

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ingeniería en Electricidad y Computación

“Sistema de control de acceso e identificación de patrones que caractericen el comportamiento de estudiantes de nivel superior, usando técnicas de pronósticos en series de tiempo y reconocimiento facial con one-shot learning.”

PROYECTO DE TITULACIÓN

Previo la obtención del Título de:

Magister en Ciencias de Datos.

Presentado por:

Diana Vanessa Cáceres Salazar

Luis Eduardo Valencia Ibarra

GUAYAQUIL - ECUADOR

Año: 2022

DEDICATORIA

El presente proyecto se lo dedicamos a Dios, por siempre estar en cada uno de nuestros pasos, él es nuestro mejor amigo, él que nos da fuerzas para continuar y cumplir todos los objetivos que deseemos alcanzar en la vida además permitir levantarnos y seguir el camino cada vez que nos tropecemos.

A su vez de manera especial a cada miembro de nuestra familia pilar fundamental en nuestra vida porque son el motivo para salir adelante, superarnos y de esta manera se sientan orgullosos de los hijos que han criado con tanto amor y cuidado.

AGRADECIMIENTOS

Nuestros más sinceros agradecimientos a Dios por toda la fortaleza que nos brindó para sacar adelante y concluir el proyecto, al centro educativo en estudio por el apoyo con los requerimientos necesarios para llevar a cabo el proyecto integrador.

De igual manera al tutor de nuestra tesis el Ing. Miguel Realpe, Ph.D. por la retroalimentación ofrecida en todo el desarrollo del proyecto. Por último, pero no menos importante a todos nuestros compañeros con quienes se formó un equipo sólido de trabajo para poder avanzar en cada una de las materias impartidas en la maestría de ciencia de datos.

DECLARACIÓN EXPRESA

“Los derechos de titularidad y explotación, nos corresponde conforme al reglamento de propiedad intelectual de la institución; Diana Vanessa Cáceres Salazar, Luis Eduardo Valencia Ibarra y damos nuestro consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”



Diana Cáceres Salazar
Autora



Luis Valencia Ibarra
Autor

COMITÉ EVALUADOR

.....
Miguel Realpe, P.h.D.

PROFESOR TUTOR

.....
Nombre del Profesor

PROFESOR EVALUADOR

RESUMEN

El reconocimiento facial es un gran avance tecnológico utilizado en distintas áreas gracias a que ayuda a la correcta identificación de personas o cosas, este proyecto esta direccionado al reconocimiento facial en tiempo real para los alumnos de una institución de Educación Superior de Ecuador, además predice el comportamiento de llegada y salida de los alumnos específicamente con las fechas, horas de ingresos y salidas de la institución. Para su desarrollo se utilizaron diferentes técnicas entre ellas la inteligencia artificial, series de tiempo y pronósticos además de la visualización de datos, con la ayuda de programas para su correcto desarrollo como Python, RStudio y Django. Como resultado final del proyecto se obtuvo un sistema de control de acceso por reconocimiento facial, mismo que permitió generar pronósticos en series de tiempo, a partir de la caracterización del comportamiento de los estudiantes frente a los reportes de ingreso a la institución, los datos de este sistema pueden ser observados desde una cuenta de los estudiantes y una cuenta de los Administradores de la Institución. El sistema de reconocimiento facial tiene un alto porcentaje de efectividad al realizar la identificación de las personas que ingresan a la institución, lo cual permite destacar las técnicas tradicionales de la competencia interinstitucional y generar una cultura educativa que conlleve a la mejora continua.

Palabras Clave: Estudiantes, Inteligencia Artificial, Python, Reconocimiento Facial, Rstudio.

ABSTRACT

Facial recognition is a great technological advance used in different areas thanks to the fact that it helps the correct identification of people or things, this project is directed to facial recognition in real time for the students of a Higher Education institution in Ecuador, it also predicts the behavior of arrival and departure of the students specifically with the dates, times of admissions and departures from the institution. For its development, different techniques were used, including artificial intelligence, time series and forecasts, as well as data visualization, with the help of programs for its correct development such as Python, RStudio and Django. As a final result of the project, a facial recognition access control system was obtained, which allowed generating forecasts in time series, based on the characterization of the behavior of the students in front of the reports of admission to the institution, the data of This system can be observed from a student account and an Institution Administrator account. The facial recognition system has a high percentage of effectiveness in identifying the people who enter the institution, which makes it possible to highlight the traditional techniques of inter-institutional competition and generate an educational culture that leads to continuous improvement.

Keywords: *Students, Artificial Intelligence, Python, Facial Recognition, Rstudio.*

ÍNDICE GENERAL

RESUMEN.....	I
ABSTRACT.....	II
ÍNDICE GENERAL	III
ÍNDICE DE FIGURAS	VI
ÍNDICE DE TABLAS.....	VIII
CAPÍTULO 1.....	1
1. Introducción	1
1.1 Descripción del problema	2
1.2 Justificación del problema	3
1.3 Objetivos	4
1.3.1 Objetivo general.....	4
1.3.2 Objetivos específicos	4
1.4 Marco teórico.....	4
1.4.1 Reconocimiento facial.....	6
1.4.1.1 Detección de rostro en una imagen.....	8
1.4.1.2 Extracción de características de rostros.....	12
1.4.1.3 Embedding	15
1.4.1.4 Clasificación de características	15
1.4.2 Series de tiempo	16
1.4.2.1 Análisis y predicción de series de tiempo.....	17
1.4.2.2 Patrones en series de tiempo.....	17
1.4.2.3 Método de pronóstico	18
1.4.2.3.1 Redes neuronales	18
1.4.2.3.2 Métodos estadísticos de pronósticos	19
1.4.3 Estudiantes de educación superior	20

1.4.4	Software para utilizar	21
1.4.4.1	Python	21
1.4.4.2	RStudio.....	21
1.4.4.3	Django.....	22
CAPÍTULO 2.....		23
2.	Metodología	23
2.1	Reconocimiento facial y caracterización del comportamiento estudiantil mediante el control de acceso.....	24
2.1.1	Reconocimiento facial.....	27
2.1.1.1	MobileNet detección de rostro.....	28
2.1.1.2	One-Shot learning	29
2.1.1.2.1	FaceNet extracción de características	30
2.1.1.3	Cálculo de distancias	30
2.1.1.3.1	Verificación del rostro.....	31
2.1.1.3.2	Identificación del rostro	31
2.1.2	Pronóstico en series de tiempo.....	32
2.1.2.1	Análisis descriptivo de los datos en series de tiempo	35
2.1.2.2	Modelo de predicción en una serie estacional.....	38
2.1.2.3	Predicción.....	41
CAPÍTULO 3.....		43
3.	Resultados y análisis	43
3.1	Recolección de datos resultantes de reconocimiento facial	44
3.1.1	Detección facial.....	44
3.1.2	Reconocimiento facial.....	47
3.2	Recolección de los resultados de las series de tiempo.	51
3.2.1	Predicción	52

3.3 Puesta en marcha y funcionamiento del sistema de control de acceso e identificación de patrones.....	55
CAPÍTULO 4.....	62
4. Conclusiones y recomendaciones	62
4.1 Conclusiones.....	62
4.2 Recomendaciones.....	62
BIBLIOGRAFÍA	64

ÍNDICE DE FIGURAS

Figura 1.1 Bounding box de rostro	8
Figura 1.2 Proceso de comparación de dos rostros mediante FaceNet	16
Figura 2.1 Arquitectura del sistema de control de acceso	26
Figura 2.2 Estructura general de una red convolucional	27
Elaborado por: Sotaquirá, 2020.....	27
Figura 2.3 Detección del rostro en una imagen	28
Figura 2.4 Extracción del rostro desde la imagen.....	29
Figura 2.5 Extracción de características del rostro.....	30
Figura 2.6 Identificación del rostro.....	32
Figura 2.7 Datos de ingreso de estudiante sin procesar	33
Figura 2.8 Serie de tiempo con datos imputados	34
Figura 2.9 Datos de entrenamiento y prueba de la serie	35
Figura 2.10 Ingreso de un estudiante por horas durante los meses de estudio	36
Figura 2.11 Ingreso promedio de los estudiantes al edificio a o b por meses	37
Figura 2.12 Ingreso promedio de los estudiantes por carrera por meses.....	37
Figura 2.13 Método de pronóstico Naive.....	38
Figura 2.14 Método de pronóstico Seasonal Naive	39
Figura 2.15 Método de pronóstico Drift	39
Figura 2.16 Método de pronóstico ARIMA.....	40
Figura 2.17 Arquitectura de la serie de tiempo - ARIMA	42
Figura 3.1 Efectividad de la detección de rostros	45
Figura 3.2 Comparación de distancia euclidiana en modelos pre-entrenados para reconocimiento de rostros	46
Figura 3.3 Detección de rostro en una imagen.....	47
Figura 3.4 Resultados de la data.....	48
Figura 3.5 Distancia euclidiana.....	49
Figura 3.6 Identificación de rostro mediante ID	49
Figura 3.7 Identificación de rostro con nombre y apellido	50
Figura 3.8 Resultados de la data.....	51
Figura 3.9 Identificación de rostro	51
Figura 3.10 Pronóstico de ingreso del estudiante en 20 días posteriores	53

Figura 3.11 Pronóstico de ingreso del estudiante DSC00479	54
Figura 3.12 Pronóstico de ingreso del estudiante DSC00780	54
Figura 3.13 Reconocimiento facial y caracterización del comportamiento estudiantil ...	56
Figura 3.14 Identificación interna de rostro, con id, nombre y apellido	56
Figura 3.15 Login del Administrador	57
Figura 3.16 Visualizador del administrador (Pantalla parte 1)	58
Figura 3.17 Visualizador del administrador (Pantalla parte 2)	58
Figura 3.18 Login del estudiante.	59
Figura 3.19 Autenticación del estudiante en el sistema.	59
Figura 3.20 Pantalla de visualización de resultados. Predicción	60

ÍNDICE DE TABLAS

Tabla 1.1 Reconocimiento facial: ventajas y desventajas	7
Tabla 1.2 Arquitectura de MobileNet	12
Tabla 1.3 Comparación de sistemas de reconocimiento facial.....	14
Tabla 2.1 Variable del estudio	32
Tabla 3.1 Comparación de los métodos de pronóstico.....	52

CAPÍTULO 1

1. INTRODUCCIÓN

Con el pasar de los años, el reconocimiento facial se ha considerado como una de las aplicaciones más investigadas en diferentes áreas y de manera especial en la biometría, para el reconocimiento de patrones y también para el procesamiento de imágenes. Uno de los principales motivos de implementar un sistema de reconocimiento facial en la institución de educación superior es incrementar la seguridad al permitir el acceso de personas autorizadas. De manera global este tipo de técnica para la identificación de personas es utilizado en diferentes lugares como lo son aeropuertos, terminales, centros comerciales, unidades bancarias y demás. Dando un refuerzo a la seguridad con la que debe contar cada establecimiento.

El presente proyecto se basa en un sistema de control de acceso e identificación de patrones que caractericen el comportamiento de estudiantes de nivel superior, usando técnicas de pronósticos en series de tiempo y reconocimiento facial con one-shot learning.

El reconocimiento facial está dividido en tres etapas. La primera etapa realiza la detección del rostro en la imagen, es decir verificar la presencia de uno o varios rostros humano en la imagen, en la segunda etapa se realiza la extracción de características que permiten describir los rostros específicos de las personas, en la tercera etapa se genera la clasificación de las características para reconocer a las personas.

Por otro lado, para caracterizar el comportamiento de los estudiantes se utiliza series de tiempo que se enfoca en la extracción de características distintivas de los estudiantes, a partir de la información que se almacena en una la base de datos de control, la cual contiene información como: fecha, hora de ingreso, carrera del estudiante, entre otras variables. Estos patrones identificados permiten generar predicciones que involucren su socialización y beneficios que conlleven.

En la realización del proyecto se hace uso de dos bases de datos la primera que contiene las imágenes de alumnos utilizada para el reconocimiento facial y la segunda base abarca el registro de acceso de estudiantes a la institución de educación superior

correspondiente a dos periodos académicos de los años 2017 y 2018 que sirve para predecir el comportamiento de ingreso futuro de los estudiantes.

La implementación de este proyecto ayuda a la institución a mejorar la seguridad en el ingreso de los estudiantes y controlar a su vez el tiempo en que llegan al establecimiento educativo.

1.1 Descripción del problema

En la actualidad de manera tradicional se han utilizado varias metodologías para llevar a cabo la identificación y registro de acceso de personas, tales como: usuario y contraseña, número de identificación, pasaporte, licencia de conducir, entre otros. Dichos recursos se pueden perder, olvidar, compartir y manipular ocasionando problemas económicos como la inversión en carnet estudiantiles de igual manera ocasionar problemas sociales como contaminar el medio ambiente con el uso de materiales plásticos el cual es uno de los componentes que demoran cerca de 500 años en desintegrarse.

Dados estos inconvenientes, surge como una alternativa la implementación de un módulo de reconocimiento facial el cual permite la identificación a las personas que ingresan a un lugar determinado, de manera adicional por medio del registro de ingreso y salida de las personas, analizar dichos datos los cuales permitan predecir el comportamiento futuro de ingreso y salida de tales personas.

En los centros educativos como en cualquier ámbito ya sea personal o laboral la puntualidad es una de las virtudes que toda persona debe tener. Sin embargo, por diferentes motivos es uno de los principales problemas que existen dentro de un centro educativo. Es por esa razón que, a través de modelos para pronósticos de tiempos, se identifica los patrones positivos y negativos en los estudiantes respecto del registro de hora de ingreso y salida de la institución para de esta manera poder notificar a los usuarios su comportamiento, así inculcar la puntualidad en los mismos.

De acuerdo con lo expuesto, en este proyecto se pretende identificar a estudiantes por medio de reconocimiento facial al ingreso de la institución de educación superior, también analizar su comportamiento a lo largo del tiempo en base a la identificación de patrones de dichos registros de ingreso.

1.2 Justificación del problema

La carencia de un sistema en la institución, que identifique el acceso e identidad de los estudiantes en tiempo real impulsa al desarrollo de este proyecto por el cual se obtendrán datos y con el análisis correspondiente genera los patrones de comportamiento por medio de estos resultados se viabilizará a las autoridades la información necesaria para tomar decisiones enfocadas en brindar un servicio de mayor calidad a los estudiantes.

Uno de los motivos al implementar el sistema de reconocimiento facial es el control de acceso a los alumnos para las diferentes áreas de la institución, esto evita el uso de implementos para procesar el carnet estudiantil que es utilizado como identificación para permitir acceso de los alumnos a la institución educativa.

Actualmente la institución de educación superior no cuenta con un sistema de reconocimiento facial para el control de ingreso de los estudiantes, a la fecha el ingreso de los alumnos lleva un registro a partir de su carnet estudiantil, el cual esta enlazado al torniquete de la Institución, sistema que almacena estos datos de control: hora de ingreso, Id estudiantil, carrera, hora de salida, mismos datos que no son utilizados en beneficio de la institución, por tal razón el presente proyecto hace uso de esta data a fin de pronosticar el comportamiento estudiantil y en el caso de que los estudiantes no lleven consigo su credencial al momento de entrada, el ingreso se controla de forma manual por el personal de seguridad de la institución.

La implementación del sistema de control de acceso mediante reconocimiento facial permite recolectar datos del usuario en base a su comportamiento habitual de la hora de entrada y salida al establecimiento, para de esta forma usar técnicas de pronósticos en series de tiempos y así predecir la llegada de los alumnos a futuro. Al ser la educación un derecho de todos, también existen obligaciones que el estudiante debe cumplir estrictamente, como la puntualidad a sus horas de clases las cuales son dispuestos por las autoridades de la institución en cada periodo académico.

Es importante que día a día se mejoren algunos aspectos que están inmersos en este campo; por tal razón la implementación de un sistema de control de acceso e identificación de patrones que caractericen el comportamiento de estudiantes de nivel superior, usando técnicas de pronósticos en series de tiempo y reconocimiento facial,

permitirá que se identifique las personas en tiempo real y con precisión, agilizando el ingreso o salida de las mismas, sin la necesidad de presentar identificaciones personales que causan malestar e inconvenientes en los usuarios, además de generar e inculcar niveles de conducta positivos a partir de las alertas o notificaciones que recibirán los estudiantes respecto del registro de su comportamiento y con ello disminuir o eliminar la conducta de impuntualidad de los estudiantes a sus clases.

1.3 Objetivos

1.3.1 Objetivo general

Implementar un sistema de control de acceso e identificación de patrones que caractericen el comportamiento de estudiantes de nivel superior, usando técnicas de reconocimiento facial con one-shot learning y pronósticos en series de tiempo.

1.3.2 Objetivos específicos

- Extraer características relevantes de un rostro con redes convolucionales que permitan lograr una alta precisión en el reconocimiento facial.
- Identificar patrones de comportamiento de los estudiantes a partir de las series de tiempo registradas en los controles de acceso.

1.4 Marco teórico

El proceso de reconocimiento facial es un avance tecnológico, considerado como una herramienta de gran interés investigativa, de acuerdo a la Organización Internacional de Policía Criminal INTERPOL, la institución considera a partir del 2020 que una herramienta de reconocimiento facial combinada con un software automatizado para uso de identificación biométrica es capaz de verificar un individuo e incluso comprobar su identidad bajo la comparación y el análisis de ciertos rasgos y contornos de rostros de un individuo, en este artículo de difusión (INTERPOL, 2020). Se menciona que es importante para la institución contar con una fotografía de pasaporte para generar las características del rostro que serán almacenadas, considerando que se trata de una imagen frontal completa con iluminación en el rostro y con un fondo neutral.

Como Reynoso Maciel Jessica, 2017 menciona en su investigación “Las máquinas aprenden: el reconocimiento facial como método de identificación” a partir de la detección

de un rostro, se emite miles de puntos imposibles de identificar a simple vista, los cuales generan una serie de constructos matemáticos, registra la forma, dimensión y proporciones de facciones, e incluso la distancia entre diferentes rasgos faciales, Reynoso, señala que estos sistemas están preparados incluso para detectar diferencias mínimas o cotidianas de la imagen detectada con la de la base de datos, por ejemplo uso de gafas, color de cabello, etc., dado que están entrenados para aprender las variaciones faciales del individuo y se adaptan a ciertos cambios en el momento de la identificación (Reynoso , 2017).

La revisión literaria acorde al tema de investigación ha permitido abordar artículos que contribuyen a este estudio, en “API para control de asistencia con reconocimiento facial usando OpenCv.JS” 2021, donde se menciona “reconocer el rostro mediante varios detectores SSD Mobilenet V1 y TinyFaceDetector” con la carga o el url de una imagen permiten de forma asíncrona el reconocimiento del rostro en tiempo real, el estudio en mención concluye que se puede generar decisiones a partir del reconocimiento facial respecto del control de asistencia de los estudiantes en las aulas de una institución. El formato Json utilizado en el estudio permite identificar que las características extraídas de las imágenes de los estudiantes en el aula coincidan con los datos almacenados previamente en el sistema, los cuales fueron extraídos a partir de una serie de características detectadas con SSD Mobilenet V1 y TinyFaceDetector.

El trabajo de investigación “Reconocimiento facial mediante la clasificación de modelos vectoriales para la autenticación de usuarios” (Guerrero, 2018) comprende puntos de investigación relacionados al presente estudio, los autores se basan en la extracción de muestras de un rostro de un usuario x mediante la utilización de clasificadores en cascada haar, seguido de la detección, normalización y almacenamiento de datos de los documentos de identificación y posterior la extracción de datos de la nueva imagen a fin de comparar estos dos grupos de datos y validar la identidad del usuario mediante redes neuronales convoluciones. Los resultados de este estudio concluyen en la validación del usuario a partir del resultado comparativo de datos en tiempo en función de la configuración de patrones de entrada lo cual produce dos resultados, coincidencia: positiva y negativa, bajo la utilización de redes neuronales, basadas en el modelo VGGFace.

1.4.1 Reconocimiento facial

Se ve como obligación de los seres humanos desde la antigüedad el reconocimiento de distintas características en otras personas de su alrededor, siendo el rostro la principal identidad de los humanos, debido a ello las tecnologías y algoritmos, han implementado varias funcionalidades propias para este proceso. El reconocimiento facial permite la identificación de un individuo con la ayuda de un medio tecnológico automatizado.

En los inicios de las tecnologías relacionadas con el reconocimiento facial se utilizaba algoritmos de reconocimientos simples que brindan más oportunidad a que los errores se produjeran, como reconocer dos personas diferentes con la misma identidad, en la actualidad los algoritmos se han actualizado y han mejorado sus tiempos de ejecución en forma exponencial, los errores son mínimos considerando que existen varias formas de reconocer un rostro.

Actualmente existen varias aplicaciones de reconocimiento facial en línea, desde el desarrollo de la inteligencia artificial y la tecnología de visión por computadora, el reconocimiento de expresiones faciales se puede realizar en un navegador, las cuales permiten entender su funcionabilidad en tiempo real, ejemplo: face-api.js la cual ha sido diseñada sobre el flujo tensorial para configurar la detección facial.

Para el uso de sistemas de identificación se requiere utilizar datos fisionómicos de los individuos por medio de cámaras, para luego poder realizar comparaciones con las imágenes almacenadas. La precisión del sistema dependerá de la calidad de las imágenes, para alcanzar un alto nivel, tanto la almacenada en la base de datos como con la nueva imagen generada. Influye aspectos como: iluminación, ángulo, distancia del objetivo calidad de la cámara, etc." (Caldera & Zapico, 2009).

A partir de una imagen digital, el fin del sistema automatizado de reconocimiento facial es identificar al rostro dejando de lado posición, iluminación o uso de lentes, maquillaje, gorras u otros accesorios. Respecto de los reportes literarios, varios de los sistemas de reconocimiento facial utilizan diversas técnicas de probabilidades en conjunto con análisis de componentes principales (PCA), con técnicas más robustas como redes neuronales o máquinas de soporte Vectorial (SVM).

El proceso en mención se realiza a partir de la extracción de características específicas del rostro, tales como: la distancia entre ojos, cejas, nariz y boca. Por ejemplo, Jorge Caldera Serrano y Felipe Zapico Alonso en “Identificación facial biométrica” 2009 mencionan que “hay datos que permiten distinguir un rostro del resto: anchura y distancia entre los elementos, color, existencia de arrugas”. Se puede definir hasta 80 puntos nodales para su identificación sin errores, normalmente los programas no utilizan todos estos nodos. Los elementos de los nodos se evalúan, a partir de un código numérico individual, y la serie de datos creada se almacena automáticamente. En tal razón, el software trabaja con información numérica y no visual. Se denomina faceprint al conjunto de datos, códigos y elementos, distintivos de cada rostro.

