesgados y sesgados por el color de la piel y la etnia (Andrejevic y Selwyn [2020](#)). Por lo tanto, la recolección de datos en los entornos escolares debe llevarse a cabo con el pleno consentimiento de los padres y mediante un proceso muy riguroso que garantice la desidentificación de las personas, para minimizar el posible uso indebido de la información y la segregación.

Agradecimiento

Queremos agradecer a CONACYT- México por la beca otorgada No. CVU 999976 que apoyó esta investigación.

Apéndice A

Código fuente.

Importación de librerías.

```
import cv2
import numpy as np
from google.colab.patches import cv2_imshow
import matplotlib.pyplot as plt
from PIL import Image
import math
import random
import itertools
import pandas as pd

from sklearn.metrics import balanced_accuracy_score
from sklearn.metrics import recall_score
from sklearn.metrics import precision_recall_fscore_support
from sklearn.metrics import confusion_matrix
```

Importación del Clasificador OpenCV

```
from google_drive_downloader import GoogleDriveDownloader as gd

gd.download_file_from_google_drive(file_id='1DJY-9SC0k5Bxwvqd8jjP1BolqcgmH-uU',
dest_path='./CascadeClassifier.zip', unzip=True)
```

Importación del Clasificador MyHaar

```
from google_drive_downloader import GoogleDriveDownloader as gd

gd.download_file_from_google_drive(file_id='1gNmuBSPXi04v2-U-R2zgxUf4ayMUWVle',
dest_path='./myhaar-1100.zip', unzip=True)
```

Importación del Dataset de prueba

```
from google_drive_downloader import GoogleDriveDownloader as gd

gd.download_file_from_google_drive(file_id='1gUUxFSfHCYK4BE053hC_cWYbTR9Vily1',
dest_path='./proc-toring.zip', unzip=True)
```

Experimentos con el clasificador OpenCV

```
face_cascade = cv2.CascadeClassifier(
'/content/CascadeClassifier/data/haarcascades/haarcascade_frontalface_default.xml')

unos = np.ones(150)
ceros = np.zeros(150)

y_true = np.append(unos,ceros, axis=None)
result = []

vecinos = [1,2,3,4,5,6,7,8,9,10]
escalas = [1.1,1.2,1.3,1.4,1.5,1.6,1.7,1.8,1.9]

for escala in escalas:

    for vecino in vecinos:
        tp = 0
        fn = 0
        fp = 0
        tn = 0

    y_pred = []

    for i in range(1,301):
        ba = 0
```

```
x = i
x = str(x)
img = cv2.imread('/content/proc-toring/'+ x + '.jpg')
img_gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
img_norm = cv2.normalize(img_gray, None, 0, 255, cv2.NORM_MINMAX)

faces = face_cascade.detectMultiScale(img_norm, scaleFactor=escala, minNeighbors=vecino)

if len(faces) >0 and i<=150:
    tp = tp + 1
    y_pred.append(1)
elif len(faces)==0 and i<=150:
    fn = fn + 1
    y_pred.append(0)
elif len(faces)>0 and i>150:
    fp = fp + 1
    y_pred.append(1)
else:
    tn = tn + 1
    y_pred.append(0)

for (x, y, w, h) in faces:
    img = cv2.rectangle(img, (x, y), (x + w, y + h), (0, 255, 0), 2)

    roi_gray = img_gray[y:y + h, x:x + w]
    roi_color = img[y:y + h, x:x + w]

ba = balanced_accuracy_score(y_true, y_pred)
print('BA: ' + str(ba))
result.append(ba)

re = recall_score(y_true, y_pred, average = None)
print('RE: ' + str(re))

f1 = precision_recall_fscore_support(y_true, y_pred, average = None)
print('F1: ' + str(f1))

print('-----')
```

