



UNIVERSIDAD POPULAR AUTÓNOMA  
DEL ESTADO DE PUEBLA

DECANATO DE INGENIERÍAS  
Maestría en Ciencia de Datos e Inteligencia de  
Negocios

**Detección de patrones de movilidad en  
Angelópolis-Puebla mediante la  
clasificación de caracteres de placas  
aplicando ciencia de datos e inteligencia de  
negocios**

Tesis que para obtener el grado de  
Maestría en Ciencia de Datos e Inteligencia de  
Negocios

Presenta

**Luis Enrique Muñoz López**

Matrícula: 17970070

Directora de Tesis

**Dra. Argelia Berenice Urbina Nájera**

Diciembre 2021



**UPAEP – Secretaría General**

Dirección General de Apoyos Académicos

Dirección del Centro de Recursos para el Aprendizaje y la Investigación.

Biblioteca Central - **Karol Wojtyła**

**Tesis Digitales Restricciones de uso:**

**DERECHOS RESERVADOS ©**

**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de textos, imágenes, gráficas, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente de donde la obtuvo mencionando el autor o autores involucrados en el documento.

Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Puebla, Pue., a 26 de noviembre de 2021

Dra. Argelia Berenice Urbina Nájera  
Dr. Vittorio Zanella Palacios  
Mtro. Sergio Humberto Martínez Arriaga  
Dra. Rocio Morales Salgado  
Dra. Sandra Murillo Cano  
UNIVERSIDAD POPULAR AUTÓNOMA DEL ESTADO DE PUEBLA

#### PRESENTES


A través de este medio les informo que el C. LUIS ENRIQUE MUÑOZ LÓPEZ, estudiante de la **Maestría en Ciencia de Datos e Inteligencia de Negocios** de su casa de estudios, con número de **Matrícula 3344163**, ha concluido con total satisfacción su tesis titulada "Aprendizaje automático aplicado en la lectura y reconocimiento de placas. Movilidad y seguridad pública".

Es de mi agrado hacerles saber que en Cargo Móvil estamos satisfechos con el trabajo realizado por Luis Enrique. Los resultados de investigación cumplen con las inquietudes de la empresa sobre el crecimiento de operaciones y descubrimiento de patrones de comportamiento con la lectura y reconocimiento de placas.


A su vez, hago constar que los datos proporcionados por la empresa son las imágenes tomadas en algunos de los proyectos existentes para el acceso de los usuarios. Los datos utilizados no comprometen o exponen información sensible de los usuarios, no obstante, se pide no publicar la investigación porque desvela datos sensibles de la empresa que ponen en riesgo su ventaja competitiva en el mercado.

Agradeciendo de antemano su atención, quedo a sus órdenes

Atentamente,



Carlos Manuel Anaya Rodríguez  
Chief Execution Officer y Fundador  
Cargo Móvil S.A.P.L. de C.V.  
Parkimovil

 **PARKIMOVIL**  
MOVING CITIES SMARTER

CARGO MÓVIL S.A.P.L. DE C.V.  
EMPRESA DE CAPITAL ABIERTO

Ciudad de Puebla, a 30 de noviembre de 2021

**Dra. Ma. del Rocío Guadalupe Morales Salgado**  
Directora de Programa Educativo  
Maestría en Ciencia de Datos e Inteligencia de Negocios  
UPAEP  
PRESENTE

**Asunto:** Aprobación para la digitalización  
de documento de tesis


Los que suscriben la presente, en calidad de comité de **tesis** de la Lic. **Luis Enrique Muñoz López**, con número de matrícula **17970070** e ID **3344163**, le informamos que hemos revisado el documento titulado **Detección de patrones de movilidad en Angelópolis-Puebla mediante la clasificación de caracteres de placas aplicando ciencia de datos e inteligencia de negocios**.

Como resultado de esta revisión consideramos que el documento de *tesis* cumple con los requisitos necesarios para ser defendido con el propósito de obtener el grado de Maestra en **Ciencia de Datos e Inteligencia de Negocios**, por lo que aprobamos que se realice la digitalización correspondiente y por ende la programación del examen de grado.

La saludamos afectuosamente, anticipando nuestro agradecimiento por la atención a la presente.