Un sistema de reconocimiento de rostros se divide de forma conceptual y funcional en tres bloques. En la etapa uno, se realiza la detección del rostro en la imagen, misma que consiste en determinar si existe o no un rostro en la imagen, si existe uno o más rostros se logra obtener la posición de la imagen. En la segunda etapa se realiza la extracción de características mismo que involucra describir los rostros específicos de las personas. Finalmente, en la tercera etapa se genera la clasificación de las características para reconocer a las personas.

Es importante considerar las ventajas y desventajas que presenta el reconocimiento facial.

Tabla 1.1 Reconocimiento facial: ventas y desventajas

Ventajas	Desventajas
Eficacia alta en la detección de rostro	Las condiciones de luminosidad son sensibles ante el sistema.
Cuando el contacto es dificultoso, el proceso es eficiente	Orientación o ubicación del rostro.
El espacio del dispositivo para el reconocimiento facial es reducido	Cirugías en el rostro que impiden la identificación
La utilización del dispositivo puede ser a distancia.	

Elaborado por: Cáceres & Valencia, 2021

1.4.1.1 Detección de rostro en una imagen

Determinar la presencia de un rostro en una imagen es el inicio de todo sistema de reconocimiento facial, esto permite trabajar únicamente con la región del rostro, datos que son normalizados geoméricamente a partir de las coordenadas de los ojos. Es importante considerar que, si en la imagen que se intenta evaluar no se detecta el rostro, no es posible generar evaluaciones.

Sin embargo, si después de detectado el rostro, no es posible identificar los ojos, esto refleja un problema en esta parte del rostro, es decir, pueden estar cerrados o sometidos a algún tipo de oclusión en el momento de la captura. Por tanto, en ese caso, se evalúa la imagen como mala y el proceso no continúa (Méndez, Chang, Rizo, & Morales, 2012).

Una vez que el rostro y los ojos han sido detectados, automáticamente el sistema continúa con la identificación de las demás zonas del rostro, a continuación, se analiza el elemento, nitidez de la imagen y posterior se evalúa la pose.

La localización de rostros consiste en identificar las coordenadas del rostro en una imagen. Es decir que el proceso de detección de rostro consiste en identificar el bounding box de cada rostro, que es la cuadrícula que señala la ubicación dentro de la imagen.

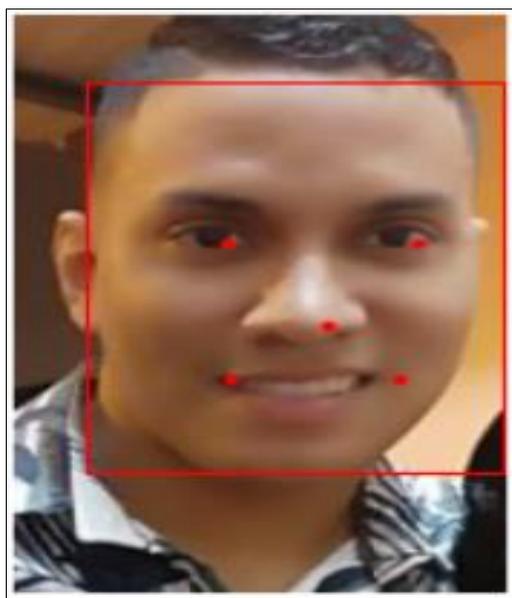


Figura 1.1 Bounding box de rostro

Elaborado por: Cáceres & Valencia, 2021

A continuación, se menciona distintos autores y métodos existentes para la detección de rostros en una imagen:

Espinoza O.D. & Jorquera G. P. en su estudio “Reconocimiento Facial” 2015, señalan cuatro categorías no excluyentes de métodos de detección facial:

- **Métodos basados en conocimiento:** codifican el conocimiento humano mediante una serie de características a detectar considerando: las distancias y las posiciones entre labios, ojos y nariz. (Espinoza Olgún & Jorquera Guillen, 2015).
- **Métodos basados en características invariantes:** son aquellas que no se alteran por variables como cambio de luz, pose o ubicación de la cámara, tales como la ceja, color de piel, nariz, textura de la piel. (Espinoza Olgún & Jorquera Guillen, 2015).
- **Métodos basados en moldes (patrones):** es la relación entre una imagen de entrada y una plantilla definida o un patrón, con componentes básicos como círculos, elipses u otros, su objetivo es capturar características del rostro, a partir de la forma de un objeto. (Espinoza Olgún & Jorquera Guillen, 2015).
- **Métodos basados en apariencia:** los modelos que se utilizan son el resultado del entrenamiento de imágenes y el aprendizaje, considerando a la imagen como un vector de características (Espinoza Olgún & Jorquera Guillen, 2015).

Viola P & Jones M. (2001), desarrollaron un algoritmo de detección de rostros que permite obtener un gran conjunto de datos el cual tiene un alto porcentaje de precisión.

- **Viola Jones:** algoritmo desarrollado para detección facial, en un tiempo mínimo de procesamiento de una imagen capturada dada su clasificación de características en una escala de grises.

En la publicación “Detección de rostros con Machine Learning” menciona la utilización de redes convolucionales para la detección de rostros en tiempo real, como métodos basados en apariencia (Sotaquirá, 2020).

El uso de redes convolucionales permite la construcción de detectores de rostros robustos, a partir del entrenamiento de redes con imágenes de rostros humanos, se

obtiene como primer resultado la clasificación de la escena, identificando si la imagen contiene o no un rostro humano.

En el estudio “Detección de rostros con Machine Learning” el autor menciona que a la actualidad las dos redes convolucionales para la detección de rostros son: la red multitarea en cascada MTCNN y Mobilenet, en los dos casos es posible detectar rostros en imágenes e incluso en video con una alta precisión, independientemente de la pose, escala, expresiones faciales o iluminación de la imagen.

- **MTCNN:** la red preentrenada ha sido desarrollada con capacidad para la detección de uno o más rostros en imágenes o en videos, a partir de una conexión en cascada de tres redes convolucionales. Su arquitectura presenta limitaciones en el proceso considerando el uso de tres redes neuronales, por el ende el tiempo de ejecución de la red juega un papel fundamental para una detección de rostros en tiempo real.
- **MobileNet:** la red convolucional es capaz de detectar rostros e incluso objetos a partir del entrenamiento asignado, además procesa las convoluciones de una manera eficiente, considerando la rapidez del procesamiento de la información.

MobileNet, logra una detección de rostros en forma precisa casi cuatro veces más rápido que la red MTCNN (Sotaquirá, 2020).

La detección de un rostro en el presente proyecto se la plantea realizar con MobileNet método basado en apariencia, el cual es una arquitectura optimizada que utiliza convoluciones para generar redes neuronales profundas y livianas que permiten comprometer efectivamente la precisión y el tiempo. Los parámetros designados en esta arquitectura dan la opción de elegir el modelo de tamaño apropiado para la aplicación en función de las restricciones del problema de investigación.

El modelo detecta varias regiones de interés en un rostro, cada una de estas regiones de interés tiene un puntaje entre 0 (baja) y 1 (alta) indicativo si pertenece o no a una región del rostro en análisis. Este modelo está construido por convoluciones de gran profundidad, es decir que se aplica un filtro único en cada canal de entrada.

La arquitectura de MobileNet de 28 capas es un modelo basado en convoluciones factorizadas estandarizadas, la cual comprende convoluciones profundas y puntales:

- **Convoluciones profundas:** aplica un filtro único para cada canal de entrada
- **Convoluciones puntuales:** combina las salidas de diferentes convoluciones de profundidad.

La primera capa de la arquitectura MobileNet es una convolución completa. Con la definición simple de una red, se puede explorar la topología la misma y encontrar la red adecuada. Todas las capas de esta arquitectura están seguidas por funciones de activación no lineal, a excepción de la capa final que está completamente conectada y no tiene una función de activación no lineal ésta se alimenta directamente a la capa softmax, es decir a la capa final para su clasificación. Tanto la convolución profunda como capa convolucional inicial pueden manejar la disminución de resolución. La capa final de agrupación promedio reduce la dimensión del mapa de entidades en 1x1 antes de la capa conectada en su totalidad. Identificando así a la convolución profunda y la convolución puntual como capas totalmente diferentes.

Tabla 1.2 Arquitectura de MobileNet

TYPE / STRIDE Tipo	FILTER SHAPE Tipo de filtro	INPUT SIZE Tamaño de entrada
Conv / se	3 x 3 x 3 x 32	224 x 224 x 3
Conv dw /s1	3 x 3 x 32 dw	112 x 112 x 32
Conv / s1	1 x 1 x 32 x 64	112 x 112 x 32
Conv dw /s2	3 x 3 x 64 dw	112 x 112 x 64
Conv / s1	1 x 1 x 64 x 128	56 x 56 x 64
Conv dw /s1	3 x 3 x 128 dw	56 x 56 x 128
Conv / s1	1 x 1 x 128 x 128	56 x 56 x 128
Conv dw /s2	3 x 3 x 128 dw	56 x 56 x 128
Conv / s1	1 x 1 x 128 x 256	28 x 28 x 128
Conv dw /s1	3 x 3 x 256 dw	28 x 28 x 256
Conv / s1	1 x 1 x 256 x 256	28 x 28 x 256
Conv dw /s2	3 x 3 x 256 dw	28 x 28 x 256
Conv / s1	1 x 1 x 256 x 512	14 x 14 x 256
Conv dw /s1 5 X	3 x 3 x 512 dw	14 x 14 x 512
Conv /s1	1 x 1 x 512 x 512	14 x 14 x 512
Conv dw /s2	3 x 3 x 512 dw	14 x 14 x 512
Conv / s1	1 x 1 x 512 x 512	7 x 7 x 512
Conv dw /s2	3 x 3 x 1024 dw	7 x 7 x 1024
Conv / s1	1 x 1 x 1024 x 1024	7 x 7 x 1024
Avg Pool /s1	Pool 7 x 7	7 x 7 x 1024
FC / s1	1024 x 1000	1 x 1 x 1024
Softmax /s1	Classifier	1 x 1 x 1000

Elaborado por: (Sotaquirá, 2020).

1.4.1.2 Extracción de características de rostros

Después que el rostro ha sido detectado, se procede a extraer ciertas zonas del rostro, la diversidad de métodos existentes para el reconocimiento se enfoca directamente en las zonas extraídas como elementos de comparación.

La extracción de características en una imagen considera tomar medidas de los diferentes puntos del rostro, extraer estos en forma de vector. Para la elección de las características a utilizar, se debe considerar ciertos puntos:

- **Discriminantes:** poseer varios valores dentro de una misma clase.

- **Fiabes:** poseer valores similares dentro de una misma clase.
- **Mínimos:** información con menor número de características en la imagen.
- **Tiempo de aceptación:** su funcionabilidad en tiempo real depende los tres apartados mencionados.

En el estudio “Control de Seguridad Biométrico de Reconocimiento Facial como Caso de Estudio Implementación en el Área Administrativa de la Facultad de Ingeniería de la Universidad Católica de Santiago de Guayaquil” (2016). Se menciona que el reconocimiento facial es el tratamiento automatizado de imágenes que contiene rostros y toma a los siguientes como modelos de reconocimiento facial:

- **Kairos:** es una plataforma pagada para análisis humano, diseñada para reconocimiento facial, la cual busca, localiza y reconoce entre personas cercanas a la imagen capturada, además esta entrenada para el análisis de emociones, la cual se concentra en identificar expresiones, además el algoritmo mide la cantidad y características de las personas como: edad y género, mediante la captura de video o imágenes en tiempo real. (Solis Calvopiña & Puga Torres, 2016)
- **OpenFace:** es un software libre, el cual se basa FaceNet, siendo este capaz de captar e identificar los rostros en tiempo real. (Solis Calvopiña & Puga Torres, 2016)
- **OpenBR:** es un software de código abierto bajo la licencia Apache 2, desarrollado en lenguaje C++ actualmente se encuentra activo en los sistemas operativos: Windows, Mac y Linux, el software está desarrollado para reconocimiento facial de imágenes fijas y evalúa su rendimiento directamente sobre la cámara frontal. (Solis Calvopiña & Puga Torres, 2016)

Hmani y Petrovska-Delacretaz, en su investigación “Rendimiento de reconocimiento facial de última generación utilizando software y conjuntos de datos disponibles públicamente” realiza una comparación de sistemas de reconocimiento facial, en los cuales obtiene los siguientes resultados. (Hmani & Petrovska, 2018)

Tabla 1.3 Comparación de sistemas de reconocimiento facial

Sistema	Desarrollador	Porcentaje de aciertos
FaceNet	Google	99,63%
DeepID2	Departamento de ingeniería de la universidad de Hong Kong, China	99,15%
VGG-DeepFace	Visual Geometry Group (VGG) de la universidad de Oxford	98,95%
CASIANet	Instituto de automatización de la academia de ciencias chinas	96,13%
DeepFace	Facebook	97,35%

Elaborado por: (Hmani & Petrovska, 2018)

Schroff, Ludwiczuk, y Satyanarayanan (2015) presentan FaceNet, un modelo de red neuronal convolucional desarrollado por Google. Actualmente, es uno de los sistemas entrenados más precisos de reconocimiento facial, el mismo es apto para verificación y reconocimiento facial.

- **FACENET:** Facenet es una red convolucional universal que permite extraer características relevantes de un rostro previamente detectado, logrando una alta precisión en el reconocimiento facial.

Para que el reconocimiento facial funcione adecuadamente, es importante la definición del modelo y que este permita la generalización correcta de los datos, además para conseguir un ajuste de parámetros óptimo, es necesario un conjunto de datos de entrenamiento lo suficientemente grande y completo, y aparte, se requiere disponer de los recursos y el tiempo suficiente para el entrenamiento del modelo.

FaceNet es empleado en varios problemas de reconocimiento facial de Inteligencia Artificial en la actualidad, ya que previamente esta entrenado y su integración no es nada compleja.

La red convolucional FaceNet aprende directamente de una base de imágenes de rostros a un espacio euclidiano el cual identifica que las distancias entre puntos de la nueva imagen correspondan directamente a un rostro almacenado respecto de las distancias de puntos registradas. *Luego de generar los espacios entre puntos*

de la imagen capturada, el reconocimiento facial, la verificación y la agrupación se pueden implementar fácilmente utilizando técnicas estándar con incrustaciones de FaceNet como vectores de características (Schroff, Kalenichenko, & Philbin, 2015). En virtud de lo mencionado, la detección de características en el presente proyecto se llevará a cabo mediante el modelo pre-entrenado FaceNet.

1.4.1.3 Embedding

Es una representación compacta que utiliza un vector con los píxeles correspondientes al rostro a partir del uso de la red convolucional FaceNet, el embedding será un vector único para cada caso, lo cual permitirá generar el reconocimiento facial con precisión. A partir de imágenes a color ingresadas se generan datos de reconocimiento importantes ubicados en un vector normalizado de 128 elementos siendo esta la representación compacta de cada rostro de entrada, independientemente estas características se generan sin importar poses, gestos o usos de accesorios.

1.4.1.4 Clasificación de características

En esta etapa el sistema aprende o dispone de los patrones necesarios que se requiere para resolver la semejanza entre rostros de individuos, por tal razón se dispone de la base de rostros de diferentes estudiantes con distintas expresiones, mismos datos que están almacenados luego del proceso de reconocimiento facial (identificación del rostro, extracción de características y clasificación de características) y dependiendo del algoritmo utilizado se compara las diferencias entre una imagen capturada con las de la etapa de entrenamiento, es decir se obtienen los vectores principales de cada estudiante y a partir del método matemático de distancias euclidianas se procede a identificar la distancia que existe entre dos puntos del objeto de interés y a continuación se determina la identidad de la persona.

La postura y la iluminación son variables fundamentales en el proceso de clasificación de características, en el artículo "Lightweight FaceNet Based on MobileNet" (2021). Se menciona que el método tradicional de reconocimiento facial basado en redes neuronales convolucionales es usar la red gemela de CNN (Convolutional Neural Networks) para extraer características faciales, y posterior a ello usar SVM (Support Vector Machine) y otros métodos de clasificación. (Xinzheng, Meng, Huanxiu, Jianying, & Xiaoyang, 2020) Sin embargo, señala que "FaceNet está entrenado para aprender el

mapeo de imágenes a puntos en el espacio euclidiano y juzga si las dos imágenes a las que corresponde directamente la distancia entre las características de las dos imágenes en el espacio euclidiano son similares”. Para realizar el reconocimiento facial como tal, se compara el embedding calculado por FaceNet con los embeddings de las imágenes de referencia. Si la distancia euclídea entre el embedding desconocido y el de referencia es menor a un cierto umbral, entonces se concluye que se trata del mismo rostro (Sotaquirá, 2020).

La figura 1.2. refleja el proceso de clasificación de características a partir de una imagen de entrada y una imagen almacenada, hasta el reconocimiento facial, las cuales comprende cinco etapas:

1. Imágenes de entrada
2. FaceNet
3. Embeddings
4. Distancia euclidiana
5. Resultado

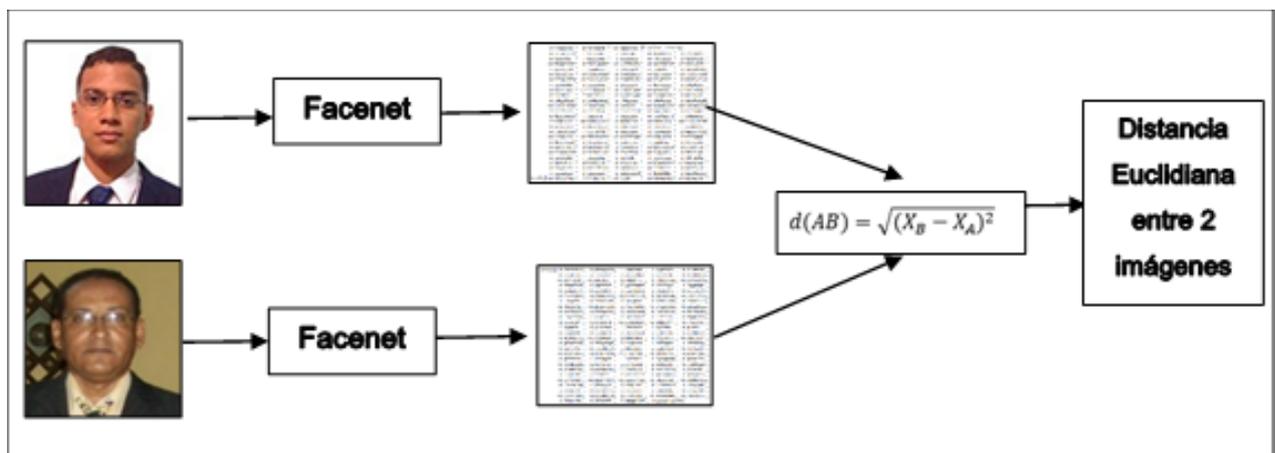


Figura 1.2 Proceso de comparación de dos rostros mediante FaceNet

Elaborado por: Cáceres & Valencia, 2021

1.4.2 Series de tiempo

El presente análisis tiene como objetivo comprender el contenido de los registros del ingreso de los estudiantes a fin de corregir, aprovechar y mejorar estos datos inculcando

a los estudiantes una cultura de calidad a partir del valor puntualidad. A menudo se miden varias señales al mismo tiempo, lo que permite un análisis más profundo, pero a la vez más complejo.

1.4.2.1 Análisis y predicción de series de tiempo

Este apartado consiste en predecir los valores de las variables que caracterizan el comportamiento de datos que son registrados en base a sus indicadores del pasado. Debido a su gran variedad de aplicaciones, el pronóstico de series de tiempo con el paso de los años ha tomado un alto interés. Existen dos tipos básicos de predicción: a corto y largo plazo.

Los pronósticos se realizan con el objeto de orientar las decisiones en las áreas de interés como mercados, transporte, clima, ingresos, salidas, entre otros. Para pronosticar una variable es necesario la construcción de un modelo a fin de estimar los parámetros utilizando datos históricos, logrando así una caracterización estadística entre los datos actuales y los datos del pasado.

Las técnicas de predicción en series de tiempo son:

- **Métodos cualitativos:** los datos del pasado no proporcionan información directa sobre el fenómeno que se trata.
- **Métodos cuantitativos:** se extrae toda la información contenida en la data del pasado y en base al patrón de conducta se realiza predicciones al futuro.

1.4.2.2 Patrones en series de tiempo

Se considera como una serie de tiempo a una sucesión de observaciones de una variable en intervalos regulares a lo largo del tiempo, a partir de estos datos se generan predicciones, que permitirán determinar qué valor tomará la variable de estudio en el futuro, esto mediante una técnica cuantitativa que permita identificar patrones en base a los datos almacenado, siendo estas señales un grupo de características distintivas entre cada individuo.

El reconocimiento de patrones consiste en determinar el proceso de decisión para separar el espacio de características, un patrón en una serie de tiempo tiene cuatro componentes:

- **Tendencia:** a muy largo plazo
- **Cíclico:** a largo plazo
- **Estacional:** a corto plazo
- **Irregular:** a muy corto plazo

La calidad de la predicción realizadas dependerá totalmente del proceso que genera la serie, es decir si la variable que ha sido analizada sigue un patrón de comportamiento más o menos fijo probablemente se obtenga predicciones más fiables, de grado de error bajo. Al contrario que, si la serie no genera ningún patrón de comportamiento específico, se debe concluir que las predicciones carecen de valor.

1.4.2.3 Método de pronóstico

1.4.2.3.1 Redes neuronales

Una red neuronal artificial está considerada como un procesador masivo paralelo el cual está formado por unidades simples de procesamiento de conocimiento experimental, siendo viable su uso. Se considera que una red neuronal, es similar a un cerebro humano en dos aspectos:

- El conocimiento se adquiere mediante una red desde su entorno a través de un proceso de aprendizaje. Haykin, 2009 (Haykin, 2009)
- Las fuerzas de las conexiones entre neuronas, conocidas como pesos sinápticos, son usadas para almacenar el conocimiento. (Haykin, 2009)

La arquitectura de una red neuronal ha sido diseñada para organizar y colocar las neuronas en la red, formando capas o agrupaciones de neuronas. Siendo sus parámetros fundamentales: número de capas, neuronas por capa, grado de conectividad y tipo de conexión entre neuronas.

Cañete en 2021, en su estudio sobre Técnicas de Deep Learning para la predicción, señala que la elección de las variables más relevantes para el estudio de una serie temporal es tan importante como seleccionar la técnica de aprendizaje automático que ayuden al cumplimiento de los objetivos planteados.

Una de las técnicas de aprendizaje automático para predecir este estudio es:

- **Long Short-Term Memory:** LSTM es una arquitectura de redes neuronales recurrentes RNN utilizada en aprendizaje profundo, la cual está diseñada para evitar dependencia a largo plazo. Esta arquitectura ha sido diseñada, para tomar una serie de entradas sin un límite de tamaño, por lo tanto, estas redes neuronales toman decisiones influenciadas por datos del pasado en la serie temporal. Se utilizan generalmente cuando es crítico la predicción de un resultado satisfactorio (Cañete, 2021).