Experimentos con el clasificador MyHaar

```
face_cascade = cv2.CascadeClassifier('/content/myhaar-1100.xml')

unos = np.ones(150)
ceros = np.zeros(150)

y_true = np.append(unos,ceros, axis=None)
result = []

vecinos = [1,2,3,4,5,6,7,8,9,10]
escalas = [1.1,1.2,1.3,1.4,1.5,1.6,1.7,1.8,1.9]

for escala in escalas:

    for vecino in vecinos:
        tp = 0
        fn = 0
        fp = 0
        tn = 0

        y_pred = []

        for i in range(1,301):
            ba = 0
            x = i
            x = str(x)
            img = cv2.imread('/content/proc-toring/'+ x + '.jpg')
            img_gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
            img_norm = cv2.normalize(img_gray,None,0,255,cv2.NORM_MINMAX)

            faces = face_cascade.detectMultiScale(img_norm, scaleFactor=escala, minNeighbors=vecino)

            if len(faces) >0 and i<=150:
                tp = tp + 1
                y_pred.append(1)
            elif len(faces)==0 and i<=150:
```

```
        fn = fn + 1
        y_pred.append(0)
    elif len(faces)>0 and i>150:
        fp = fp + 1
        y_pred.append(1)
    else:
        tn = tn + 1
        y_pred.append(0)

    for (x, y, w, h) in faces:
        img = cv2.rectangle(img, (x, y), (x + w, y + h), (0, 255, 0), 2)

        roi_gray = img_gray[y:y + h, x:x + w]
        roi_color = img[y:y + h, x:x + w]

    ba = balanced_accuracy_score(y_true, y_pred)
    print('BA: ' + str(ba))
    result.append(ba)

    re = recall_score(y_true, y_pred, average = None)
    print('RE: ' + str(re))

    f1 = precision_recall_fscore_support(y_true, y_pred, average = None)
    print('F1: ' + str(f1))

    print('-----')
```

Liga de acceso al proyecto en Google Colab:

https://colab.research.google.com/drive/1_RhApKORW1mKi6NGOtHiKnLHBJsqm9dM?usp=sharing

Apéndice B

**Publicación en el libro
Online Learning
Analytics editado por
Jay Liebowitz.**

Este tema de investigación forma parte del libro, el cual conforma el capítulo 12.

Book Description

In our increasingly digitally enabled education world, analytics used ethically, strategically, and with care hold the potential to help more and more diverse students be more successful on higher education journeys than ever before. Jay Liebowitz and a cadre of the fields best "good trouble" makers in this space help shine a light on the possibilities, potential challenges, and the power of learning together in this work.—Mark David Milliron, Ph.D., Senior Vice President and Executive Dean of the Teachers College, Western Governors University

Due to the COVID-19 pandemic and aftereffects, we have begun to enter the "new normal" of education. Instead of online learning being an "added feature" of K–12 schools and universities worldwide, it will be incorporated as an essential feature in one's education. There are many questions and concerns from parents, students, teachers, professors, administrators, staff, accrediting bodies, and others regarding the quality of virtual learning and its impact on student learning outcomes.

Online Learning Analytics is conceived on trying to answer the questions of those who may be skeptical about online learning. Through better understanding and applying learning analytics, we can assess how successful learning and student/faculty engagement, as examples, can contribute towards producing the educational outcomes needed to advance student learning for future generations. Learning analytics has proven to be successful in many areas, such as the impact of using learning analytics in asynchronous online discussions in higher education. To prepare for a future where online learning plays a major role, this book examines such as:

- Data insights for improving curriculum design, teaching practice, and learning
- Scaling up learning analytics in an evidence-informed way
- The role of trust in online learning.

Online learning faces very real philosophical and operational challenges. This book addresses areas of concern about the future of education and learning. It also energizes the field of learning analytics by presenting research on a range of topics that is broad and recognizes the humanness and depth of educating and learning.

Figura B.1: Descripción del libro.

Fuente: Imagen propia

Table of Contents

- 1 Leveraging Learning Analytics for Assessment and Feedback**
Dirk Ifenthaler and Samuel Greiff
- 2 Desperately Seeking the Impact of Learning Analytics in Education at Scale: Marrying Data Analysis with Teaching and Learning**
Olga Viberg and Åke Grönlund
- 3 Designing for Insights: An Evidenced-Centered Approach to Learning Analytics**
Kara N. McWilliams, Kristen Herrick, K. Becca Runyon, and Andreas Oranje
- 4 Implementing Learning Analytics at Scale in an Online World: Lessons Learned from the Open University UK**
Bart Rienties
- 5 Realizing the Potential of Learning Analytics: Reflections from a Pandemic**
Mohammad Khalil, Paul Prinsloo, and Sharon Slade
- 6 Using Learning Analytics and Instructional Design to Inform, Find, and Scale Quality Online Learning**
John Fritz, Mariann Hawken, and Sarah Shin
- 7 Democratizing Data at a Large R1 Institution: Supporting Data-Informed Decision Making for Advisers, Faculty, and Instructional Designers**
Chris Millet, Jessica Resig, and Bart Pursel
- 8 The Benefits of the 'New Normal': Data Insights for Improving Curriculum Design, Teaching Practice, and Learning**
Deborah West and Pablo Munguia
- 9 Learning Information, Knowledge, and Data Analysis in Israel: A Case Study**
Moria Levy and Ronit Nehemia
- 10 Scaling Up Learning Analytics in an Evidence-Informed Way**
Justian Knobbout and Esther van der Stappen
- 11 The Role of Trust in Online Learning**
Joanna Paliszkievicz and Edyta Skarzyńska
- 12 Face Detection with Applications in Education**
Juan Carlos Bonilla-Robles, José Alberto Hernández Aguilar, and Guillermo Santamaría-Bonfil

Figura B.2: Tabla de contenido del libro.