Cordialmente,

  
Dra. Argelia Berenice Urbina Nájera  
Directora de tesis

  
Dr. Vittorio Zanella Palacios  
Asesor

  
Mtro. Sergio H. Martínez Arriaga<sup>1</sup>  
Asesor

  
Dra. María del Rocío Morales Salgado  
Sinodal

  
Dra. Sandra Rocío Murillo Cano  
Sinodal

<sup>1</sup> El Mtro. Sergio Humberto Martínez Arriaga es director de operaciones de Cargomovil, empresa mexicana dedicada al desarrollo de soluciones de Smart Mobility en una plataforma integral para transformar la experiencia de moverse en el mundo, en accesos, estacionamientos, ciudades y todo tipo de movilidad inteligente. <https://parkimovil.com>



## DEDICATORIA

*A mis padres Martín y Lina que son todo para mí, representan mis valores, mis enseñanzas, mis metas y mi vida entera. Porque aprendí que los conocimientos son importantes, pero de nada sirven sino despertamos cada día para ser mejores personas. Gracias por apoyarme en todo momento, aún cuando no lo necesitaba.*

*A mis amigos Nacho, Pily y Hugo. Estoy muy agradecido de que sean parte de mi vida, porque han estado en las buenas y en las peores. Me soportaron y ayudaron tantos años que siempre voy a estar en deuda con ustedes. Los quiero.*

*Al maestro Carlos Guillermo, porque tuve tanto miedo en su primera clase que eso me hizo ser mejor estudiante desde ese momento. Estoy profundamente agradecido por el conocimiento compartido, por los infinitos regaños y por los consejos que siempre he recibido.*

*A la doctora Argelia, por el tiempo y paciencia que supuso acompañarme a lo largo de este trabajo.*

*A Cargo Móvil por la oportunidad de crecimiento que me han brindado a lo largo de este tiempo.*

# ÍNDICE

2

RESUMEN	iii
ABSTRACT	iii
INTRODUCCIÓN	iv
CAPÍTULO 1: Protocolo de trabajo práctico	1
1.1    Introducción	1
1.2    Planteamiento del problema	1
1.3    Justificación	2
1.4    Objetivos del proyecto	3
1.5    Preguntas del negocio	3
1.6    Alcances del proyecto	4
1.7    Limitaciones del proyecto	4
1.8    Viabilidad de la investigación	4
1.9    Resultados esperados	4
1.10   Contribuciones originales	5
CAPÍTULO 2: Marco teórico	6
2.1    Lectura y reconocimiento de placa	6
2.2    Vecinos cercanos	8
2.3    Bosques aleatorios de clasificación	10
2.4    Máquinas de soporte vectorial	13
2.5    Redes neuronales	15
2.5    Tableros	17
CAPÍTULO 3: Revisión del estado del arte	19
CAPÍTULO 4: Metodología	25
4.1    Metodología KDD para clasificación de caracteres	26
CAPÍTULO 5: Resultados	33
5.1    Detección de caracteres	33
5.1.1 Clasificación de caracteres con vecinos cercanos	33
5.1.2 Clasificación de caracteres con máquinas de soporte vectorial	36
5.1.3 Clasificación de caracteres con árboles y bosques aleatorios	39

5.1.4 Clasificación de caracteres con redes neuronales	40
5.2 Tablero de movilidad	43
5.3. Tablero de seguridad	48
CONCLUSIONES	55
REFERENCIAS	58

## RESUMEN

El crecimiento de las ciudades urbanas en la republica mexicana disminuye el bienestar social al impactar en la movilidad y seguridad pública. La falta de información para estrategias de corto y largo prolonga los tiempos de conmutación y la percepción de seguridad a los ciudadanos. Este documento compara la precisión de algoritmos de aprendizaje supervisado en una fase de clasificación de caracteres para detectar las placas de la zona de Angelópolis en Puebla. La metodología elegida propone segmentar los caracteres de la placa, procesar y transformar las imágenes a blanco y negro con una dimensión de 20x20 y finalmente extraer las características por el método HOG para comparar los algoritmos. Los resultados muestran que las máquinas de soporte vectorial son el mejor algoritmo para clasificar los caracteres al tener una precisión de 92% para 765 instancias de entrenamiento y 91.94% para 255 instancias de prueba. Se concluye que la clasificación de caracteres ayuda a la detección de patrones de movilidad con inteligencia de negocios.