1.4.2.3.2 Métodos estadísticos de pronósticos

El pronóstico estadístico ofrece un nivel de conocimiento y automatización que permiten mejorar la precisión del pronóstico, en particular cuando los datos de la variable a analizar crecen continuamente.

La ventaja de utilizar modelos estadísticos de pronóstico es que sus beneficios son altos. Son métodos robustos que están diseñados para detectar y extrapolar patrones, como es la estacionalidad, ciclos, tendencias, entre otros.

- **Modelo de regresión:** los modelos de regresión permiten incorporar factores de causa como precios, promociones e indicadores económicos en los pronósticos, es decir incluir una variable al objeto de estudio, a fin de mejorar los resultados. Los modelos son la combinación de una regresión lineal simple a fin de capturar: tendencia, estacionalidad y las relaciones entre las fases del tiempo de distintas variables.
- **Modelo de series de tiempo:** los modelos de pronóstico están basados en la demanda del pasado de la variable que se está pronosticando. El modelo se desarrolla en base a patrones en los datos históricos. Los modelos utilizados para series de tiempo son correctos cuando existe continuidad con los datos del pasado y tienen relación con los datos del futuro. Además, se considera adecuados para la predicción a corto plazo en los cuales se encuentran los siguientes:
 - **Modelos simples:** también denominados promedios móviles, reflejan datos similares a los datos de tiempo atrás (corto plazo).

- **Modelos de suavización exponencial:** este método de pronóstico es de buen desempeño y exactitud, su aplicación no es compleja y se pueden automatizarlos a manera que admitan la predicción a gran escala, de acuerdo a los parámetros que se utilice. Es un modelo adaptativo y el pronóstico considera como elemento primordial la historia más actual en comparación con la historia más antigua.
- **Modelo de demanda intermitente de CROSTON:** este modelo CRO está específicamente diseñado para series de datos donde existe demanda de cero y la ocurrencia de la demanda no se identifica comúnmente. La funcionalidad del modelo surge a partir de la combinación de dos suavizaciones, una para las demandas diferentes a cero y otra para el intervalo de tiempo entre cada demanda distinta de cero.
- **Modelos de box jenkins (ARIMA):** el modelo ARIMA es de carácter adaptativo ya que permite la identificación de patrones de tendencia y estacionalidad mismos que pueden ser automatizados. Este modelo no está basado únicamente en el principio de descomposición: nivel, tendencia y estacionalidad, sino que considera la dependencia que existe entre los datos bajo autocorrelación. El modelo de Box-Jenkins tienden a obtener un mejor desempeño que los modelos suavización exponenciales en data histórica larga y estables y no tan bien en conjuntos de datos ruidosos y con alta volatilidad.

El presente estudio se lo desarrolla mediante el método de pronóstico estadístico ARIMA, tratamiento a realizarse en R-Studio.

1.4.3 Estudiantes de educación superior

En la actualidad existe la tendencia a afirmar que los estudiantes de universidad de hoy son diferentes de los de las generaciones anteriores en la forma de aprender, de usar la tecnología digital y de interactuar entre ellos y aunque no es una verdad evidente.

Se utiliza la expresión «tecnología digital» para referir a una varia gama de herramientas, programas, dispositivos y recursos que almacenan y transmiten información en formato digital como, por ejemplo: correo electrónico, ordenadores, internet, teléfonos, cámaras

y tecnologías web 2.0 (blogs, redes sociales). En virtud de lo mencionado, este proyecto se enfoca en generar beneficios a los estudiantes a partir de los datos generados por un medio tecnológico como es el reconocimiento facial.

1.4.4 Software para utilizar

El software es el elemento más importante en una aplicación de visión por computadora, es el responsable del análisis, proceso e identificación de características de las imágenes.

A la fecha existe gran variedad de aplicaciones utilizadas para el desarrollo de sistemas de reconocimiento facial, los cuales tienen funciones y librerías que permiten el desarrollo de aplicaciones de visión por computadora sin una alta complejidad en su uso.

1.4.4.1 Python

Python, lenguaje de programación de propósito general iniciado por Guido van Rossum, que se hizo muy popular en poco tiempo principalmente debido a su simplicidad y legibilidad de código. Permite que el programador pueda plasmar sus ideas en menos líneas de código.

Entre sus características, destacan:

- Lenguaje con un fin general
- Menor complejidad en el manejo sintaxis
- Lenguaje Open Source, orientado a objetos
- Lenguaje de alto nivel
- Extensas librerías para su desarrollo.

1.4.4.2 RStudio

Es una interfaz de desarrollo integrado para R y Python, utiliza una consola, un editor de resaltado de sintaxis el cual permite que se ejecute el código en forma directa, además dispone de herramientas para el trazado, historial de código y procesamiento, depuración y la gestión del espacio de trabajo.

Su principal ventaja es el orden y la visualización de procesos de manera simultánea.

1.4.4.3 Django

Es un framework, es decir un entorno de trabajo de desarrollo web de alto nivel de sitios web seguros y mantenibles, de cualquier complejidad y en tiempos razonables. Django es gratuito y de código abierto, escrita en Python.

CAPÍTULO 2

2. METODOLOGÍA

En la actualidad existen varias maneras de lograr el reconocimiento facial a partir de técnicas basadas en aprendizaje automático juntamente con la utilización de redes neuronales a partir de dos aplicaciones: verificación e identidad del rostro.

En la presente investigación, el reconocimiento facial, se llevó a cabo a partir de la detección de un rostro en la imagen (MobileNet) seguido de la extracción de características del rostro (FaceNet) y finalmente, se generará la clasificación de las características para reconocer a las personas por medio de distancia euclidiana y una red neuronal. El dataset disponible para el estudio contuvo 1500 imágenes de estudiantes de una institución de educación superior y los registros de ingreso correspondientes a 10 meses, es decir dos periodos académicos ordinarios.

En la identificación, se comparó la imagen de un rostro desconocido con todas las imágenes de rostros almacenados previamente en una base de datos, con el objetivo de determinar la identidad correspondiente a la imagen de entrada.

El entrenamiento se realizó a partir de One-shot learning considerando que es un algoritmo capaz de aprender para reconocimiento facial a partir de una única imagen por clase en la base de datos.

Las series de tiempo son compilaciones de registros de determinado fenómeno, las cuales se producen en forma sucesiva en el tiempo, usualmente equiespaciados, mismos datos que permitieron la caracterización del comportamiento de los estudiantes.

El reconocimiento de patrones en las series de tiempo se enfocó en la extracción de características distintivas de los estudiantes, a partir de la información que se almaceno en una la base de datos de control, la cual contiene información como: fecha, hora de ingreso, carrera del estudiante, entre otras variables. Estos patrones identificados permitieron generar predicciones que involucren su socialización y beneficios que conlleven.

El reconocimiento de patrones en series de tiempo se llevó a cabo mediante el análisis de estacionalidad de los datos que se almacenan a partir del reconocimiento facial y generan una base de datos del registro de acceso de estudiantes, además se realizó un análisis comparativo de modelos de predicción estadísticos, a fin de seleccionar el modelo con mayor precisión de acuerdo con las métricas resultantes. Los datos tienen una frecuencia inferior a un año y oscilan en el tiempo.

Los datasets son fundamentales a la hora del entrenamiento de los modelos y al momento de evaluarlos, la calidad de los resultados del entrenamiento y la evaluación depende en gran parte de la calidad del dataset usado, tanto de la calidad de datos como del correcto etiquetado de cada individuo. El presente proyecto se generó a partir de dos bases de datos. Por un lado, se hizo uso de una base de datos de imágenes de alumnos para el reconocimiento facial. Por otro lado, para lograr la caracterización del comportamiento de los alumnos se utilizó el registro de acceso de estudiantes a la institución de educación superior. La información corresponde a dos periodos académicos mayo - septiembre 2017 y octubre - febrero 2018

El dataset de imágenes contiene:

1500 imágenes reales, en tamaño carnet y en formato jpg con el IdUsuario correspondiente.

El dataset de registro de acceso de estudiantes contiene las siguientes variables:

- IdUsuario
- Fecha
- Hora de ingreso
- Carrera
- Lugar de registro: edificio a o b

2.1 Reconocimiento facial y caracterización del comportamiento estudiantil mediante el control de acceso

La figura 2.1 señala el proceso para dar cumplimiento a los objetivos planteados. El mismo inicia con la captura de imágenes en un punto óptimo de la cámara, una vez

obtenida esta imagen el sistema detecta automáticamente el rostro a través de MobilNet, para generar el proceso de reconocimiento facial, a partir de la extracción de características con FaceNet, modelo pre-entrenado que identifica las distancias entre los puntos de los rostros de las imágenes almacenadas, generando un embedding con datos normalizados para cada rostro.

A continuación, esta información se compara con los datos almacenados y caracterizados previamente e identifica si el estudiante pertenece o no a la institución de acuerdo con la data, si se identifica que el estudiante pertenece a la institución se procede a abrir las puertas y a guardar los siguientes datos:

- Id del estudiante
- Fecha
- Hora de ingreso
- Carrera a la que pertenece el estudiante
- Edificio de ingreso

Con estos datos el sistema generará patrones en series de tiempo, los cuales se analizan automáticamente y a continuación se generará un reporte de pronóstico de comportamiento, por el contrario, si el sistema no lo reconoce al estudiante, desde la comparación, no se abren las puertas para su ingreso, se captura nuevamente la imagen, se extrae características, se entrena y de ser el caso y si se reconoce el rostro en un segundo control, continua con el proceso de registro de datos, etc. Caso contrario, el estudiante finaliza este proceso y podrá ingresar mediante la verificación personal con el personal de seguridad de la institución.

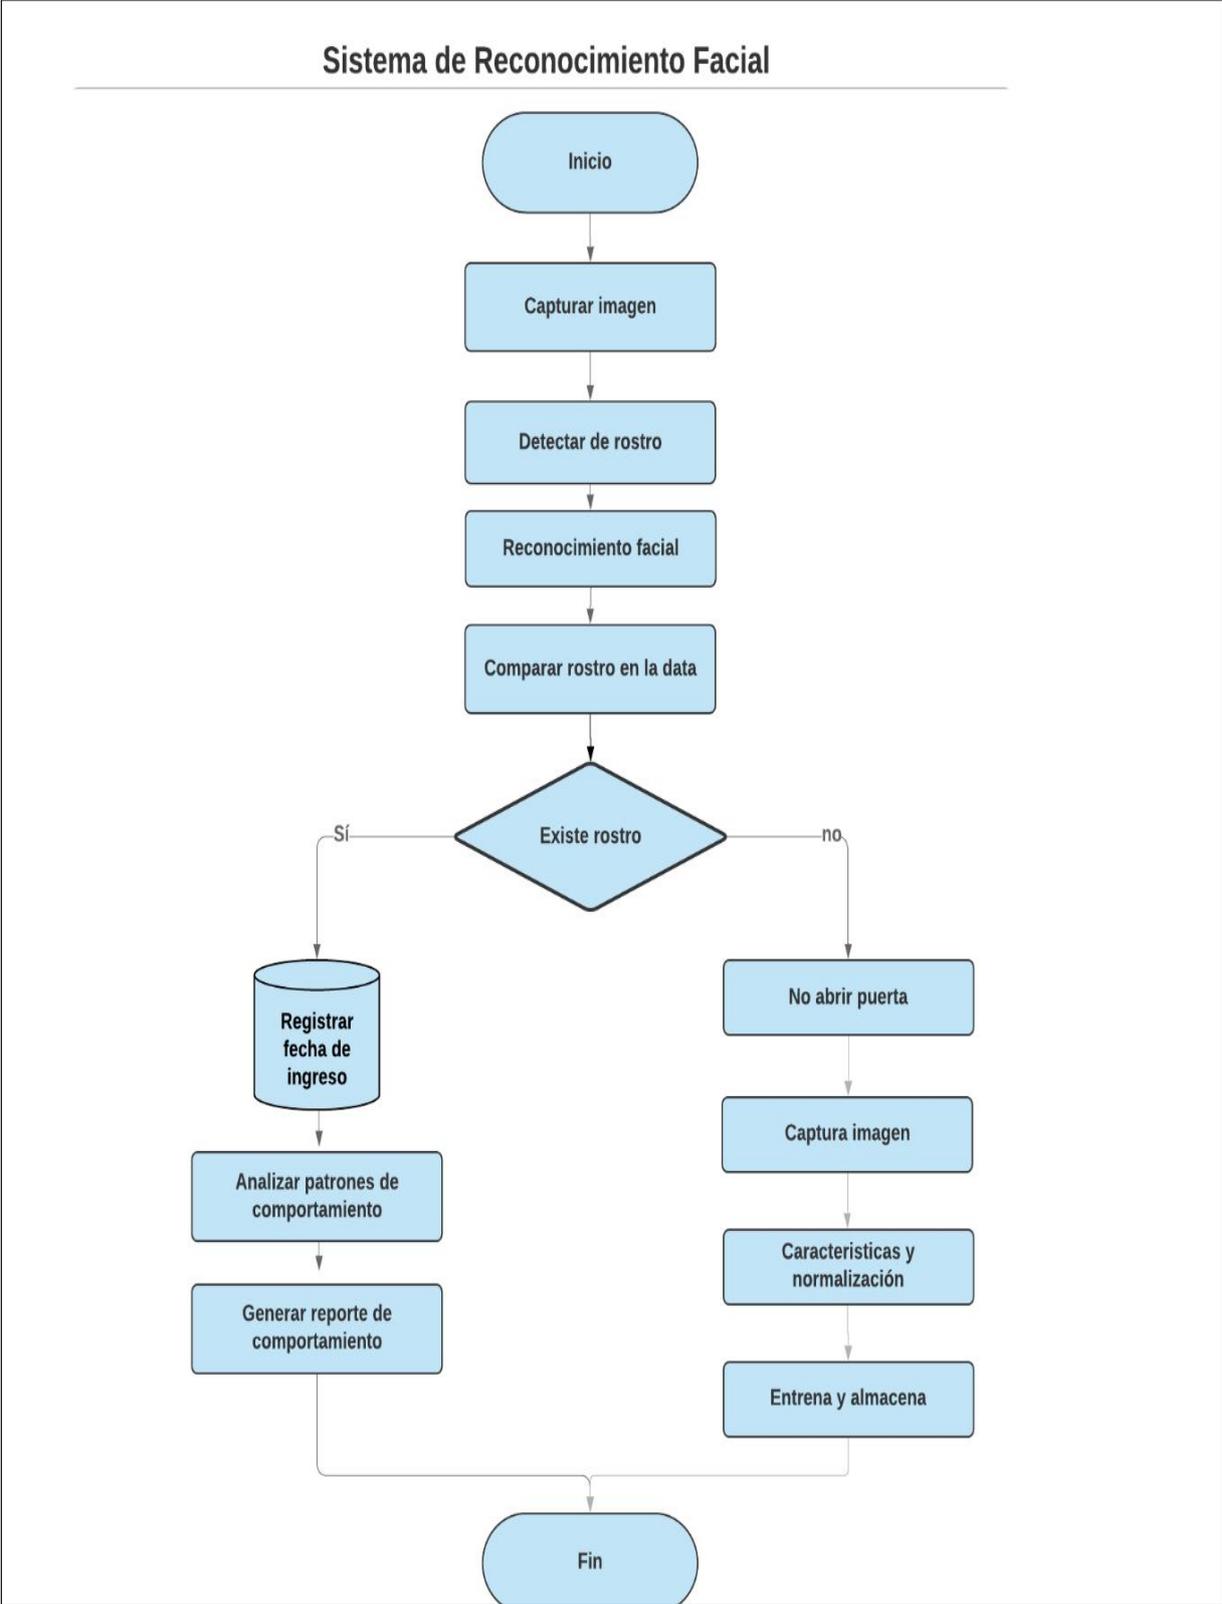


Figura 2.1 Arquitectura del sistema de control de acceso

Elaborado por: Cáceres & Valencia, 2021

2.1.1 Reconocimiento facial

El reconocimiento facial utilizando Deep Learning permite desarrollar un sistema capaz de determinar si el rostro de una imagen corresponde a un individuo en particular.

El sistema de Deep Learning tiene el objetivo que ser capaz de encontrar en las imágenes almacenadas el individuo de referencia, es decir debe ser un sistema lo suficientemente robusto a fin de lograr detectar con precisión todos y cada una de las características del rostro que se presente en la imagen.

La investigación utilizará una red convolucional, misma que su objetivo es detectar patrones en los datos de entrada, es decir en la imagen, esta red está formada por:

- **Capas convolucionales:** las cuales son encargadas de extraer características importantes de las imágenes.
- **Capas fully connected:** encargadas de obtener una representación de las características relevantes obtenidas
- **Capa de clasificación:** encargada de formar el vector, conjunto de características importantes y relevantes obtenidas de la imagen.

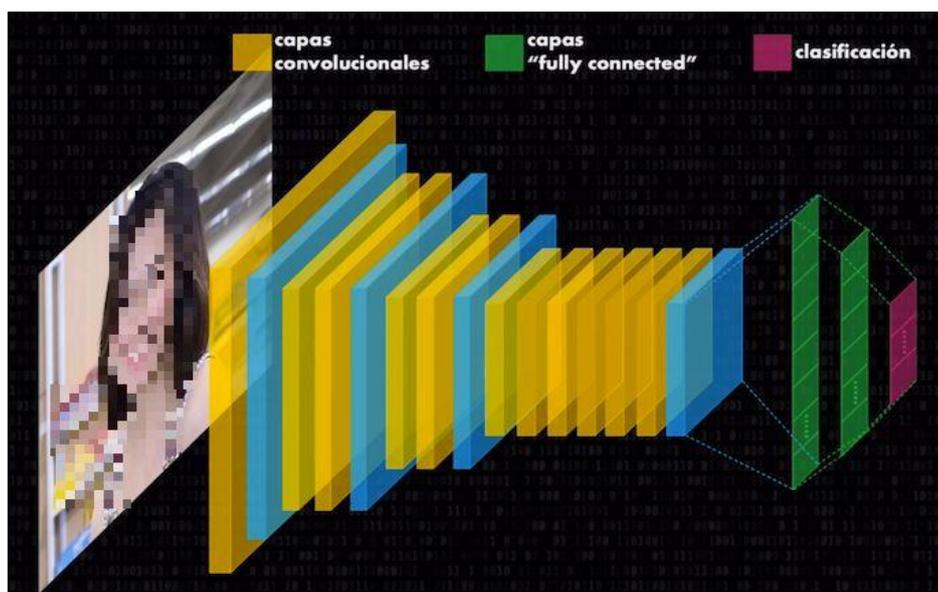


Figura 2.2 Estructura general de una red convolucional

Elaborado por: Sotaquirá, 2020

El funcionamiento de las redes neuronales en un breve resumen implica que su entrada es una imagen en formato digital, y sus primeras capas extraen puntos básicos como líneas y bordes de la misma, mientras esta se profundiza, estos elementos básicos se van combinando hasta detectar patrones más complejos, que podrían representar características como ojos, nariz, boca, cejas y finalmente un rostro completo.

2.1.1.1 MobileNet detección de rostro

Para el reconocimiento facial de la presente investigación, se implementará un sistema de detección de rostros en base a la red convolucional pre-entrenada MobilNet, esta etapa del estudio permitirá generar ciertas regiones de interés que contendrán las coordenadas del rostro de las imágenes de entrada.

Esta red convolucional es capaz de detectar rostros con rapidez y alta precisión en imágenes, sin considerar escala, pose, expresiones o condiciones de iluminación del rostro.

La figura 2.3 indica los puntos que la red selecciona en forma de un cuadrante para extraer el rostro de una imagen.

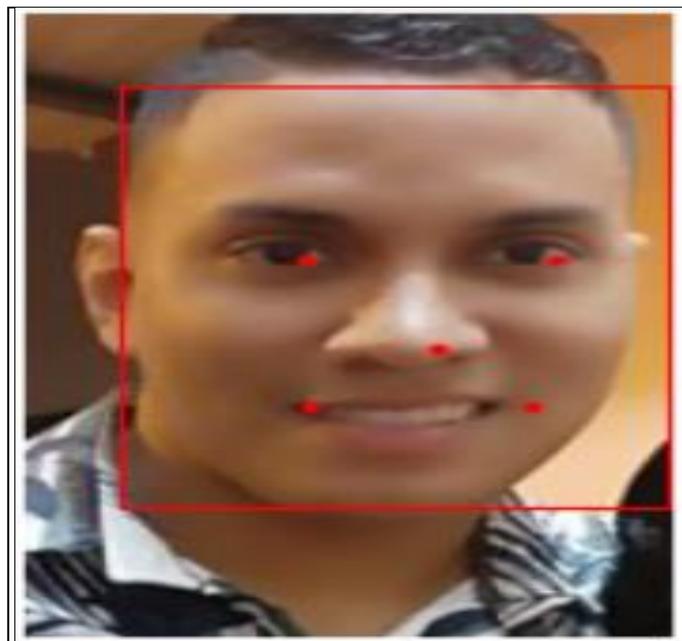


Figura 2.3 Detección del rostro en una imagen

Elaborado por: Cáceres & Valencia, 2021

Una vez extraído el rostro, se crea una nueva imagen que contiene solamente la región de interés (ROI) que representa el rostro figura 2.4 y se continúa con el proceso de reconocimiento facial.

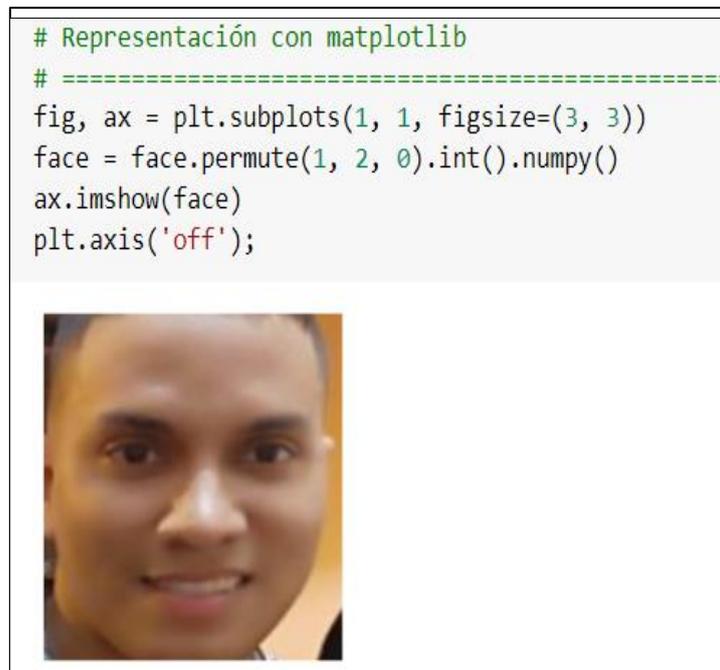


Figura 2.4 Extracción del rostro desde la imagen

Elaborado por: Cáceres & Valencia, 2021

2.1.1.2 One-Shot learning

La ejecución del sistema de reconocimiento facial se desarrollará mediante one-shot learning, que significa que la red tendrá una sola oportunidad (imagen) para aprender las características primordiales del rostro y reconocerlo, esto dado que la base de datos de imágenes contiene una imagen individual por estudiante, por tal razón se eliminará el clasificador de la estructura general de una red convolucional presentada en la figura 2.2. dado que el clasificador se utiliza para aprender con varias imágenes.