Fuente: Imagen propia

Chapter 12

Face Detection with Applications in Education

Juan Carlos Bonilla Robles,¹ José Alberto Hernández Aguilar,¹ Guillermo Santamaría Bonfil²

Abstract

E-learning has grown in importance, particularly nowadays under the COVID pandemic context. In this type of educational application, it is extremely useful to apply face-detection techniques to support online teachers—not only for the automation of roll call and for proctoring (supervision functions) in online assessments, but also to identify academic emotions, learning engagement, or boredom to carry out automatic adaptive tasks. In this research, we discuss the application of Haar filters and the AdaBoost classifier (Viola, 2001) for the detection of faces, in order to facilitate the counting and proctoring in online education activities. For this purpose, we analyzed 1,100 positive images (faces) and 1,100 negative images (no faces) to train a model; we obtained our own Myhaar.xml file and compared it with the default frontal .XML file of OpenCV; for this test we use

¹ Autonomous University of the State of Morelos (UAEMor), Av. Universidad 1001, Col. Chamilpa, Cuernavaca, Morelos, México

² National Council of Science and Technology—National Institute of Electricity and Clean Energy (CONACYT-INEEL), Reforma 113, Col. Palmira, Cuernavaca, Morelos, México

Figura B.3: Portada del capítulo.

Fuente: Imagen propia

Liga de la publicación del libro:

<https://www.routledge.com/Online-Learning-Analytics/Liebowitz/p/book/9781032047775>

Referencias

- Adouani, A., Henia, W. M. B. & Lachiri, Z. (2019). Comparison of Haar-like, HOG and LBP approaches for face detection in video sequences, En *2019 16th International Multi-Conference on Systems, Signals & Devices (SSD)*. IEEE.
- Andrejevic, M. & Selwyn, N. (2020). Facial recognition technology in schools: Critical questions and concerns. *Learning, Media and Technology*, *45*(2), 115-128.
- Blanz, V. & Vetter, T. (2003). Face recognition based on fitting a 3d morphable model. *IEEE Transactions on pattern analysis and machine intelligence*, *25*(9), 1063-1074.
- Bosch, N., D'Mello, S., Baker, R., Ocumpaugh, J., Shute, V., Ventura, M., Wang, L. & Zhao, W. (2015). Automatic detection of learning-centered affective states in the wild, En *Proceedings of the 20th international conference on intelligent user interfaces*.
- Bradley, D. & Roth, G. (2007). Adaptive thresholding using the integral image. *Journal of graphics tools*, *12*(2), 13-21.
- Chellappa, R., Wilson, C. L. & Sirohey, S. (1995). Human and machine recognition of faces: A survey. *Proceedings of the IEEE*, *83*(5), 705-741.

- Cocodataset.org. (2020). *COCO - Common Objects in Context*. Recuperado el 10 de diciembre de 2020, desde <https://cocodataset.org/>
- Cuimei, L., Zhiliang, Q., Nan, J. & Jianhua, W. (2017). Human face detection algorithm via Haar cascade classifier combined with three additional classifiers, En *2017 13th IEEE International Conference on Electronic Measurement & Instruments (ICEMI)*. IEEE.
- Elias, T. (2011). Learning analytics. *Learning*, 1-22.
- Freund, Y., Iyer, R., Schapire, R. E. & Singer, Y. (2003). An efficient boosting algorithm for combining preferences. *Journal of machine learning research*, 4(Nov), 933-969.
- Freund, Y. & Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of computer and system sciences*, 55(1), 119-139.
- Freund, Y., Schapire, R. E. Y col. (1996). Experiments with a new boosting algorithm, En *icml*. Citeseer.
- Geraci, A. Y col. (1990). IEEE Standard Glossary of Image Processing and Pattern Recognition Terminology. *Institute of Electrical and Electronics Engineers (IEEE) Std*, 610-4.
- Gonzalez, R. C. & Woods, R. E. (1992). Digital Image Processing Addison-Wesley. *Reading, Ma*, 2.
- Guerrero, G. G., Reyna, M. R. H. & Mendoza, M. E. C. (s.f.). Reconocimiento Facial a través de Cámaras de Video Vigilancia.
- Guevara, M. L., Echeverry, J. D. & Uruena, W. A. (2008). Detección de rostros en imágenes digitales usando clasificadores en cascada. *Scientia et technica*, 1(38).
- Gutierrez, E. J., Duque, L. A. & Cano, S. (2017). Midiendo la Experiencia de Usuario en Niños a Través del Reconocimiento de las Emociones.