Es decir, para el reconocimiento facial con one.shot learning, se utilizará la red convoluciones convencional, sin la capa final, es decir se utilizará únicamente las capas convolucionales y las capas fully connected lo cual da como salida de la red convolucional no una imagen sino un vector, el cual contendrá menos elementos que una imagen, pero estará formado de información relevante de la misma.

2.1.1.2.1 FaceNet extracción de características

A continuación de la detección del rostro en imágenes, estos rostros serán trasladados a un sistema de reconocimiento facial. Es decir, se hará uso de la red FaceNet, misma que será encargada del proceso de verificación, este es el momento cuando se determina si el rostro en análisis pertenece o no al estudiante de referencia en la data.

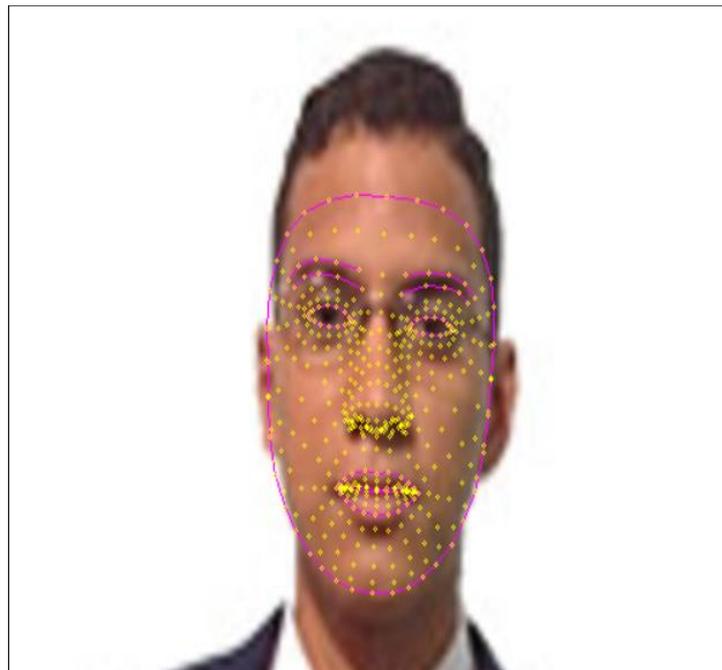


Figura 2.5 Extracción de características del rostro

Elaborado por: Cáceres & Valencia, 2021

El vector de salida que genera este sistema de reconocimiento facial contiene 128 elementos esenciales de cada rostro de entrada, este vector toma el nombre de embedding. y permitirá realizar el reconocimiento facial con una alta precisión.

2.1.1.3 Cálculo de distancias

A continuación del entramiento de la red, para el presente estudio se realiza un proceso de comparación de características entre el embedding del rostro de entrada con el embedding de los rostros de la data.

El reconocimiento facial, para el presente estudio, se llevará a cabo en su parte final mediante distancia euclideana, la cual es un número positivo que indica el espacio entre

dos puntos en un espacio, representados por medio de vectores. Así, la longitud de un vector AB es la distancia que existe en un espacio euclidiano entre los puntos A y B, ver ecuación 2.1.

$$d(AB) = \sqrt{(X_B - X_A)^2} \tag{2.1}$$

Donde:

X_B = coordenada del punto B

X_A = coordenada del punto A

2.1.1.3.1 Verificación del rostro

Se introduce a la red convolucional (FaceNet) la imagen de referencia y el rostro desconocido, para de esta forma obtener un embedding para cada caso y proceder a calcular la distancia entre ellos, confirmando su identidad si el umbral de la distancia es igual o inferior a 0.7 (Sotaquirá, 2020). Este proceso verifica si el rostro es o no el mismo que consta en la data.

2.1.1.3.2 Identificación del rostro

Este proceso se genera siempre y cuando el rostro este verificado, caso contrario no. El proceso es similar al de la verificación del rostro, primero se calculan los embeddings de los rostros tanto de la data como de la nueva imagen y se obtienen las distancias desde el nuevo rostro hasta cada uno de los embeddings de referencia. Luego, se determina la menor distancia por debajo del umbral 0.7 (Sotaquirá, 2020). De ser así el individuo es reconocido exitosamente.

La figura 2.6 a su izquierda refleja el inicio del proceso, es decir detecta el rostro de la imagen sin identificación y luego del procesamiento correspondiente y al paso de un tiempo mínimo se refleja su identidad, como lo indica la imagen de la derecha.

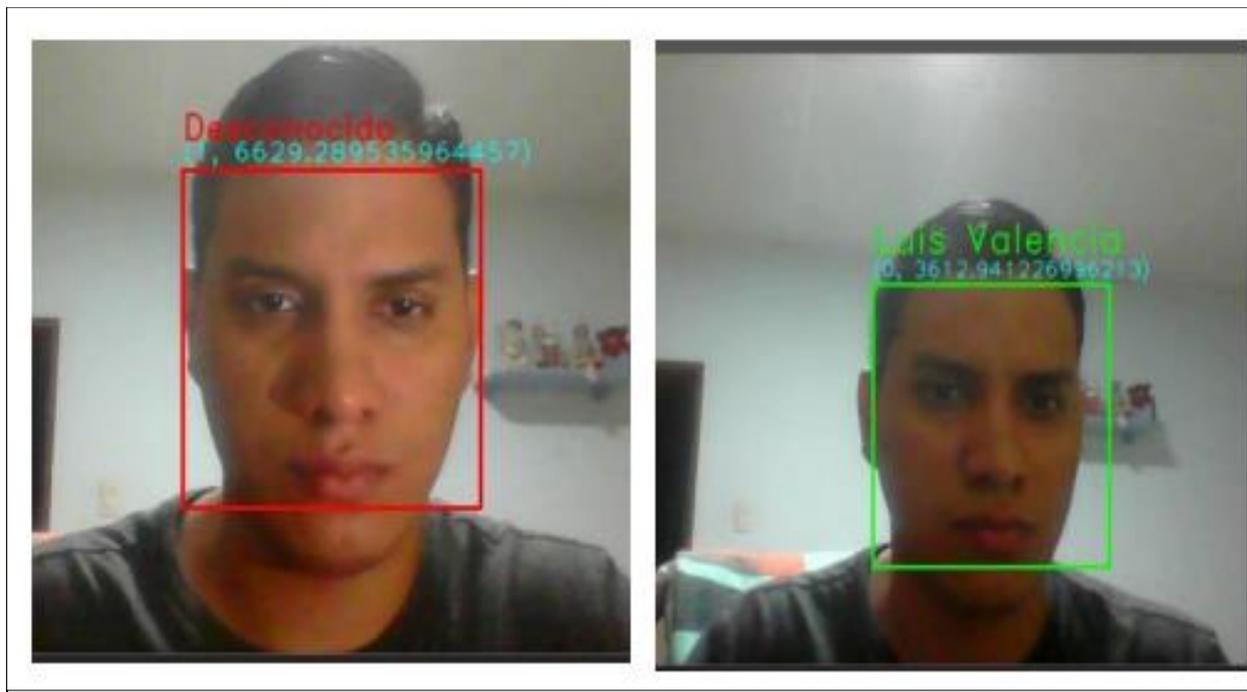


Figura 2.6 Identificación del rostro

Elaborado por: Cáceres & Valencia, 2021

2.1.2 Pronóstico en series de tiempo

Se desarrolla a partir de la base de datos de la institución de Educación Superior, la cual consta de 792080 registros de estudiantes, durante 10 meses, es decir dos periodos académicos ordinarios (mayo septiembre 2017 y octubre marzo 2018).

La data ha llevado un proceso de limpieza profunda y la misma consta de la siguiente información:

Tabla 2.1 Variable del estudio

Variable	Descripción
Id	Identificación del estudiante
Fecha	Fecha de ingreso a la institución
Hora entrada	Hora de ingreso detectada a la institución
Carrera	Carrera a la que pertenece el estudiante
Edificio	Edificio por el cual ingresa el estudiante Campus A: Todas las facultades, excepto facultad de Salud Campus B: Facultad de Salud

Elaborado por: Cáceres & Valencia, 2021

La información de ingreso de los estudiantes se registra diariamente en el acceso o puerta principal de la institución, este dato es almacenado de forma automática, cada vez que ellos presentan la credencial y se almacena en la base de datos del sistema. Tener la posibilidad de predecir la hora de ingreso de los estudiantes permitiría conocer características de estos y en qué momentos hay mayor o menor afluencia de personas. Debido a que los datos de la hora de ingreso (en horas) tienen una fecha específica, es posible modelar a la función univariada como una serie de tiempo, y disponer de la posibilidad de utilizar métodos estadísticos para obtener pronósticos y predicciones.

Para este objetivo se utilizó en primera instancia la herramienta R con las librerías fpp2, forecast y dplyr con el propósito de evaluar diferentes modelos estadísticos de predicción de series de tiempo, en este caso se evaluaron como opciones, los modelos: Naive, Seasonal Naive, Drift y ARIMA.

Inicialmente la serie de tiempo presentaba algunas características que era necesario considerar para poder aplicar las técnicas de pronóstico. Una de ellas, es que la serie estaba incompleta (Figura 2.7), debido a diferentes motivos, muchos de ellos relacionados a que en varias ocasiones los estudiantes ingresan sin presentar apropiadamente su documento de identidad e ingresan por el torniquete o puertas de emergencia, otro de los motivos radica naturalmente en los periodos de vacaciones estudiantiles.

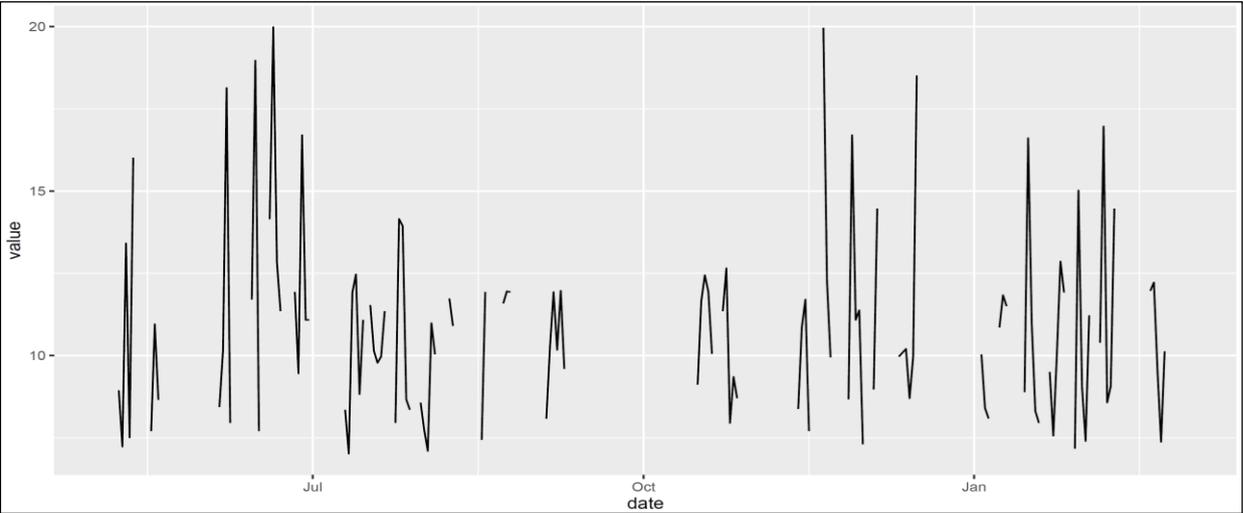


Figura 2.7 Datos de ingreso de estudiante sin procesar

Elaborado por: Cáceres & Valencia, 2021

La solución a este escenario es completar la serie mediante una imputación de datos considerando las características y significado de los valores de ingreso (número en horas), ya que en este caso se podría considerar una solución simple: Asignarles un valor de cero a los días vacíos, sin embargo, el valor cero es una interpretación de ingreso del estudiante a la hora cero de ese día o la media noche, siendo este, un valor erróneo, por lo que no se podría considerar esta alternativa. La mejor alternativa es imputar los datos con aproximaciones en base a sus valores vecinos para mantener el comportamiento de la serie (Figura 2.8).

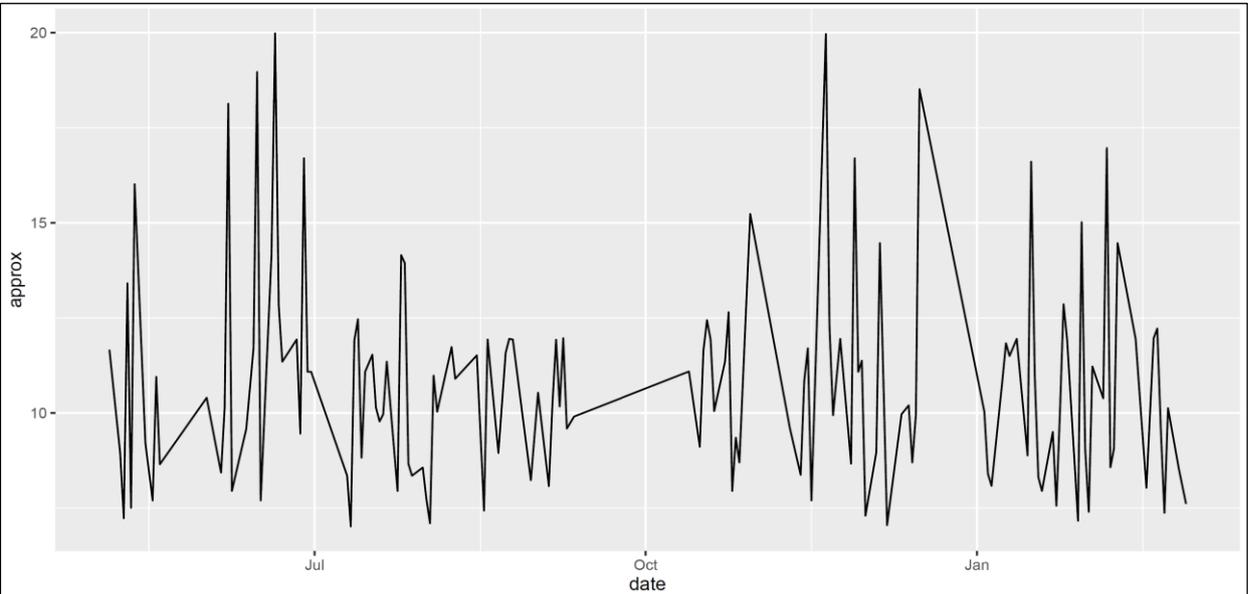


Figura 2.8 Serie de tiempo con datos imputados

Elaborado por: Cáceres & Valencia, 2021

Una vez completada la serie, se procede a aplicar los métodos de pronóstico de series de tiempo para determinar el método óptimo en base a los datos mediante datos de entrenamiento y prueba para validarlos con pronósticos (Figura 2.9).

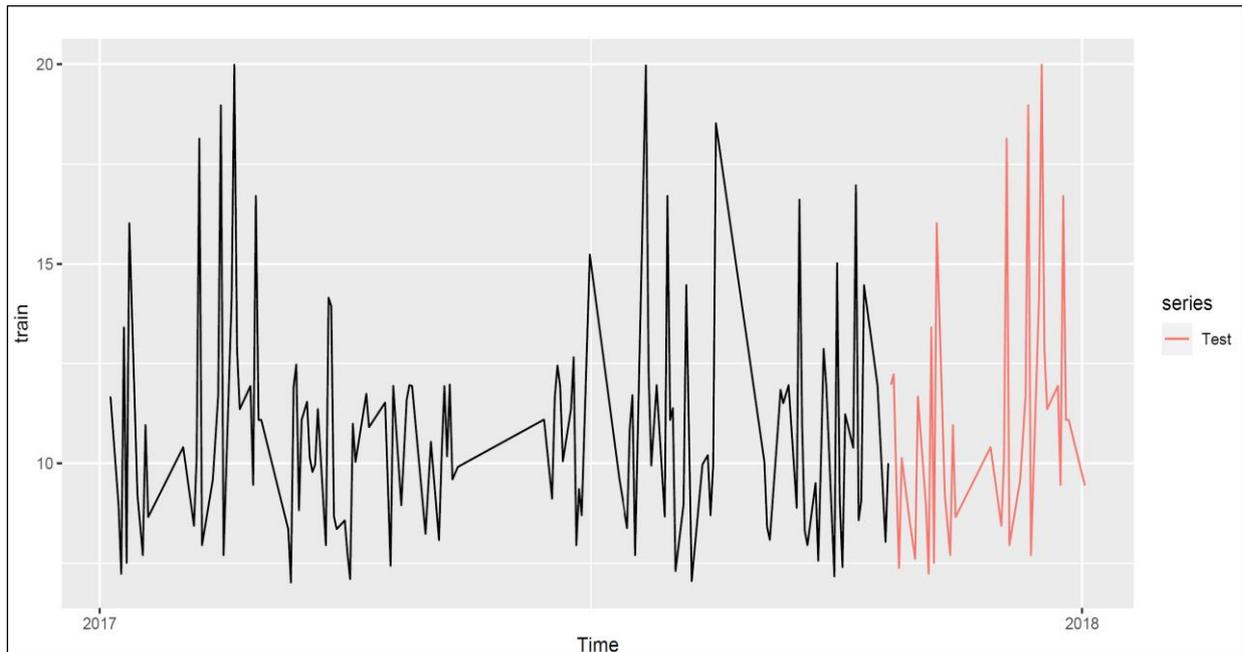


Figura 2.9 Datos de entrenamiento y prueba de la serie

Elaborado por: Cáceres & Valencia, 2021

2.1.2.1 Análisis descriptivo de los datos en series de tiempo

A continuación, se realiza un breve análisis descriptivo de los datos que forman parte del estudio.

Se analiza la distribución de las variables de la base de datos, considerando los datos de la población analizada.

La figura 2.10 señala el ingreso de un estudiante a la institución por hora, en los meses seleccionados para el estudio, la imagen presenta altos y bajos considerando los horarios de ingreso a la institución varían desde las 6:30 am hasta las 10:00 pm. Además, se debe considerar que la imagen en el eje de las X refleja los días de los 10 meses, es decir que se observa los 30 o 31 días de todos los meses, mayo 2017 a febrero 2018.

Además, se refleja el reporte de ingreso a la institución de un estudiante durante ciertos meses, se puede apreciar que entre los meses de julio y octubre se refleja una disminución, esto se debe a que el mes de agosto los estudiantes tienen vacaciones y se acercan a la institución por casos específicos, matriculas, supletorios, recalificaciones, pagos, entre otros. En el mes de diciembre se refleja una caída total, esto se debe a que,

al finalizar el año, la institución está de vacaciones, esto incluye a docentes, administrativos y estudiantes.

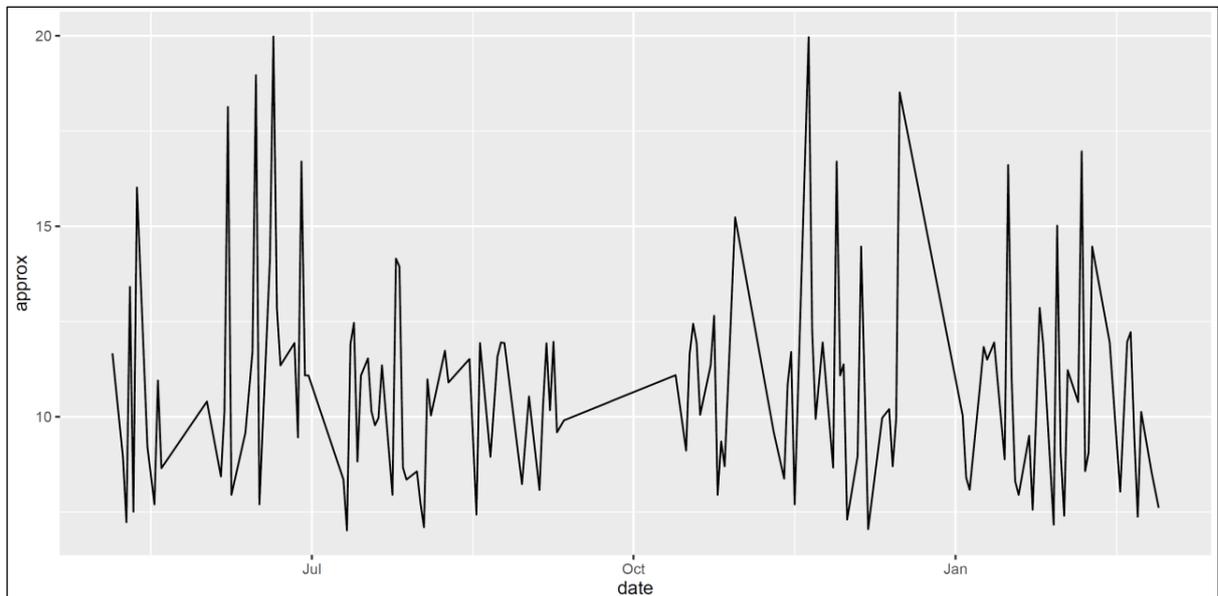


Figura 2.10 Ingreso de un estudiante por horas durante los meses de estudio

Elaborado por: Cáceres & Valencia, 2021

El acceso al campus A y B, tiene dos puertas el acceso con carnet estudiantil con verificación por el personal de seguridad de la Institución y el acceso por medio del torniquete con el uso del código de barras que aparece en el carnet, en la figura 2.10 vemos el ingreso promedio por hora de ingreso a la institución de los estudiantes que forman parte del estudio.

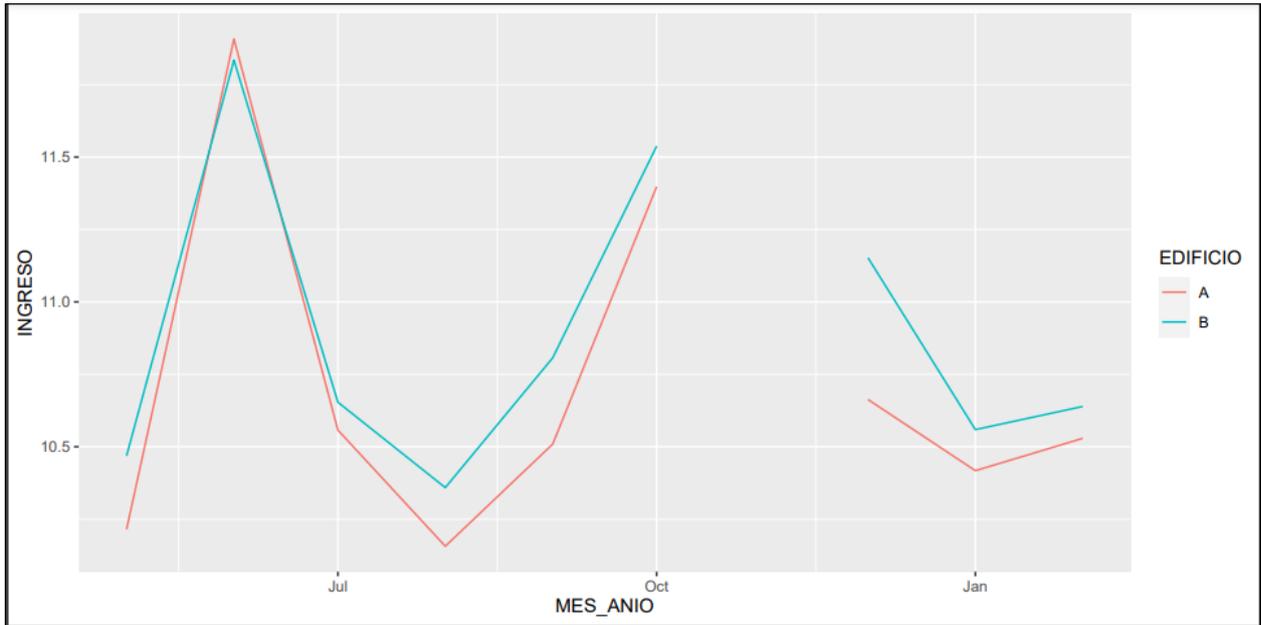


Figura 2.71 Ingreso promedio de los estudiantes al edificio a o b por meses

Elaborado por: Cáceres & Valencia, 2021

La figura a continuación señala el promedio de ingreso de los estudiantes a la institución en los meses de análisis por carreras. Se puede observar que la carrera de Enfermería tiene un promedio de horas de ingreso diferente, esto confirma los horarios de clases de la institución, siendo verpertino para esta carrera y matutino para el resto.

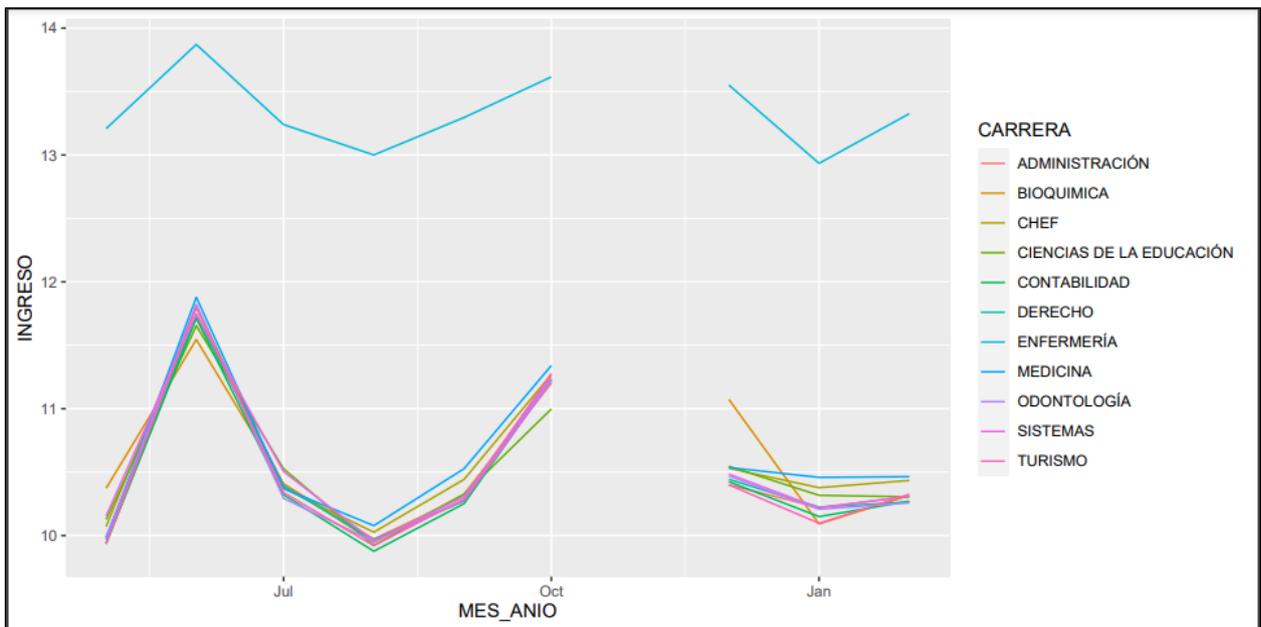


Figura 2.12 Ingreso promedio de los estudiantes por carrera por meses

Elaborado por: Cáceres & Valencia, 2021

2.1.2.2 Modelo de predicción en una serie estacional

Una serie temporal se considera como una sucesión de observaciones en una cierta variable en intervalos regulares de tiempo, para llevar a cabo este proceso se debe considerar que exista entre los datos una cierta estabilidad en la estructura de las variables objeto de estudio, es decir que será necesario estudiar períodos lo más homogéneos posibles.

A fin de dar cumplimiento a la identificación de patrones de comportamiento de los estudiantes a partir de las series de tiempo registradas en los controles de acceso, es importante considerar el comportamiento de una variable a través del tiempo, bajo el supuesto de que no se sufrirá cambios estructurales y se podrá realizar predicciones.

A partir de la figura 2.13 se muestra el resultado de pronóstico en series de tiempo realizada en R-Estudio, en base a modelos de predicción, esto se ha generado por datos agrupados del estudiante.

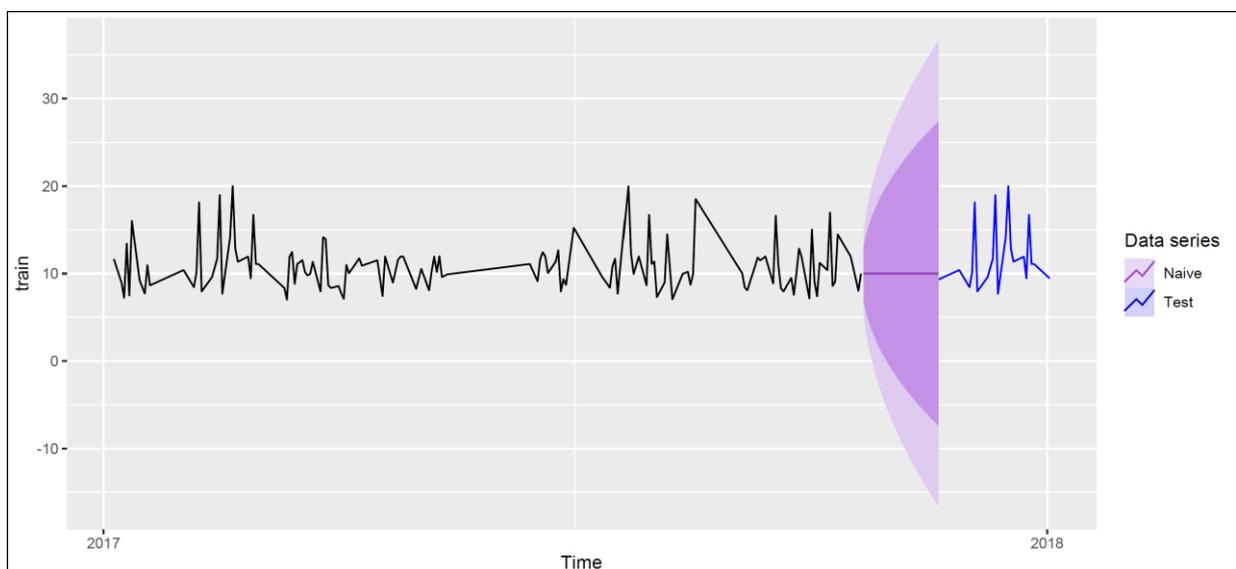


Figura 2.83 Método de pronóstico Naive

Elaborado por: Cáceres & Valencia, 2021

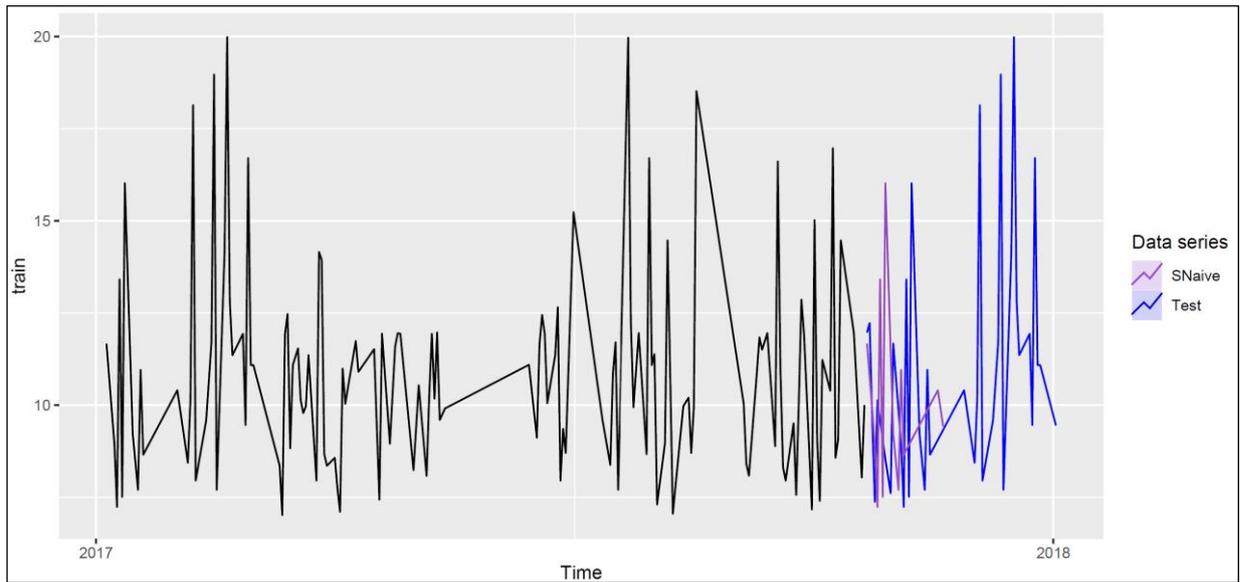


Figura 2.14 Método de pronóstico Seasonal Naive

Elaborado por: Cáceres & Valencia, 2021

Se ha ejecutado cuatro modelos de predicción a fin de seleccionar el más óptimo para el presente estudio.

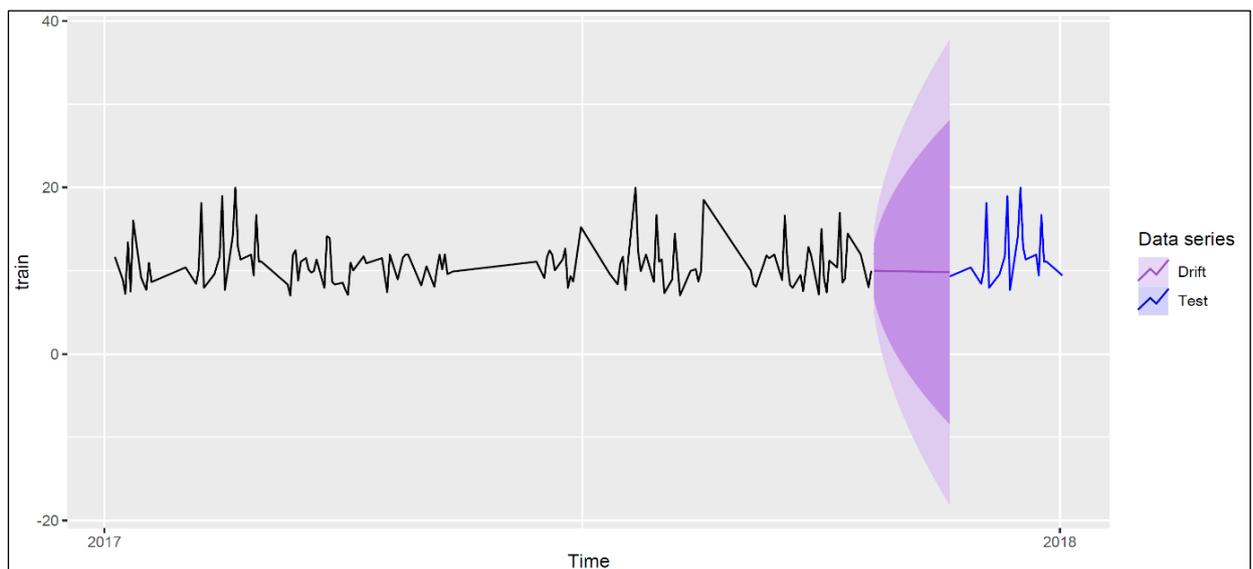


Figura 2.15 Método de pronóstico Drift

Elaborado por: Cáceres & Valencia, 2021

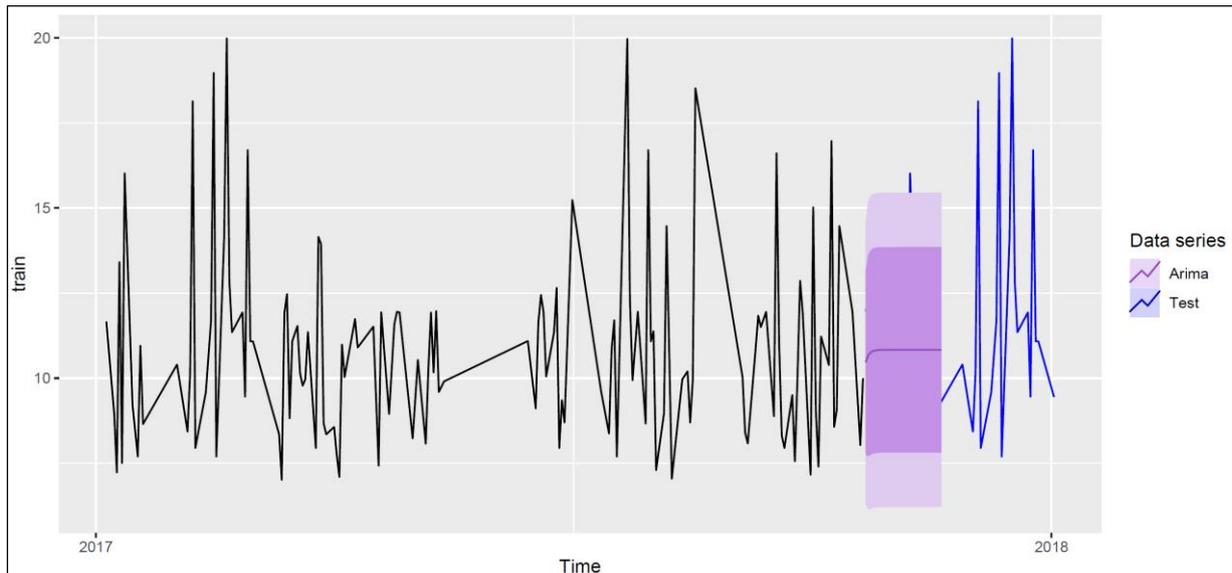


Figura 2.16 Método de pronóstico ARIMA

Elaborado por: Cáceres & Valencia, 2021

Si bien, el pronóstico de ARIMA, para este caso, no determina estacionalidad de forma automática, en base a la información histórica, es posible determinar un promedio de ingresos del estudiante en periodos de tiempo determinado durante el año.

En virtud de la gráfica, se ha identificado que el modelo para predecir en el presente estudio se llevará a cabo mediante ARIMA.

Box y Jenkins son los desarrolladores de modelos estadísticos para series de tiempo, las cuales tienen como objetivo verificar la dependencia que existe entre los datos que son modelados en función de valores anteriores. Los análisis están basados en el modelo ARIMA (AutoRegresive Integrated Moving Average), el cual contiene tres componentes AR (Autoregresivo), D(Diferencia) y MA (Medias Móviles).

- **Autorregresivo (AR):** a partir de los datos de una serie temporal definida tiene su valor de retraso, el cual es representado por el valor P en el modelo.
- **Diferencia (D):** consiste en diferenciar los datos de series de tiempo para eliminar tendencias y convertir series de tiempo no estacionarias en series de tiempo estáticas, el cual es representado con el valor 'd'.

- **Median móvil (MA):** el modelo está representado por el valor de 'q' el cual es denominado como número de retrasos en el término de error.

El modelo ARIMA se describe como una función lineal de datos del pasado y errores que se deben al azar, además, se puede incluir un componente cíclico o estacional, es decir, debe contener todos los elementos necesarios para describir el fenómeno de estudio. Los autores del modelo recomiendan utilizar un número mínimo de 50 observaciones en la serie temporal.

2.1.2.3 Predicción

El comportamiento de estudiantes de nivel superior se ha llevado a cabo mediante el análisis de series de tiempo, a partir de la base de datos de controles de acceso de la institución, la cual refleja datos como: fecha, hora de entrega, edificio, carrera.

Obteniendo la data como indica el flujo de la figura 2.15 se genera la información en el proceso de identificación, con el cual se almacenará la fecha y hora de registro mediante esto datos se puede realizar una predicción a través del modelo ARIMA, el cual es un modelo estadístico para series de tiempo que utiliza el pasado de la serie para predecir a corto plazo.

Luego de identificado el rostro de los estudiantes, en forma automática se predice el ingreso de los estudiantes, en base al almacenamiento de los datos del pasado.

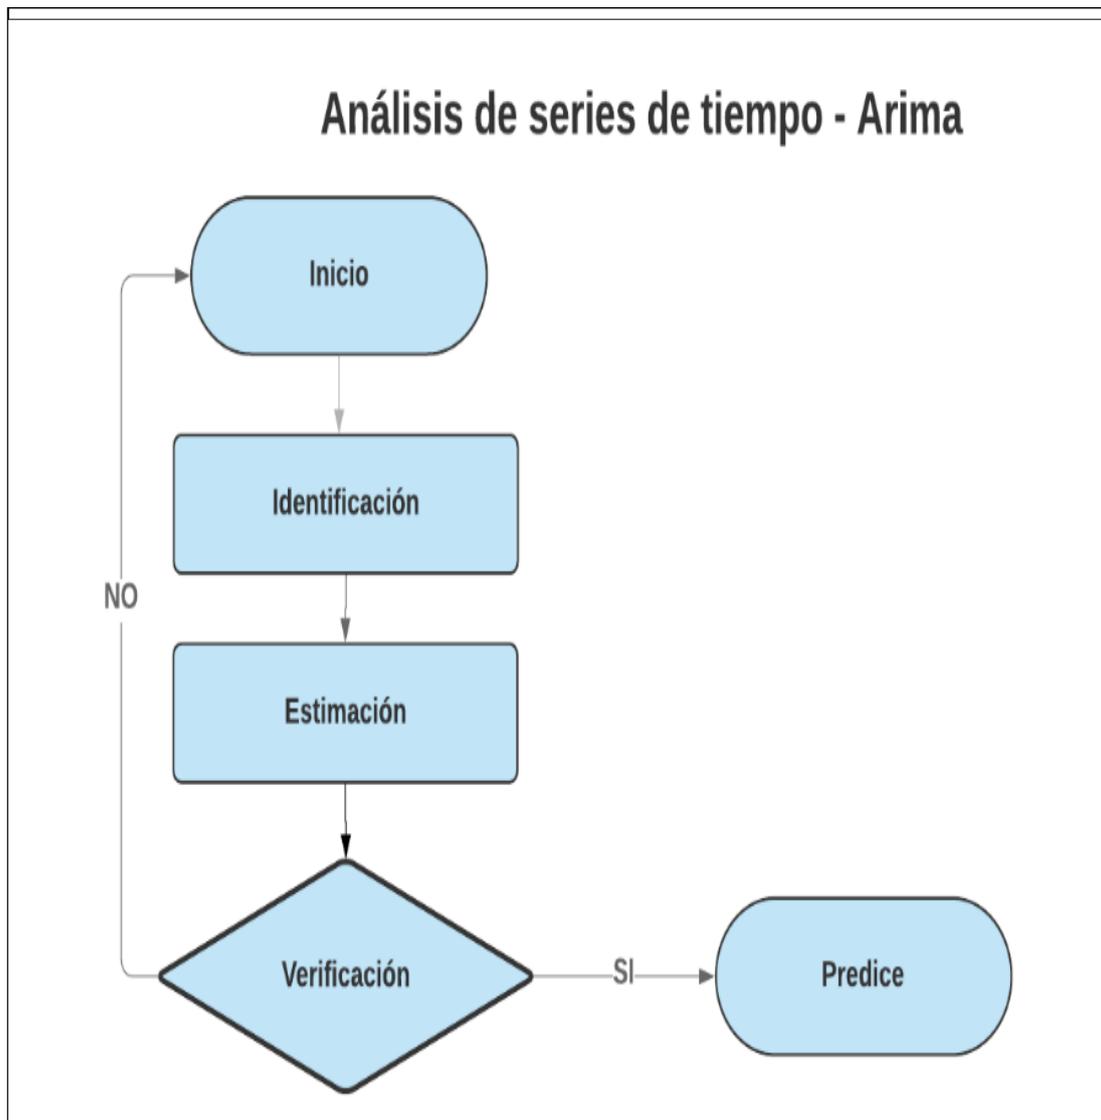


Figura 2.17 Arquitectura de la serie de tiempo - ARIMA

Elaborado por: Cáceres & Valencia, 2021

CAPÍTULO 3

3. RESULTADOS Y ANÁLISIS

El presente proyecto fue direccionado al reconocimiento de rostros de estudiantes de una institución de educación superior mediante una técnica de reconocimiento facial en tiempo real, además de caracterizar el comportamiento de los estudiantes por medio de los registros de ingresos de la institución, específicamente con la fecha, hora de ingreso de los alumnos, las ramas de estudio que se entremezclan son la inteligencia artificial, series de tiempo y pronósticos y visualización de datos, áreas que permitieron observar tendencias de mejora a la industria educativa, que en el presente estudio busco ir más allá de las técnicas tradicionales de competencia interinstitucional y lograr generar una cultura educativa que conlleve a la mejora continua de sus estudiantes.