- Han, C.-C., Liao, H.-Y. M., Yu, G.-J. & Chen, L.-H. (1997). Fast face detection via morphology-based pre-processing, En *International Conference on Image Analysis and Processing*. Springer.
- Krithika, L., Venkatesh, K., Rathore, S. & Kumar, M. H. (2017). Facial recognition in education system, En *IOP Conference Series: Materials Science and Engineering*. IOP Publishing.
- Kumar, T. & Verma, K. (2010). A Theory Based on Conversion of RGB image to Gray image. *International Journal of Computer Applications*, 7(2), 7-10.
- Langner, O., Dotsch, R., Bijlstra, G., Wigboldus, D. H., Hawk, S. T. & Van Knippenberg, A. (2010). Presentation and validation of the Radboud Faces Database. *Cognition and emotion*, 24(8), 1377-1388.
- Liu, Q. & Peng, G.-z. (2010). A robust skin color based face detection algorithm, En *2010 2nd International Asia Conference on Informatics in Control, Automation and Robotics (CAR 2010)*. IEEE.
- López, M. B., Montes, A. J. H., Ramirez, R. V., Hernández, G. A., Cabaña, R. Z. & Estrada, M. L. B. (2016). EmoRemSys: Sistema de recomendación de recursos educativos basado en detección de emociones. *RISTI-Revista Ibérica de Sistemas e Tecnologias de Informação*, (17), 80-95.
- Louban, R. (2009). Image processing of edge and surface defects. *Berlin Heidelberg*.
- Ma, S. & Bai, L. (2016). A face detection algorithm based on Adaboost and new Haar-Like feature, En *2016 7th IEEE International Conference on Software Engineering and Service Science (ICSESS)*. IEEE.
- Marsh, B. (2016). Multivariate analysis of the vector boson fusion higgs boson. *University of Missouri*, 8.

- McDaniel, B., D'Mello, S., King, B., Chipman, P., Tapp, K. & Graesser, A. (2007). Facial features for affective state detection in learning environments, En *Proceedings of the Annual Meeting of the Cognitive Science Society*.
- Mehta, D., Siddiqui, M. F. H. & Javaid, A. Y. (2018). Facial emotion recognition: A survey and real-world user experiences in mixed reality. *Sensors*, 18(2), 416.
- Menezes, P., Barreto, J. C. & Dias, J. (2004). Face tracking based on haar-like features and eigenfaces. *IFAC Proceedings Volumes*, 37(8), 304-309.
- Minaee, S., Luo, P., Lin, Z. & Bowyer, K. (2021). Going Deeper Into Face Detection: A Survey. *arXiv preprint arXiv:2103.14983*.
- Murillo, P. C. U., Moreno, R. J. & Arenas, J. O. P. (2017). Comparison between cnn and haar classifiers for surgical instrumentation classification. *Contemporary Engineering Sciences*, 10(28), 1351-1363.
- Nechyba, M. C., Brandy, L. & Schneiderman, H. (2007). Pittpatt face detection and tracking for the CLEAR 2007 evaluation, En *Multi-modal Technologies for Perception of Humans*. Springer.
- Nixon, M. (1985). Eye spacing measurement for facial recognition, En *Applications of Digital Image Processing VIII*. International Society for Optics y Photonics.
- Opencv.org. (2020). *OpenCV: Cascade Classifier*. Recuperado el 26 de mayo de 2020, desde https://docs.opencv.org/3.4/db/d28/tutorial_cascade_classifier.html
- Osuna, E., Freund, R. & Girosit, F. (1997). Training support vector machines: an application to face detection, En *Proceedings of IEEE computer society conference on computer vision and pattern recognition*. IEEE.

- Raphaël, F., Olivier, B. & Daniel, C. (1997). A constrained generative model applied to face detection. *Neural Processing Letters*, 5(2), 11-19.
- Raveendran, S., Edavoor, P. J., YB, N. K. & Vasantha, M. (2018). Design and Implementation of Reversible Logic based RGB to Gray scale Color Space Converter, En *TENCON 2018-2018 IEEE Region 10 Conference*. IEEE.
- Rezaei, M. (2013). Creating a cascade of haar-like classifiers: Step by step. *Aplikasi Pendeteksian Ras kucing dengan mendeteksi wajah kucing dengan metode viola jones*.
- Rowley, H. A., Baluja, S. & Kanade, T. (1998). Neural network-based face detection. *IEEE Transactions on pattern analysis and machine intelligence*, 20(1), 23-38.
- Sandipan. (2018). *EigenFaces and A Simple Face Detector with PCA/SVD in Python*. Recuperado el 10 de agosto de 2020, desde <https://sandipanweb.wordpress.com/2018/01/06/eigenfaces-and-a-simple-face-detector-with-pca-svd-in-python/>
- Schapire, R. E. (2013). Explaining adaboost, En *Empirical inference*. Springer.
- Singh, D., Hadke, R. S., Khonde, S. S., Patil, V. D., Kamnani, M. & Ingle, M. R. (2014). Attendance monitoring using face recognition. *International Journal of Computer Science and Mobile Computing*, 3, 633-636.
- Sirovich, L. & Kirby, M. (1987). Low-dimensional procedure for the characterization of human faces. *Josa a*, 4(3), 519-524.
- Suárez, Ó. D. (2000). Introducción al reconocimiento de caras. *Buran*, 39-42.

- Sung, K.-K. (1996). Learning and example selection for object and pattern detection.
- Turk, M. & Pentland, A. (1991). Eigenfaces for Recognition: Journal of Cognitive Neuroscience.
- Unipython.com. (2017). *Detección de sentimientos y emociones, usando marcas faciales*. Recuperado el 18 de septiembre de 2021, desde <https://www.kaggle.com/ciplab/real-and-fake-face-detection>
- Universidad de la República, I. (2003). *Normalización de la imagen*. Recuperado el 14 de enero de 2021, desde <https://iie.fing.edu.uy/investigacion/grupos/gti/timag/trabajos/2003/huellas/html/node8.html>
- Urueña, W. A., Osorio, J. A. C. & Vargas, J. A. M. (2011). Técnicas alternativas para la conversión de imágenes a color a escala de grises en el tratamiento digital de imágenes. *Scientia et Technica*, 1(47), 207-212.
- Viola, P. & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features, En *Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition. CVPR 2001*. IEEE.
- Viola, P., Jones, M. Y col. (2001). Robust real-time object detection. *International journal of computer vision*, 4(34-47), 4.
- Wechsler, H. (2009). *Reliable face recognition methods: system design, implementation and evaluation* (Vol. 7). Springer Science & Business Media.
- Wentzel, K. R. (2009). Peers and academic functioning at school.
- Wilson, P. & Fernandez, J. (2005). Establishing a face recognition research environment using open source software, En *ASEE Gulf-Southwest Annual Conference*.

-
- Wilson, P. I. & Fernandez, J. [John]. (2006). Facial feature detection using Haar classifiers. *Journal of Computing Sciences in Colleges*, 21(4), 127-133.
- Yang, M., Kriegman, D. & Ahuja, N. (2002). Detecting faces in images: A survey. *IEEE Transactions on Pattern Analysis & Machine Intelligence*.

Cuernavaca, Morelos a 26 de octubre del 2021.

DR. AUGUSTO RENATO PÉREZ MAYO
SECRETARIO DE INVESTIGACIÓN Y POSGRADO DE LA FCAeI
PRESENTE

En mi carácter de revisor de Tesis, hago de su conocimiento que he leído con interés la tesis para obtener el grado de la **Maestría en Optimización y Cómputo Aplicado**, del estudiante **Juan Carlos Bonilla Robles**, con matrícula **10034117**, con el título “**Detección de rostros con aplicaciones en la educación**”. por lo cual, me permito informarle que después de una revisión cuidadosa de dicha tesis, concluyo que el trabajo se caracteriza por el establecimiento de objetivos académicos pertinentes y una metodología adecuada para su logro. Además construye una estructura coherente y bien documentada, por lo cual considero que los resultados obtenidos contribuyen al conocimiento del tema tratado.

Con base en los argumentos precedentes me permito expresar mi **VOTO APROBATORIO** por lo que de mi parte no existe inconveniente para que el estudiante continúe con los trámites que esta Secretaría de Investigación y Posgrado tenga establecidos para obtener el grado mencionado.

Atentamente
Por una humanidad culta
Una universidad de excelencia

Dr. José Alberto Hernández Aguilar
Profesor - Investigador
Facultad de Contaduría Administración e Informática



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento firmado electrónicamente de conformidad con el ACUERDO GENERAL PARA LA CONTINUIDAD DEL FUNCIONAMIENTO DE LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS DURANTE LA EMERGENCIA SANITARIA PROVOCADA POR EL VIRUS SARS-COV2 (COVID-19) emitido el 27 de abril del 2020.