La presente investigación, de acuerdo con uno de sus objetivos: *Extraer características relevantes de un rostro con redes convolucionales que permitan lograr una alta precisión en el reconocimiento facial*, ha logrado su cumplimiento total considerando el proceso desarrollado, desde capturar una imagen, detectar el rostro, realizar el reconocimiento facial, comparar este rostro con la data de imágenes de los alumnos de dos periodos académicos de una institución y permitir o no el ingreso de los estudiantes a las instalaciones, mediante el uso de modelos pre-entrenado como MobileNet y FaceNet los cuales, bajo análisis y comparaciones realizadas, fueron los modelos óptimos para el cumplimiento de este objetivo del estudio.

Además, el *Identificar patrones de comportamiento de los estudiantes a partir de las series de tiempo registradas en los controles de acceso*, fue un proceso que logró su cumplimiento a partir del análisis y limpieza profunda de su base de datos con variables indispensables como id de imagen, nombre, fecha de ingreso, etc., y comparación de distintos modelos de predicción, obteniendo mejores resultados para este estudio el modelo estadístico de predicción ARIMA, el cual permite realizar el pronóstico de ingreso de los estudiantes hasta 20 días a partir del último ingreso.

Al final del proyecto se obtuvo un sistema de control de acceso por reconocimiento facial, mismo que permitió generar pronósticos en series de tiempo, a partir de la

caracterización del comportamiento de los estudiantes frente a los reportes de ingreso a la institución.

A continuación, se presenta a detalle los resultados para cada uno de los objetivos del estudio, considerando como dos módulos: reconocimiento facial y series de tiempo.

3.1 Recolección de datos resultantes de reconocimiento facial

3.1.1 Detección facial

Se utilizó un modelo pre-entrenado denominado MobileNet el cual cuenta con un accuracy de 71.8 con una reducción en el número de parámetros esto con la finalidad de hacer su procesamiento más rápido, con la red ya mencionada los movimientos en la captura de video son más naturales y esto se da por el número menor de operaciones requeridas durante la detección, este proceso fue comparado con el modelo pre-entrenado MTCNN, del cual se obtuvo un resultado similar de efectividad 71,9 pero el inconveniente encontrado en este modelo fue su procesamiento lento, dado su uso de tres redes neuronales, por el ende el tiempo de ejecución de la red en tiempo real se incrementa.

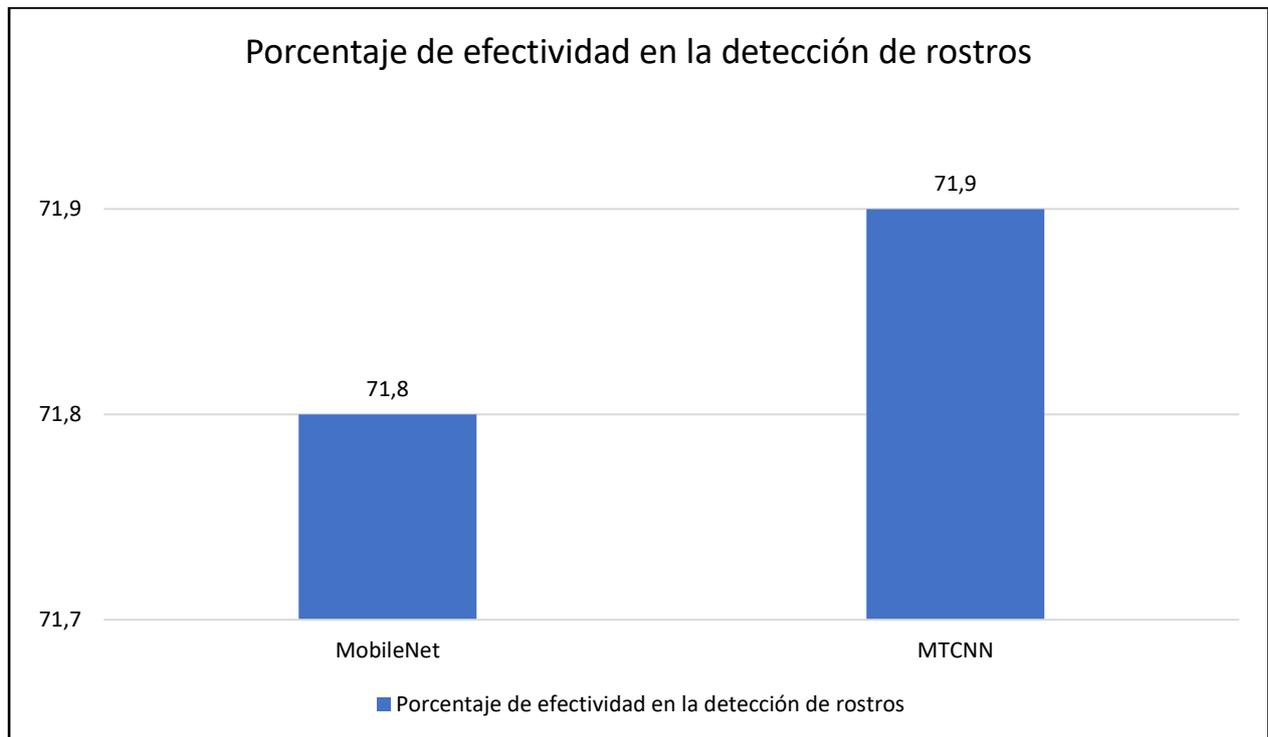


Figura 3.1 Efectividad de la detección de rostros

Elaborado por: Cáceres & Valencia, 2021

A su vez este modelo se utilizó en el procesamiento de 1500 imágenes en tamaño carnet para realizar la extracción de los rostros de cada imagen RGB haciendo un Resize de (160x160) con el objetivo de formar una matriz, la cual se convertirá en 128 puntos usando la función Predict la cual es originaria del modelo de FaceNet, utilizado para la detección e identificación de rostros, basada en una arquitectura de red convolucional el cual estudia y establece el rostro en una dimensión euclidiano, una vez obtenido la dimensión tanto la detección e identificación de rostros. Utilizando dichos modelos por medio de técnicas de transfer Learning de FaceNet, se obtiene un resultado de Accuracy del 98.57, una Precisión del 100, Recall 97.14 y un F1 98.55 (Rajput, 2019).

A partir de los resultados obtenidos en la comparación de distancia euclidiana en los dos modelos pre-entrenados figura 3.2. que se utilizó, se considera desarrollar el presente estudio, con el modelo FaceNet.

Al utilizar una red neuronal profunda la extracción de características de las imágenes es mucho más representativa a diferencia de usar un modelo de aprendizaje automático. Uno de los problemas al utilizar estas redes es que no se puede probar su máxima

funcionalidad con pequeñas cantidades de datos, por lo cual se utilizó modelos ya entrenados que cumplen esta peculiaridad de una gran data para así conservar el conocimiento de como compilar las imágenes de los rostros, a su vez el ajuste realizado en SVM mejora la precisión obtenida.

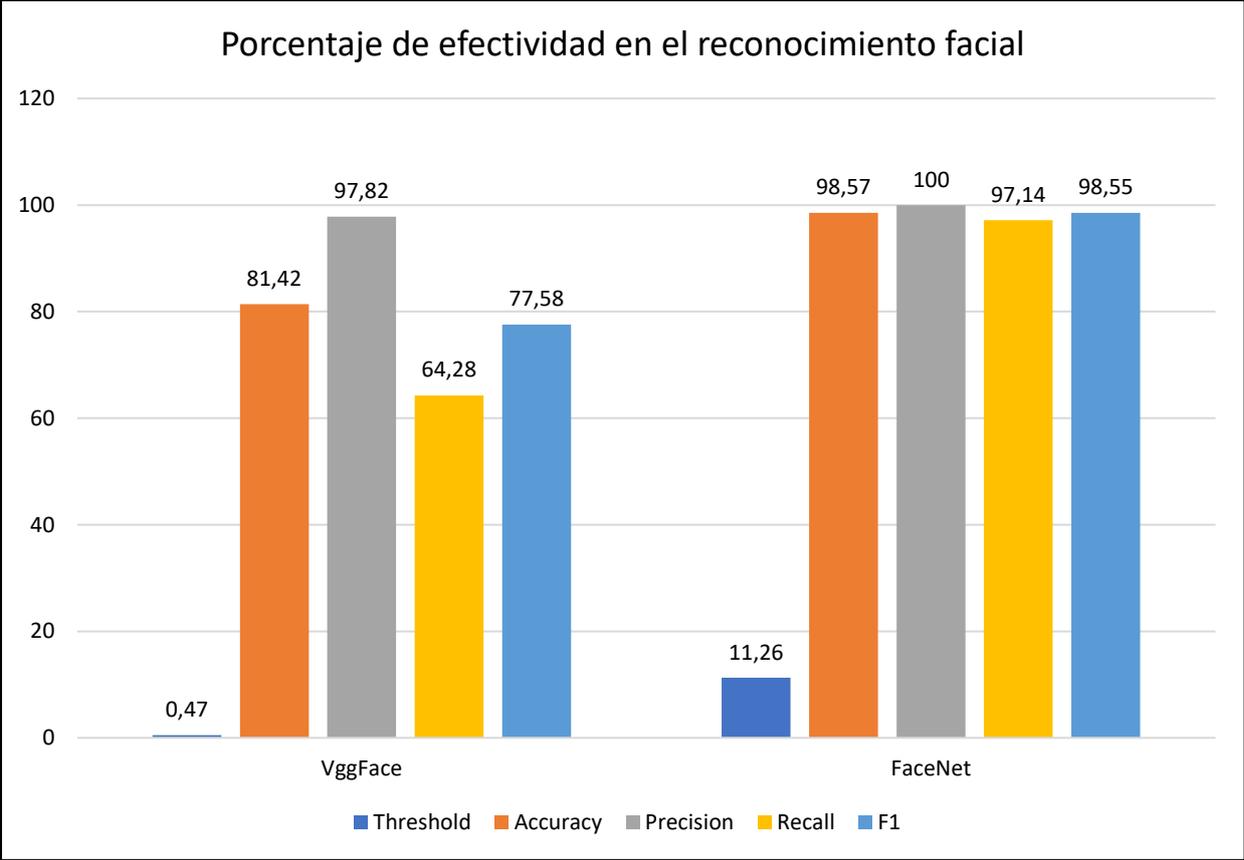


Figura 3.2 Comparación de distancia euclidiana en modelos pre-entrenados para reconocimiento de rostros

Elaborado por: Cáceres & Valencia, 2021

El entrenamiento del modelo MobileNet para detectar un rostro en el presente estudio ha reflejado resultados de 71.8 de accuracy. En la figura 3.3 se observa un ejemplo del funcionamiento de la detección únicamente del rostro de un individuo en una imagen de entrada.

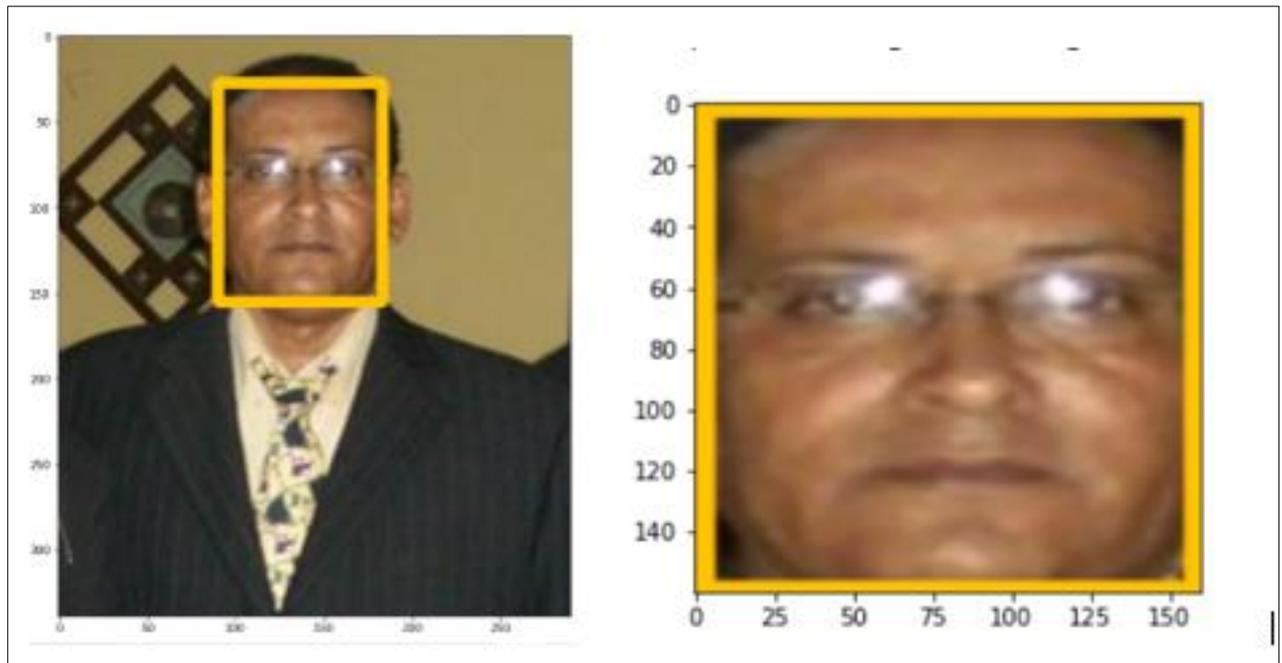


Figura 3.3 Detección de rostro en una imagen

Elaborado por: Cáceres & Valencia, 2021

3.1.2 Reconocimiento facial

En los estudiantes de una Institución de Educación Superior a partir de la técnica one-shot learning utilizada, es decir una red convolucional se ha extraído las características relevantes de un rostro permitiendo lograr una alta precisión en el reconocimiento facial.

La verificación trata de la comparación de un rostro desconocido con las imágenes de referencia y así el sistema permite el rechazo o la confirmación de la identidad de los estudiantes en el ingreso a la institución de Educación Superior, objeto de estudio.

Se procede a completar el proceso de la arquitectura diseñada para dar cumplimiento a los objetivos del presente proyecto, mediante el modelo de reconocimiento facial pre-entrenado FaceNet, el cual de acuerdo con los parámetros establecidos genera el embedding correspondiente.

La figura 3.4 evidencia los embedding, es decir un vector normalizado de 128 datos cada uno, el mismo se genera en Python mediante el proceso one-shot learning, por cada uno de los usuarios de la base de datos inicial, es decir el procesamiento de la data que forma parte del estudio.

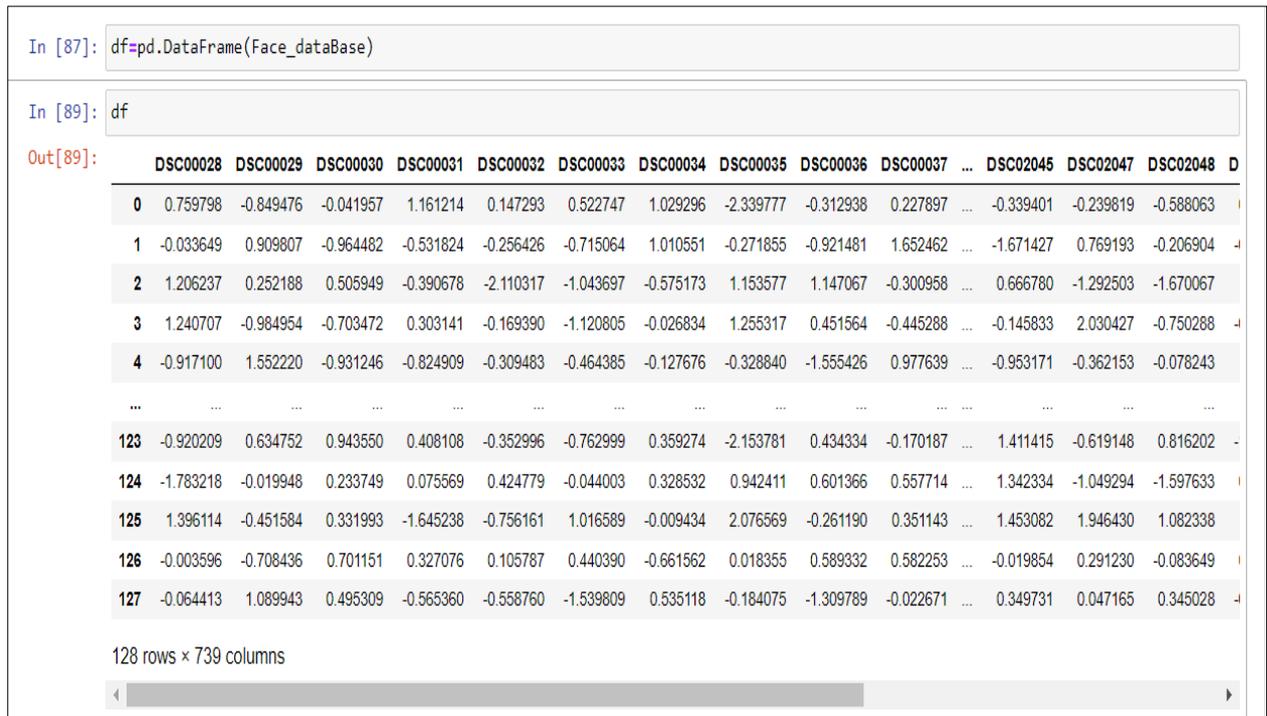


Figura 3.4 Resultados de la data
 Elaborado por: Cáceres & Valencia, 2021

La figura 3.5 muestra una imagen de referencia almacenada (izquierda) y una imagen de entrada (derecha) coincidiendo entre ellas su rostro, su única diferencia es visible en sus ojos. El procesamiento de la data para reconocimiento facial utiliza distancia euclidiana, la cual se refleja en el número mostrado en la parte superior de las imágenes. Debido a que se trata del mismo rostro, la distancia es mínima y se reconoce correctamente su identidad sin error.

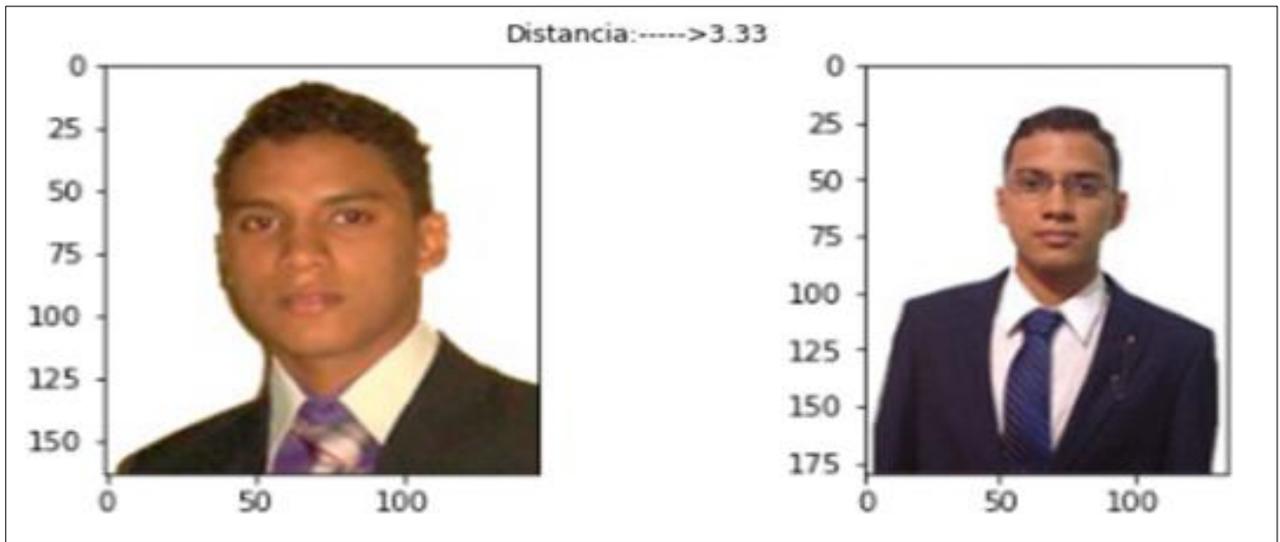


Figura 3.5 Distancia euclidiana

Elaborado por: Cáceres & Valencia, 2021

La figura 3.6 se evidencia el id de la persona identificada y en la figura a continuación refleja incluso los datos personales del rostro a partir del resultado de la distancia euclidiana que se genera entre la imagen almacenada y procesada, confirmando de esta manera el funcionamiento correcto de los modelos utilizados en el presente estudio.