El presente documento cuenta con la firma electrónica UAEM del funcionario universitario competente, amparada por un certificado vigente a la fecha de su elaboración y es válido de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DE ESTADO DE MORELOS emitidos el 13 de noviembre del 2019 mediante circular No. 32.

Sello electrónico

JOSE ALBERTO HERNANDEZ AGUILAR | Fecha:2021-10-27 17:56:50 | Firmante

xKudHXO8gPMm3TVDU+GE7T1l9SGd5Q8rREkunbYJHjBxxPjAhVp2KxQutLfsXigKmkx3yIS+OzNQZEHVnH371iqwjXgN+/yRZrpANRP+LKHt4Kcl4TmRgxLftgd0MZ/qDRRePnt/
NkwGXnEoUIRptiLBdUpn/IWAPEHaHmgG4DC7HHeOnphmRTUPQczxTJFSPgDQzM97jrWQvoqpShMyrJNi116fHquBPINHoPwwO93nVc6fXwfgxNzQJrEFy0keKQsmx5XYsDzZ
Am8+zky7WoFbOfU+dnqmwovbdbmuGADpk5Vm6+UI6Unoyq393e9JcBQZaPyHrdLltzTQl4QKeA==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o
escaneando el código QR ingresando la siguiente clave:



[uvO8Bqegr](#)

<https://efirma.uaem.mx/noRepudio/WTR6bGgFJO7XWKBzGwU2aJNxu9qCyjac>



Cuernavaca, Morelos a 26 de octubre del 2021.

DR. AUGUSTO RENATO PÉREZ MAYO
SECRETARIO DE INVESTIGACIÓN Y POSGRADO DE LA FCAeI
PRESENTE

En mi carácter de revisor de Tesis, hago de su conocimiento que he leído con interés la tesis para obtener el grado de la **Maestría en Optimización y Cómputo Aplicado**, del estudiante **Juan Carlos Bonilla Robles**, con matrícula **10034117**, con el título “**Detección de rostros con aplicaciones en la educación**”. por lo cual, me permito informarle que después de una revisión cuidadosa de dicha tesis, concluyo que el trabajo se caracteriza por el establecimiento de objetivos académicos pertinentes y una metodología adecuada para su logro. Además construye una estructura coherente y bien documentada, por lo cual considero que los resultados obtenidos contribuyen al conocimiento del tema tratado.

Con base en los argumentos precedentes me permito expresar mi **VOTO APROBATORIO** por lo que de mi parte no existe inconveniente para que el estudiante continúe con los trámites que esta Secretaría de Investigación y Posgrado tenga establecidos para obtener el grado mencionado.

Atentamente
Por una humanidad culta
Una universidad de excelencia

Dr. Guillermo Santamaría Bonfil
Investigador
Instituto Nacional de Electricidad y Energías Limpias



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento firmado electrónicamente de conformidad con el ACUERDO GENERAL PARA LA CONTINUIDAD DEL FUNCIONAMIENTO DE LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS DURANTE LA EMERGENCIA SANITARIA PROVOCADA POR EL VIRUS SARS-COV2 (COVID-19) emitido el 27 de abril del 2020.

El presente documento cuenta con la firma electrónica UAEM del funcionario universitario competente, amparada por un certificado vigente a la fecha de su elaboración y es válido de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DE ESTADO DE MORELOS emitidos el 13 de noviembre del 2019 mediante circular No. 32.

Sello electrónico

GUILLERMO SANTAMARÍA BONFIL | Fecha:2021-10-26 21:21:33 | Firmante

PORlkjAhL1oedCFHGZkwm+g6RHXDGwn2Gsq49DywbkRwDzfPqTMtslyDagma3pHkrJ9iwi3LHPFpfZhyMBCq7kpnZ7o+wSZVqj/XwXOZmt/qGmChGZf5JjGwPjMzS2qjxMbgio
nxH540beJ9UuYpx1+0HLOEt0W8zipYT1K3stom9C4Cuamg/v3Qa4sB7/QAugx35S6GUMSrmB4rsqs2cm7pR8qMV62fOpWaBLS1XJS/icsySgeZ8YcVHnTb4dLtUwtO0FFV5uTw
KTYEDc0ggc9jrdero7oF7DR8vlaievJgN/RaxarvXXjh4rOhi8rtklW0xvSj4PipjINvAlzQ==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o
escaneando el código QR ingresando la siguiente clave:



DFZP835kg

<https://efirma.uaem.mx/noRepudio/8miNMtYIJQT3G0cQLtPCImwOywRQaDdN>



Cuernavaca, Morelos a 26 de octubre del 2021.

DR. AUGUSTO RENATO PÉREZ MAYO
SECRETARIO DE INVESTIGACIÓN Y POSGRADO DE LA FCAei
PRESENTE

En mi carácter de revisor de Tesis, hago de su conocimiento que he leído con interés la tesis para obtener el grado de la **Maestría en Optimización y Cómputo Aplicado**, del estudiante **Juan Carlos Bonilla Robles**, con matrícula **10034117**, con el título “**Detección de rostros con aplicaciones en la educación**”. por lo cual, me permito informarle que después de una revisión cuidadosa de dicha tesis, concluyo que el trabajo se caracteriza por el establecimiento de objetivos académicos pertinentes y una metodología adecuada para su logro. Además construye una estructura coherente y bien documentada, por lo cual considero que los resultados obtenidos contribuyen al conocimiento del tema tratado.

Con base en los argumentos precedentes me permito expresar mi **VOTO APROBATORIO** por lo que de mi parte no existe inconveniente para que el estudiante continúe con los trámites que esta Secretaría de Investigación y Posgrado tenga establecidos para obtener el grado mencionado.

Atentamente
Por una humanidad culta
Una universidad de excelencia

Dr. Federico Alonso Pecina
Profesor - Investigador
Facultad de Contaduría Administración e Informática



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento firmado electrónicamente de conformidad con el ACUERDO GENERAL PARA LA CONTINUIDAD DEL FUNCIONAMIENTO DE LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS DURANTE LA EMERGENCIA SANITARIA PROVOCADA POR EL VIRUS SARS-COV2 (COVID-19) emitido el 27 de abril del 2020.

El presente documento cuenta con la firma electrónica UAEM del funcionario universitario competente, amparada por un certificado vigente a la fecha de su elaboración y es válido de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DE ESTADO DE MORELOS emitidos el 13 de noviembre del 2019 mediante circular No. 32.

Sello electrónico

FEDERICO ALONSO PECINA | Fecha:2021-10-26 14:36:00 | Firmante

xAqO54FzIOLNoJALGIQOgPdG3gi0vDzYFiwRDurMmXBVw21qyehjNjBW6QoIqmNPIUQf6fKO8aJTM8Nq9O+D7cfFtBqu5/mXX7T+e5HftjsoG6yaQ8aTXK3NfTDEs119mCFpDq78D9m0ntA9D9lv0JLd+QdUMly/++3NxgDqw99/6GqZqyDwD0WNVVWRE3P+Cr3E8Pdk42NmSueYyQrgb7Ck7DkTWtPuiG690cAEHAeG/6bN2rVLCwlcO3dUzri6SjWvHdHdlohT41kmonMwqQBJaJCwwxvLgvl0pXDD3LivcBdmF8KWW/R+kHBwAIT0FiFB3Y96uD4ViqhpKJ8Mkg==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o escaneando el código QR ingresando la siguiente clave:



[g8LUN3pak](#)

<https://efirma.uaem.mx/noRepudio/ofBPffqdoWh21UZOE9eaJ8HKrlpstUU6>





UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS



Cuernavaca, Morelos a 26 de octubre del 2021.

DR. AUGUSTO RENATO PÉREZ MAYO
SECRETARIO DE INVESTIGACIÓN Y POSGRADO DE LA FCAeI
PRESENTE

En mi carácter de revisor de Tesis, hago de su conocimiento que he leído con interés la tesis para obtener el grado de la **Maestría en Optimización y Cómputo Aplicado**, del estudiante **Juan Carlos Bonilla Robles**, con matrícula **10034117**, con el título **“Detección de rostros con aplicaciones en la educación”**. por lo cual, me permito informarle que después de una revisión cuidadosa de dicha tesis, concluyo que el trabajo se caracteriza por el establecimiento de objetivos académicos pertinentes y una metodología adecuada para su logro. Además construye una estructura coherente y bien documentada, por lo cual considero que los resultados obtenidos contribuyen al conocimiento del tema tratado.

Con base en los argumentos precedentes me permito expresar mi **VOTO APROBATORIO** por lo que de mi parte no existe inconveniente para que el estudiante continúe con los trámites que esta Secretaría de Investigación y Posgrado tenga establecidos para obtener el grado mencionado.

Atentamente
Por una humanidad culta
Una universidad de excelencia

Dr. José Crispín Zavala Díaz
Profesor - Investigador
Facultad de Contaduría Administración e Informática



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento firmado electrónicamente de conformidad con el ACUERDO GENERAL PARA LA CONTINUIDAD DEL FUNCIONAMIENTO DE LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS DURANTE LA EMERGENCIA SANITARIA PROVOCADA POR EL VIRUS SARS-COV2 (COVID-19) emitido el 27 de abril del 2020.