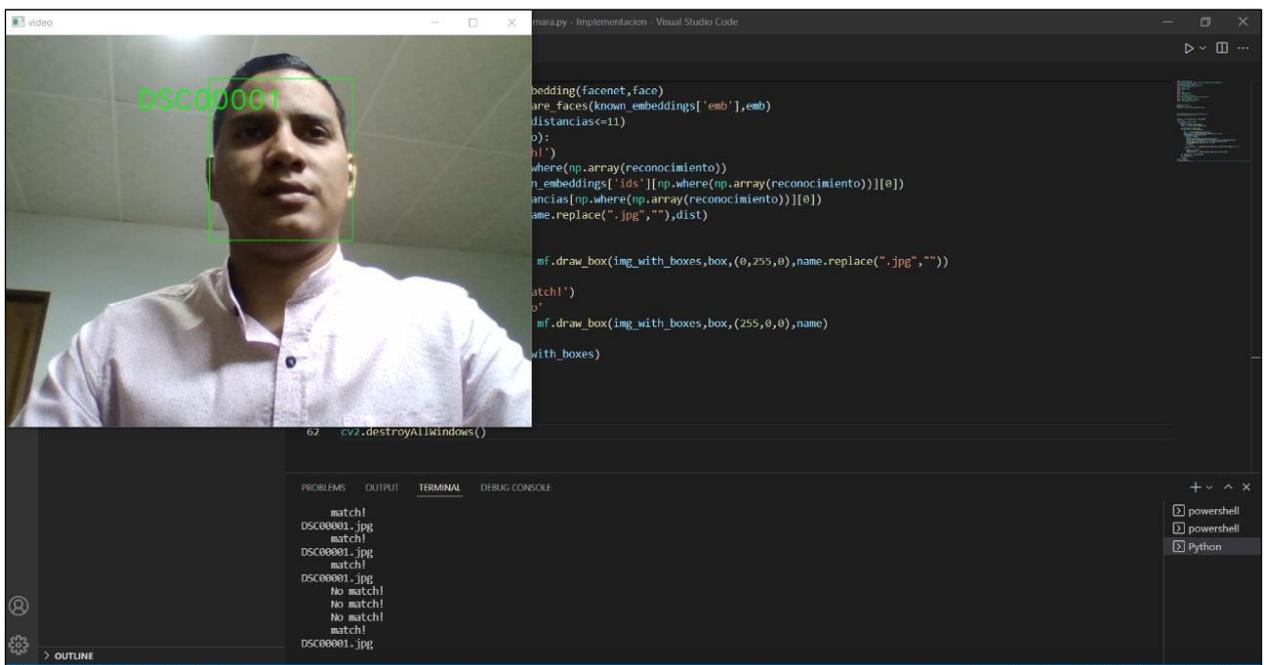


Figura 3.6 Identificación de rostro mediante ID

Elaborado por: Cáceres & Valencia, 2021

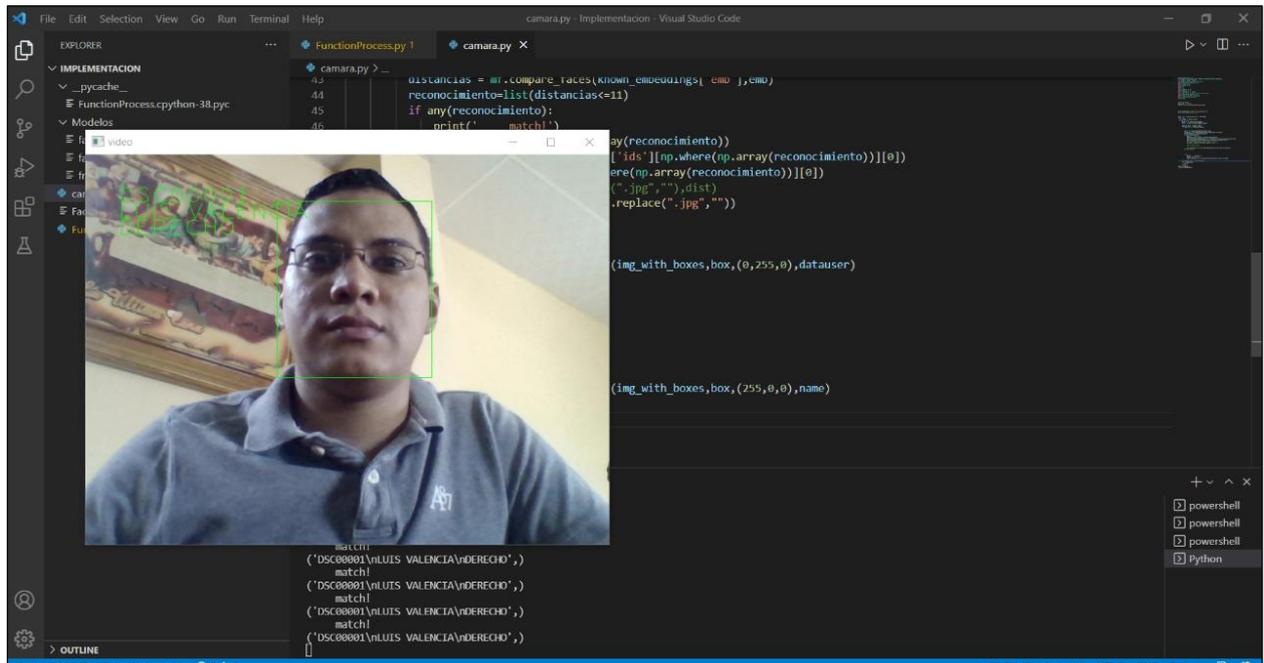


Figura 3.2 Identificación de rostro con nombre y apellido

Elaborado por: Cáceres & Valencia, 2021

La figura 3.8 refleja los resultados del procesamiento 800 imágenes en formato JPG la cual se dividió en trainit y test cada una de las imágenes con su eje Y & X, las cuales con el uso del modelo SVC lineal (Support Vector Classifier) nos brinda un hiperplano con el que podemos dividir o categorizar nuestros datos, el resultado obtenido fue un: accuracy: train=100 y test= 93.75. El procesamiento de datos se llevó a cabo mediante programación en el lenguaje de programación.

```

from sklearn.metrics import accuracy_score
from sklearn.preprocessing import LabelEncoder
from sklearn.preprocessing import Normalizer
from sklearn.svm import SVC

print("Dataset: train=%d, test=%d" % (EndTrainX.shape[0], emdTestX.shape[0]))
# normalize input vectors
in_encoder = Normalizer()
emdTrainX_norm = in_encoder.transform(EndTrainX)
emdTestX_norm = in_encoder.transform(emdTestX)
# label encode targets
out_encoder = LabelEncoder()
out_encoder.fit(Trainy)
trainy_enc = out_encoder.transform(Trainy)
testy_enc = out_encoder.transform(testy)
# fit model
model = SVC(kernel='linear', probability=True)
model.fit(emdTrainX_norm, trainy_enc)
# predict
yhat_train = model.predict(emdTrainX_norm)
yhat_test = model.predict(emdTestX_norm)
# score
score_train = accuracy_score(trainy_enc, yhat_train)
score_test = accuracy_score(testy_enc, yhat_test)
# summarize
print('Accuracy: train=%.3f, test=%.3f' % (score_train*100, score_test*100))

Dataset: train=739, test=16
Accuracy: train=100.000, test=93.750

```

Figura 3.3 Resultados de la data
 Elaborado por: Cáceres & Valencia, 2021

3.2 Recolección de los resultados de las series de tiempo.

A partir del tratamiento a la base de datos del registro de ingresos de los estudiantes a la Institución de Educación, se evidencia en la figura a continuación ciertas variables objeto de estudio, listas para su ejecución en el lenguaje de programación Python.

In [6]: dflista.head()

Out[6]:

	APELLIDOS	NOMBRES	CEDULA	CARRERA	MODALIDAD	LINK FOTOGRAFIA
0	CASTILLO QUINTANA	LORENA L.	7	ADMINISTRACION	PRESENCIAL	DSC00035.JPG
1	PICO PAREDES	TANNIA	10	ADMINISTRACION	PRESENCIAL	DSC00047.JPG
2	MAIZANCHO TOPANTA	ALEXANDRA	0	ADMINISTRACION	PRESENCIAL	DSC00054.JPG
3	MEDINA VALENCIA	SANTIAGO	1000000004	ADMINISTRACION	PRESENCIAL	DSC00059.JPG
4	MEDINA HERRERA	MELINA	1000000002	ADMINISTRACION	PRESENCIAL	DSC00061.JPG

Figura 3.4 Identificación de rostro
 Elaborado por: Cáceres & Valencia, 2021

El procesamiento de los registros de la base datos objeto del estudio fueron previamente tratados mediante la función de autocorrelación diff (difference in differences) a fin de lograr una serie estacionaria, lo que permite realizar la predicción individual y mediante el modelo de predicción estadístico ARIMA, presentando los resultados a continuación:

3.2.1 Predicción

Luego de ser ejecutados varios modelos para la predicción de ingreso de estudiantes, se ha concluido que el modelo más apropiado es ARIMA, en base al RMSE (Root Mean Square Error) el cual demuestra valores de pronóstico e intervalos de confianza más apropiado basado en los datos históricos del estudiante.

METODO	ME	RMSE	MAE	MPE	MAPE	MASE
Naive	0.524204718	2.583759	1.677448	0.629039	14.54841	NA
SNaive	-0.048721461	3.771451	2.78598	-5.79094	26.54683	NA
Drift	0.737584188	2.66838	1.717197	2.678282	14.65167	NA
ARIMA (auto)	-0.979916228	2.287178	2.001333	-14.2111	21.66722	NA

Tabla 3.1 Comparación de los métodos de pronóstico

Elaborado por: Cáceres & Valencia, 2021

Una vez procesada la información mediante los ajustes correspondientes en el modelo ARIMA, se obtiene los siguientes resultados, para presentación del presente escrito se ha considera el pronóstico a veinte días.

El modelo ARIMA con los parámetros p,d y q obtenidos de R fue codificado en Python para poder utilizar librerías de ciencia de datos como Pandas, Numpy y modelos estadísticos de pronóstico desde la librería statsmodel con SARIMAX.

Esta metodología toma las horas de ingreso del estudiante, se determina un promedio diario y se pronostica en base a su información histórica cual será la hora a la que el ingresará en días posteriores. En la figura 3.10 se evidencia el resultado luego de realizados los ajustes necesarios para que el resultado de la predicción.

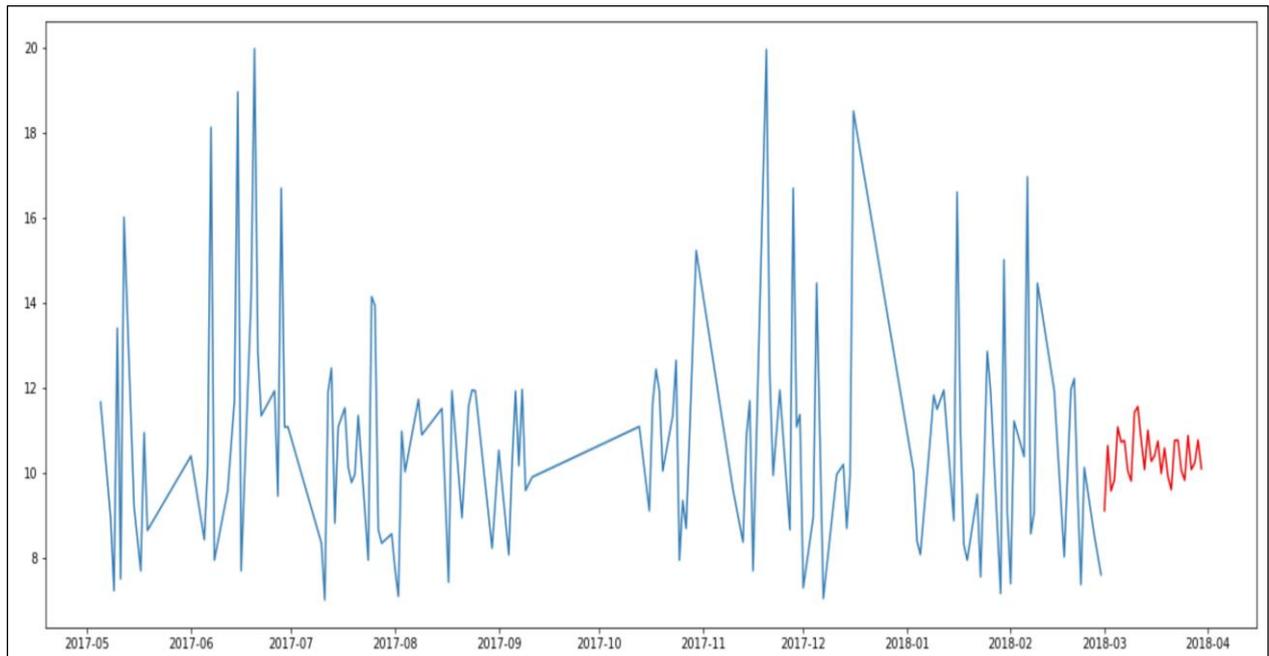


Figura 3.5 Pronóstico de ingreso del estudiante en 20 días posteriores

Elaborado por: Cáceres & Valencia, 2021

Se ha incluido una tabla de visualizaciones para cada usuario identificado, luego de verificado un rostro, la cual refleja la fecha y la hora de pronóstico, durante 20 días, esto a partir de la data histórica.

Las dos figuras a continuación son el reflejo de dos estudiantes tomados al azar e identificados previamente y colocados en el documento para su ejemplificación de resultados, esto en la página web.

Luego de revisada la base de datos, el Usuario DSC00479, pertenece a un estudiante, de la carrera de Contabilidad, y su sección de clases es en horario matutino.

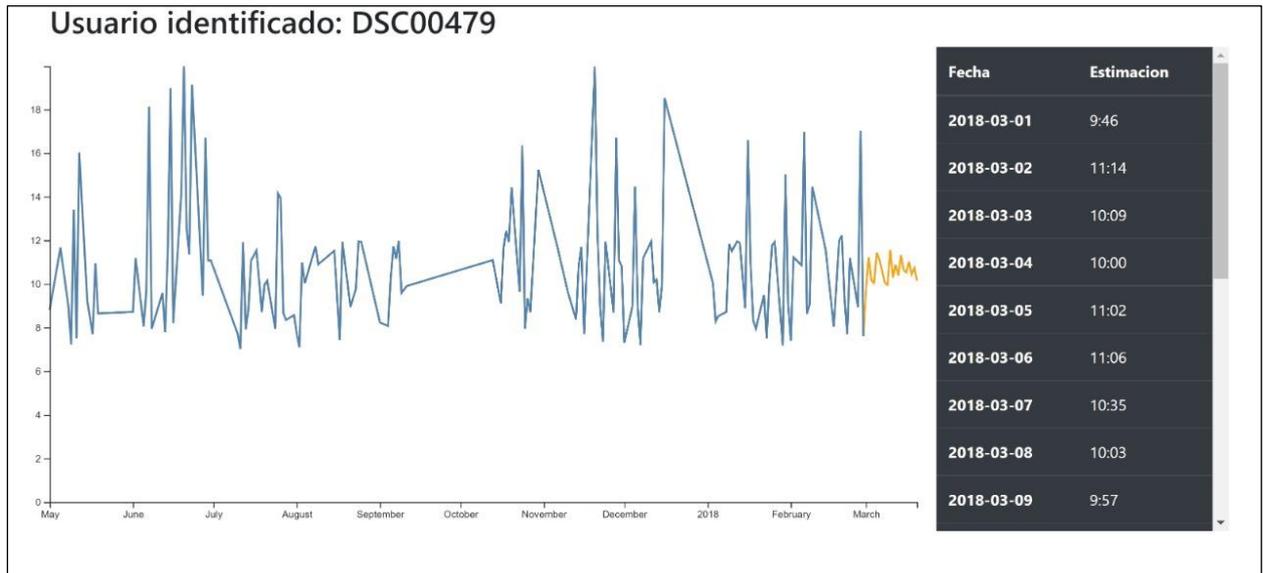


Figura 3.61 Pronóstico de ingreso del estudiante DSC00479

Elaborado por: Cáceres & Valencia, 2021

Luego de revisada la base de datos, el Usuario DSC00780, pertenece a un estudiante, de la carrera de Chefs, y su sección de clases es en horario matutino.

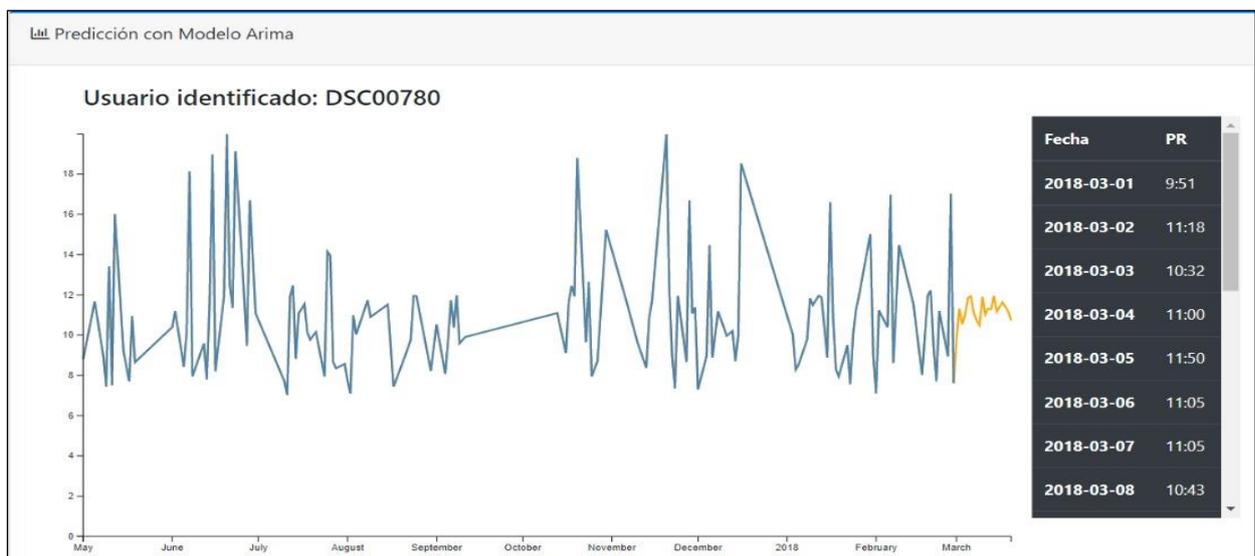


Figura 3.72 Pronóstico de ingreso del estudiante DSC00780

Elaborado por: Cáceres & Valencia, 2021

3.3 Puesta en marcha y funcionamiento del sistema de control de acceso e identificación de patrones

El funcionamiento del sistema del presente proyecto se refleja en la figura 3.13. El reconocimiento facial y caracterización del comportamiento estudiantil mediante el control de acceso del presente estudio se lleva a cabo mediante el proceso que inicia con el ingreso de los estudiantes a la institución por el edificio a o b, a continuación se realiza la detección facial mediante el modelo MobileNet, seguido del reconocimiento facial mediante el modelo preentrenado FaceNet, el cual permite obtener características a las que denominaremos embedding, los cuales son comparados mediante distancia euclidiana con los embedding de los rostros almacenados y así obtener la identidad de los estudiantes que ingresan a la institución. Una vez verificado el acceso, automáticamente se guardan los datos como Id del estudiante, nombres, apellidos, hora de ingreso, carrera y edificio en una base SQL, los cuales están configurados para que automáticamente generen el pronóstico en base al modelo ARIMA. La visualización de los resultados se encuentra publicado en un desarrollador web Django, la cual presenta un pronóstico a 20 días de los estudiantes objeto de estudio.

La implementación esta seccionada en 2 módulos, los cuales corresponden al control de acceso por reconocimiento facial y a identificación de patrones. Sistema al que puede acceder el estudiante y el administrados del mismo.

El control de acceso se realiza localmente en un ejecutable .py que tiene almacenado los embedding de los rostros entrenados en un archivo .npz con los Id que corresponda a cada embedding. De esa forma se captura mediante video la imagen de la persona que va a acceder y se procesa el embedding correspondiente para hacer una comparación con los embedding almacenados. Una vez identificada la persona, se almacena la fecha de ingreso en una base de datos, la cual se usa para la identificación de patrones, esto es, para predecir en que tiempo llegará a futuro a partir de los datos históricos, estos datos serán visualizados por el usuario en una aplicación web la cual mostrará graficas de su comportamiento de llegada a la Institución Educativa.

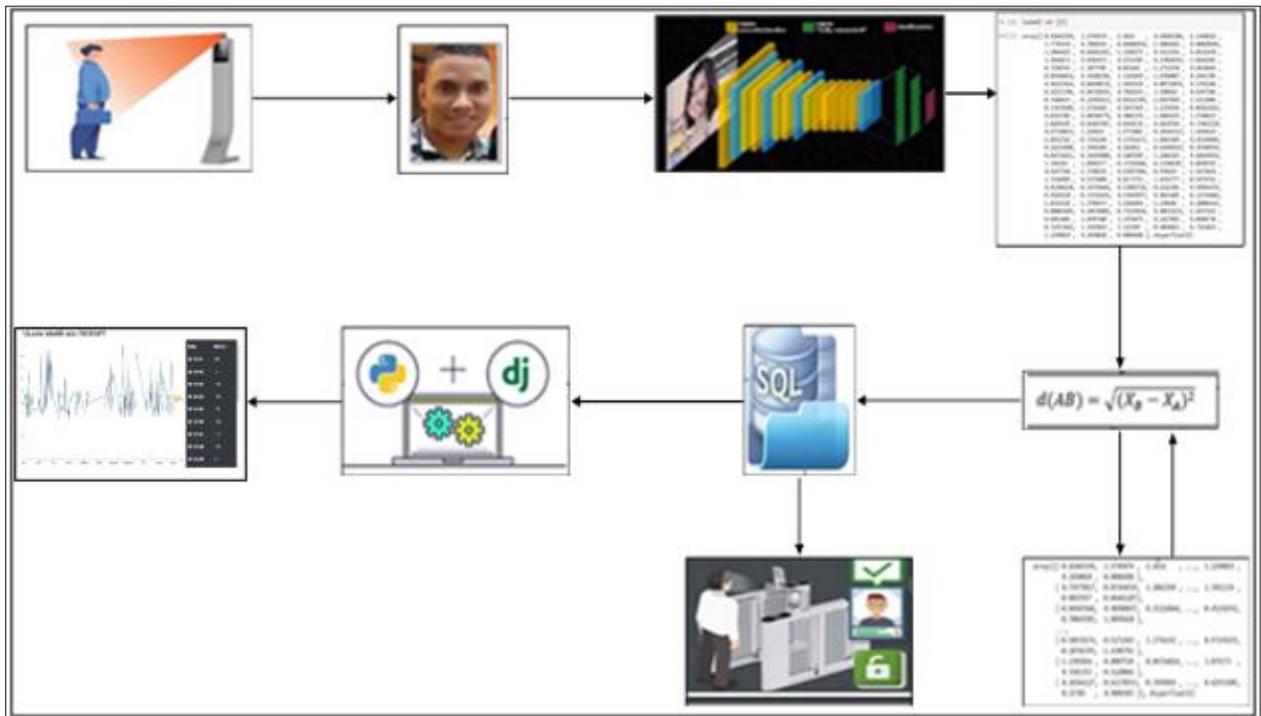


Figura 3.8 Reconocimiento facial y caracterización del comportamiento estudiantil

Elaborado por: Cáceres & Valencia, 2021

Como parte del proceso de implementación del desarrollo del código en Python se utilizó un notebook de Jupyter para replicar los pasos necesarios, obteniendo como resultado del reconocimiento facial, el rostro identificado, con id, nombre, apellido y carrera a la que pertenece.

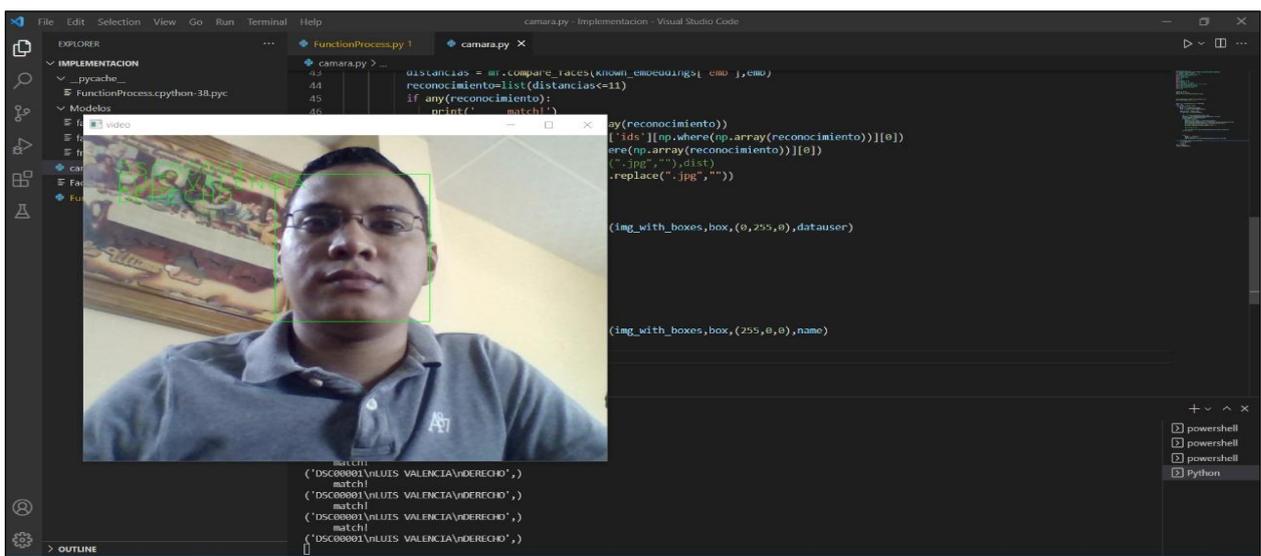


Figura 3.14 Identificación interna de rostro, con id, nombre y apellido

Elaborado por: Cáceres & Valencia, 2021

El resultado final para el pronóstico fue una metodología representada en Django para el procesamiento de la información histórica del estudiante para generar pronósticos, generada a partir de todo el análisis y procesamiento detallado en esta investigación.

Los datos fueron almacenados en una tabla de la base de datos del sistema, con el propósito de trabajar directamente con el modelo en el framework Django. La información es procesada por una vista que toma los datos del estudiante disponible y genera un dataset limpio con los datos promediados de forma diaria, y los datos faltantes interpolados.

El presente proyecto tiene acceso para el estudiante y administrador. A su vez el estudiante puede realizar su ingreso al sistema con reconocimiento facial o si requiere mediante un usuario y contraseña asignado.

La Figura 3.15, señala la página web en donde se requiere de un acceso por parte del administrador, para el funcionamiento del sistema.

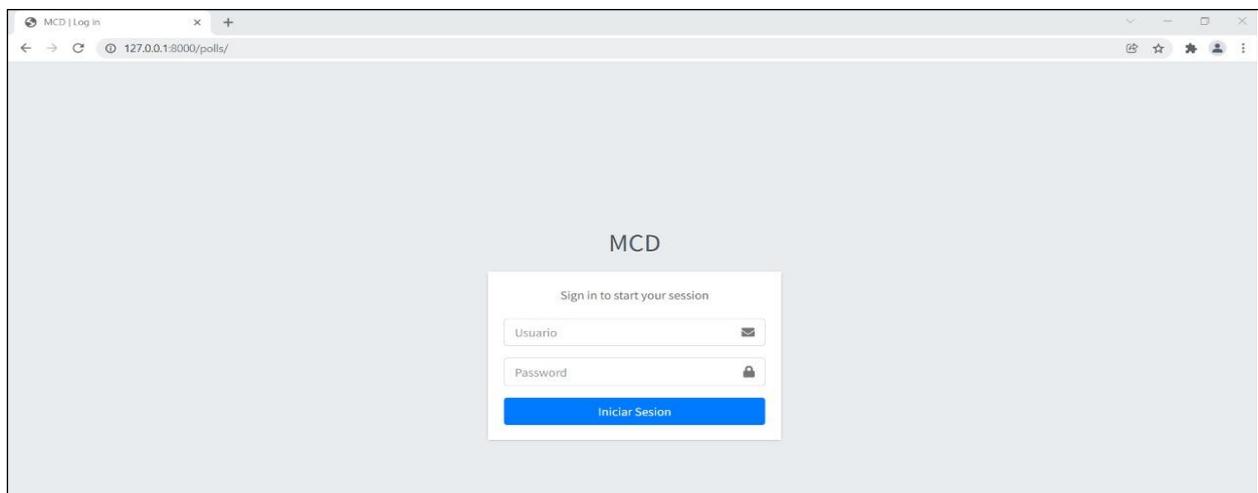


Figura 3.15 Login del Administrador

Elaborado por: Cáceres & Valencia, 2021

Ingresados los usuarios y contraseñas del administrador, podemos identificar los datos almacenados de los dos módulos, reconocimiento facial y predicción mediante el modelo ARIMA, esto con la finalidad de que la Institución posea todos estos datos para la toma de decisiones y mejora continua de la Universidad.

Esta pantalla tiene acceso a la información de todos los estudiantes, la misma identifica datos al instante, tales como:

- Número de usuarios registrados
- Número de ingresos a la institución por día
- Carrera
- Estudiante
- Predicción del estudiante seleccionado

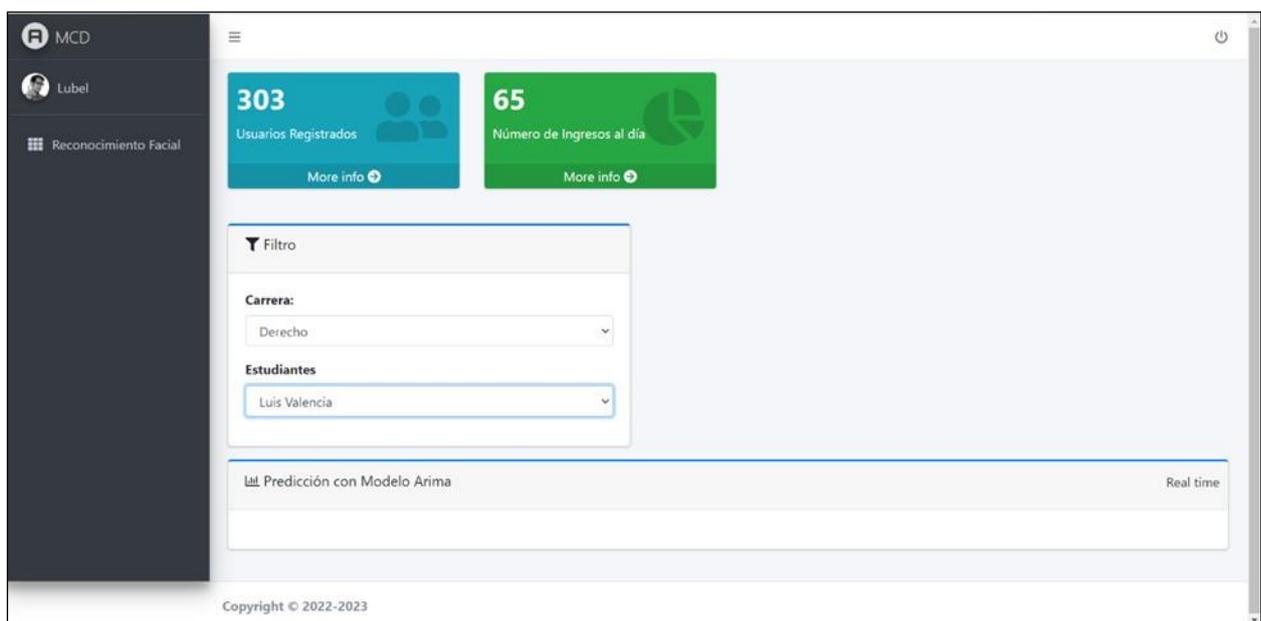


Figura 3.16 Visualizador del administrador (Pantalla parte 1)

Elaborado por: Cáceres & Valencia, 2021

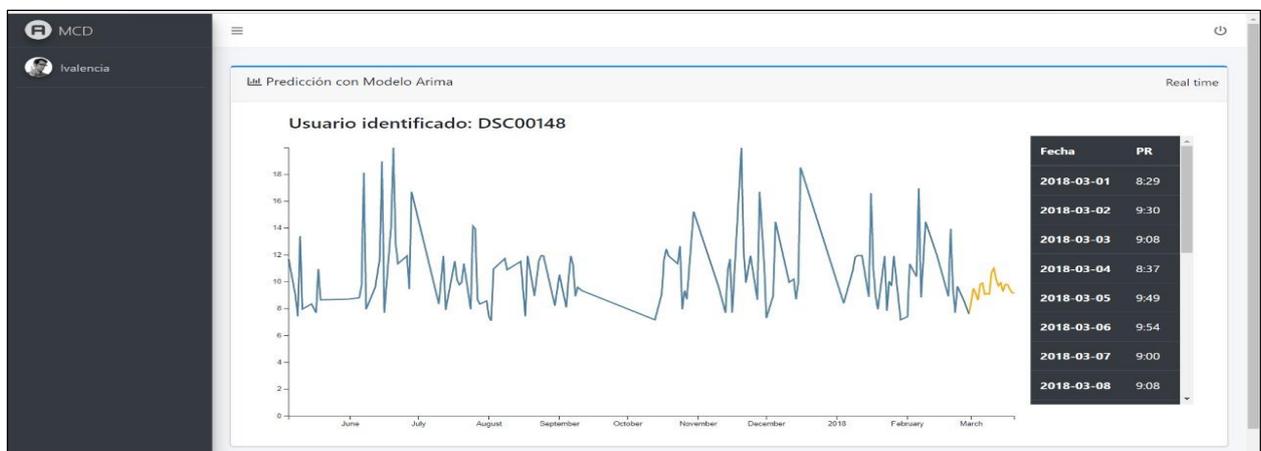


Figura 3.17 Visualizador del administrador (Pantalla parte 2)

Elaborado por: Cáceres & Valencia, 2021

A continuación, detallamos el módulo en el sitio web el cual permite el acceso a los estudiantes, mediante ingreso biométrico, es decir con reconocimiento facial.

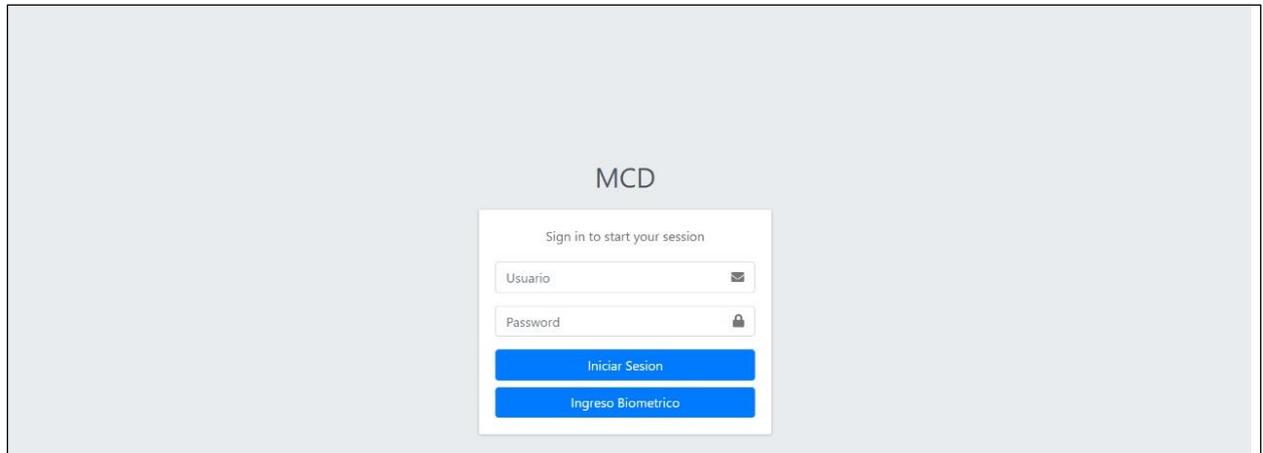


Figura 3.18 Login del estudiante.

Elaborado por: Cáceres & Valencia, 2021

Una vez que el estudiante ha seleccionada el campo de ingreso biométrico el usuario deberá colocar su rostro frente a la cámara para que sea detectado de acuerdo al entrenamiento del sistema.

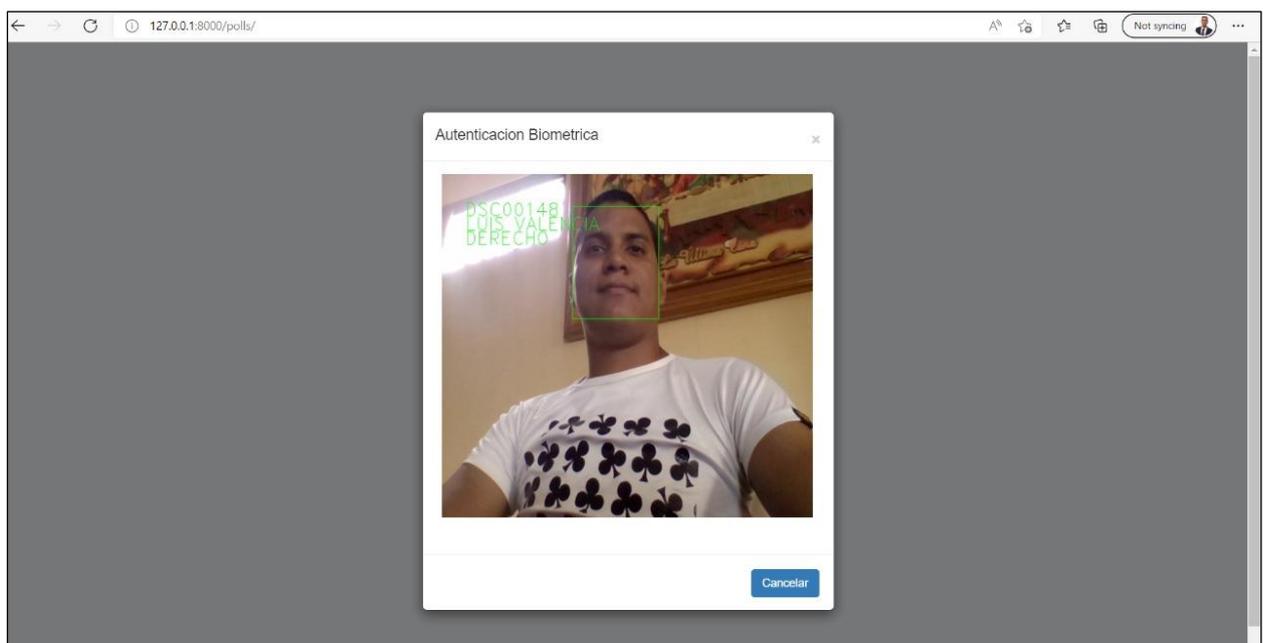


Figura 3.19 Autenticación del estudiante en el sistema.

Elaborado por: Cáceres & Valencia, 2021

Una vez identificado el usuario, se obtiene la vista de pronósticos la cual toma los datos del nuevo ingreso y automáticamente los almacena para posterior ser analizados por el modelo ARIMA y generar predicciones en un periodo de 20 días adelante. Esta información es incorporada a los datos originales y en conjunto se genera un dataset que puede ser convertido a formato JSON. El resultado final (JSON) es leído en la plantilla html en donde se muestra la detección del estudiante y genera de forma automática un gráfico de líneas o serie temporal junto con las predicciones.



Figura 3.20 Pantalla de visualización de resultados. Predicción

Elaborado por: Cáceres & Valencia, 2021

Es importante mencionar que a este sistema, el estudiante también tiene la opción de ingresar con un usuario y contraseña previamente entregado, teniendo las mismas funcionalidades que con reconocimiento facial.

La implementación del sistema de pronóstico y los resultados observados han generado a los administradores del sistema y la Institución una gran base de datos la cual permite tomar decisiones para el beneficio de los estudiantes. El tema de controles de seguridad de la institución ha sido mejorado, considerando la función conjunta de pronóstico y la identificación de rostros, permite a los responsables del ingreso una alta confiabilidad del personal de la institución, además se considera que cada vez, es menor el uso del

torniquete, mismo que durante años, fue el único registro de ingreso a la institución. Datos que no permitían generar ninguna mejora en la institución.

Atrasos y ausencia de estudiantes, son dos variables que a partir de este sistema, son fáciles de detectar de acuerdo a los registros de ingresos y predicción, actualmente la institución realiza un seguimiento a estos estudiantes, siempre y cuando los coordinadores de aula reporten alguna inconsistencia, a partir de la implementación de estas herramientas en la institución se podrá realizar un seguimiento y con ello detectar posibles problemas que interfieren en el desenvolvimiento normal de los estudiantes.

CAPÍTULO 4

4. CONCLUSIONES Y RECOMENDACIONES

4.1 Conclusiones

- A partir de la ejecución de redes neuronales en Python con MobilNer y FaceNet, modelos pre-entrenados se ha logrado extraer características relevantes del rostro de estudiantes de una Institución de Educación Superior, las cuales generan una alta precisión en el reconocimiento facial en tiempo real.
- La ejecución y selección del modelo ARIMA realizada en Rstudio, ha permitido la identificación de patrones de comportamiento de los estudiantes a partir de la data de series de tiempo de la institución, lo cual pronostica la llegada de los alumnos a la institución a corto plazo.
- El sistema de control de acceso mediante reconocimiento facial con one-shot learning y el pronóstico de series de tiempo a partir de los patrones identificados se ha generado con éxito.

4.2 Recomendaciones

- Actualización de la base de datos con las imágenes de todos los estudiantes con la finalidad que se realice un correcto reconocimiento facial de cada persona al ingresar a centro educativo. a su vez sería de gran ayuda tener cámaras conectadas al sistema de reconocimiento facial para controlar el comportamiento de los estudiantes dentro de cada espacio de la institución como aulas, bibliotecas, centros recreativos, y demás.
- A partir de la implementación del sistema de control de acceso e identificación de patrones que caracterizan el comportamiento de estudiantes de educación de nivel superior, usando técnicas de reconocimiento facial con one-shot learning y pronósticos en series de tiempo, incluir un módulo que genere alertas a los correos electrónicos institucionales y/o teléfonos celulares de los alumnos, con el pronóstico de llegada a la institución a corto plazo, de forma inmediata a partir del acceso satisfactorio.

- Generados los datos de pronóstico, el responsable que lleva el control en la institución, podrá enviar a los departamentos correspondientes información como:
 - Datos de los estudiantes que con frecuencia ingresan tarde a la institución, derivar al departamento de bienestar universitario, para lograr identificar el problema.
 - Identificar la frecuencia de ausencia de los estudiantes y dirigir esta información al departamento de bienestar universitario y dirección de carrera a fin de solucionar el inconveniente y evitar una posible deserción.
 - Datos de ingreso en fechas de evaluaciones de parciales, podrán ser enviados a las direcciones de carrera a fin de considerar esta información para la distribución de los horarios de uso de laboratorios en las próximas evaluaciones y así evitar cruces con la organización de otras carreras, que utilizan las mismas instalaciones.
 - Los datos poblacionales, permitirán a la institución y el departamento de relaciones públicas organizar programas, de acuerdo con el día, número de ingresos de estudiantes y aforo permitido para eventos.
 - La información general, seccionada por carreras y niveles, podrá ser direccionada a la coordinación de aulas, para de esta forma generar horarios que permitan mantener un aforo equitativo en todas las secciones: matutina, vespertina y nocturna, considerando que, para el presente estudio, más del 50% de la información corresponde a los horarios de la sección matutina.

Estos beneficios serán de utilidad para la institución, los estudiantes y público en general, mejorando la calidad en la prestación de los servicios del centro educativo.

BIBLIOGRAFÍA

- Caldera, J., & Zapico, F. (2009). Identificación facial biométrica . *Gestión de la información personal*, 428. Recuperado el 2021 de agosto de 2021, de <https://revista.profesionaldelainformacion.com/index.php/EPI/article/view/epi.2009.jul.11/21552>
- Cañete, J. (2021). *Técnicas de Deep Learning para la predicción de los niveles de contaminación*. Obtenido de Repositorio Institucional del CIEMAT: http://documenta.ciemat.es/bitstream/123456789/842/1/TFM_Juan_Canete.pdf
- Espinoza Olgúin, D. E., & Jorquera Guillen, P. I. (2015). *Reconocimiento Facial*.
- Guerrero, M. M. (2018). *Reconocimiento facial para la autenticación de usuarios*. Obtenido de Universitat Politècnica de València: <https://riunet.upv.es/bitstream/handle/10251/93928/MART%C3%8DNEZ%20-%20Reconocimiento%20facial%20para%20la%20autenticaci%C3%B3n%20de%20usuarios.pdf?sequence=1>
- Haykin, S. (2009). *Neural Networks and Learning Machines*. (P. P. Hall, Ed.)
- Hmani, A., & Petrovska, D. (21 de Marzo de 2018). *State-of-the-art Face Recognition Performance Using Publicly Available Software and Datasets*. Obtenido de <https://www.zenodo.net/record/1323670/files/hmani-atsip-2018.pdf>
- INTERPOL. (03 de 2020). *Reconocimiento facial*. Obtenido de <https://www.interpol.int/es/Como-trabajamos/Policia-cientifica/Reconocimiento-facial>
- Méndez, H., Chang, L., Rizo, D., & Morales, A. (2012). Evaluación de la calidad de las imágenes de rostros utilizadas para la identificación de las personas. *Scielo*, 147-165. Recuperado el 27 de Agosto de 2021, de <http://www.scielo.org.mx/pdf/cys/v16n2/v16n2a3.pdf>
- Rajput, V. (2019). Detección y reconocimiento de rostros capaz de vencer a los humanos mediante FaceNet. *Analytics Vidhya*.
- Reynoso , J. (25 de septiembre de 2017). *Las máquinas aprenden: el reconocimiento facial como método de identificación*. Recuperado el 17 de agosto de 2021, de MORABANC: <https://www.morabanc.ad/morablog/machine-learning-y-reconocimiento-facial/>

- Schroff, F., Kalenichenko, D., & Philbin, J. (2015). *FaceNet: A Unified Embedding for Face Recognition and Clustering*. Recuperado el 16 de Junio de 2021, de Computer Vision Foundation: https://www.cv-foundation.org/openaccess/content_cvpr_2015/papers/Schroff_FaceNet_A_Unified_2015_CVPR_paper.pdf
- Solis Calvopiña, L. N., & Puga Torres, L. R. (2016). *Control de Seguridad Biométrico de Reconocimiento Facial como Caso de Estudio Implementación en el Área Administrativa de la Facultad de Ingeniería de la Universidad Católica de Santiago de Guayaquil*. Guayaquil. Recuperado el 21 de 10 de 2021, de <http://repositorio.ucsg.edu.ec/bitstream/3317/6737/1/T-UCSG-PRE-ING-CIS-128.pdf>
- Sotaquirá, M. (15 de 06 de 2020). *CodificandoBits*. Obtenido de Detección de Rostros con Machine Learning: <https://www.codificandobits.com/blog/deteccion-de-rostros-machine-learning/>
- Xinzheng, X., Meng, D., Huanxiu, G., Jianying, C., & Xiaoyang, Z. (2020). *FaceNet ligero basado en MobileNet*. xuzhou: Scientific Research Publishing. Obtenido de https://www.scirp.org/pdf/ijis_2020120116481967.pdf