El presente documento cuenta con la firma electrónica UAEM del funcionario universitario competente, amparada por un certificado vigente a la fecha de su elaboración y es válido de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DE ESTADO DE MORELOS emitidos el 13 de noviembre del 2019 mediante circular No. 32.

Sello electrónico

JOSE CRISPIN ZAVALA DIAZ | Fecha:2021-10-26 21:44:09 | Firmante

blCZOKfouT9i9abwR8ssorfFi+qd9p7/r8ennJOq1RxA7XR+jeG90RViYUJEhTKj6dpQ72x+nAXUbAXUOZj5Tq3iaulnPq3KZA1/xLY3Zct1MW7z3+6j+b06BjzeJyCg4+82cbFfyLa7TZguelwUBJ0kuLY6GXCQPOrzBHQetwudXGlivP42pjtx4Pfx2ZQsXxESB1omP3zbZjApd5F2ITZ9Rz59juC584ckxZAoiKZOHPxN7rTn1F7YpTsLr0axNeibyghUCI6HDMr+sVQPSoI V93v0pw3MGkU408fEivWseG2/tyaJEROIUcTn84ent4P4h6KEp6rDut8utxpbA==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o escaneando el código QR ingresando la siguiente clave:



Vn0fMdA9D

<https://efirma.uaem.mx/noRepudio/R65sQfA0M7T6PXaHnB43Sxp1LXGAt3Hc>



Cuernavaca, Morelos a 26 de octubre del 2021.

DR. AUGUSTO RENATO PÉREZ MAYO
SECRETARIO DE INVESTIGACIÓN Y POSGRADO DE LA FCAei
PRESENTE

En mi carácter de revisor de Tesis, hago de su conocimiento que he leído con interés la tesis para obtener el grado de la **Maestría en Optimización y Cómputo Aplicado**, del estudiante **Juan Carlos Bonilla Robles**, con matrícula **10034117**, con el título “**Detección de rostros con aplicaciones en la educación**”. por lo cual, me permito informarle que después de una revisión cuidadosa de dicha tesis, concluyo que el trabajo se caracteriza por el establecimiento de objetivos académicos pertinentes y una metodología adecuada para su logro. Además construye una estructura coherente y bien documentada, por lo cual considero que los resultados obtenidos contribuyen al conocimiento del tema tratado.

Con base en los argumentos precedentes me permito expresar mi **VOTO APROBATORIO** por lo que de mi parte no existe inconveniente para que el estudiante continúe con los trámites que esta Secretaría de Investigación y Posgrado tenga establecidos para obtener el grado mencionado.

Atentamente
Por una humanidad culta
Una universidad de excelencia

Dr. Martín Gerardo Martínez Rangel
Profesor - Investigador
Facultad de Contaduría Administración e Informática



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento firmado electrónicamente de conformidad con el ACUERDO GENERAL PARA LA CONTINUIDAD DEL FUNCIONAMIENTO DE LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS DURANTE LA EMERGENCIA SANITARIA PROVOCADA POR EL VIRUS SARS-COV2 (COVID-19) emitido el 27 de abril del 2020.

El presente documento cuenta con la firma electrónica UAEM del funcionario universitario competente, amparada por un certificado vigente a la fecha de su elaboración y es válido de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DE ESTADO DE MORELOS emitidos el 13 de noviembre del 2019 mediante circular No. 32.

Sello electrónico

MARTIN GERARDO MARTINEZ RANGEL | Fecha:2021-10-28 14:12:45 | Firmante

OSw/ICdo877n20Tk2raFYTiCYVGUXzuvM1cYNSz1NDn1+5bEOWpl9Gyf1gHWV8iiqzoe75F6rpDhEdTWiwsSPPRGDS2fXcARUfRxGezzZlVwOzA2qjF7ZFT3jf7z7TeVLKytIPtjPx
dNf8F6G0hv96n0pdu5gN0CEm5jPCvAmqjIeagCCumSso8E1rGLgcuafLeLKBIX/j44QBk+beZd4MhnRWzZfe3h/WQ+59CiQTNehurGEP3OXqKzCCgLWSJq3uL/ty7oCgqN0la2t
ygNK8/YjB9ifR6NjyxM1p9R/wfRz+VqFl0o3S7gQu9NMPyo/JbLRuHpm23zj7deFEg==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o
escaneando el código QR ingresando la siguiente clave:



[rkzNdyPwc](#)

<https://efirma.uaem.mx/noRepudio/Yc1j8iOjvkfPUQ5WgNrEUGzps0IWAMAU>