## ABSTRACT

The social welfare decreases because of the urban cities growth and it is impact in mobility and public security. The lack of relevant information restricts short- and long-term strategies extending the commute times and perception of security of citizens. This paper compares the effectiveness of license plate's characters classification in machine learning algorithms. The methodology proposed begins with the licenses plate character segmentation, then, transform the data in black and white color and resize the images into 20x20 dimension, after that the HOG method is used to extract all the characteristics to compare the algorithms precision. The results show that support vector machines achieve 92% of effectiveness on 765 instances of training data and 91.94% on 255 instances of testing data. In this way, data from other services can be integrated to detect mobility patterns and characteristics of vehicles reported as stolen. The paper concludes that the license plate character segmentation helps to detect mobility patterns with business intelligence

*Palabras clave:* aprendizaje automático, clasificación de caracteres, ciencia de datos, inteligencia de negocios, movilidad urbana

*Keywords:* machine learning, characters classification, data science, business intelligence, urban mobility.

## INTRODUCCIÓN

La movilidad urbana es una variable que contribuye a la construcción, crecimiento y planeación de las ciudades que de no atenderse provoca efectos negativos en el bienestar de las personas. En el caso de las ciudades urbanas de la República Mexicana, el Fideicomiso para el Mejoramiento de las Vías de Comunicación del Distrito Federal (2012) encuentra características en común sobre las ciudades que impiden planear metas estratégicas como complejidad en la estructura y programas que han tenido efectos contrarios a los deseados que provocan congestiones viales, rutas de viajes lentas, contaminación auditiva, contaminación visual, contaminación atmosférica y robo de vehículos. Lo anterior, se contrasta con lo expresado por el Instituto de Estadística y Geografía (2019), la inseguridad ciudadana se refleja en que un 68.1% de la población nacional se siente insegura en la ciudad y la tasa delictiva es de 9,091 robos en vialidad y transporte público por cada 100,000 habitantes.

La movilidad urbana se ve comprometida en las ciudades que expresan un crecimiento constante de población como de infraestructura en sus espacios. Una ciudad que experimenta un crecimiento de ambos factores es Puebla, uno de los puntos más importantes en el país que ofrece servicios como vivienda y centros de negocios. Sin embargo, este crecimiento ha generado problemas para los ciudadanos como lo relata el Informe del Gobierno Municipal de Puebla (2017); el tiempo para encontrar un lugar de estacionamiento en el centro es de casi media hora, las grandes avenidas se ven congestionadas por el transporte público y privado, además los tiempos de traslado de un punto a otro de la ciudad cada vez son más prolongados.

Las dificultades de ciudades en crecimiento como Puebla se deben a la falta de información relevante para la toma de decisiones en el corto y largo plazo. Por esta razón, en este documento se propone comparar la precisión de algoritmos de aprendizaje automático para clasificar caracteres de placas en la zona Angelópolis. Mediante esta propuesta se plantea identificar a los autos que transitan por esta zona e integrar los datos con operaciones de una aplicación de movilidad para detectar patrones de comportamiento y obtener características de automóviles con reporte de robo.

La propuesta de este documento se basa en implementar modelos computacionales sobre un conjunto de datos de caracteres para clasificar a las instancias con su etiqueta correspondiente. La efectividad de los modelos computacionales se basa en la precisión que tienen para clasificar a las etiquetas. Se utilizan cuatro distintos modelos computacionales para clasificar como son vecinos cercanos, bosques de clasificación, máquinas de soporte vectorial y redes neuronales.

La precisión de los algoritmos de clasificación ayuda a identificar las placas que se leen en la zona de Angelópolis. De esta manera, se pueden integrar datos de otras plataformas para obtener un conjunto de datos para detección de patrones e interacción de las variables en su conjunto. Lo anterior, se logra con la ciencia de datos y sus diferentes técnicas de manipulación de datos estructurados y no estructurados que se pueden complementar con modelos multidimensionales para la explotación de información.

La ciencia de datos brinda la capacidad de obtener información para su explotación y planeación de estrategias. Las estrategias deben responder a los objetivos planteados por el negocio. Para esta situación se utiliza la inteligencia de negocios en el análisis y visualización de los datos que otorga la posibilidad de ver las características e interacción de los vehículos y personas en la zona. Lo anterior, se traduce en la planeación de estrategias para mitigar las congestiones viales, contaminación ambiental y reducción de inseguridad pública.

La estructura de este documento se divide en cuatro capítulos. El primer capítulo trata sobre el planteamiento del problema, justificación y objetivos a alcanzar. El segundo capítulo es sobre el marco teórico que es el soporte teórico y conceptual del documento. El tercer capítulo es la revisión del estado del arte que habla de las aplicaciones más recientes de los sistemas de lecturas de placa. El penúltimo capítulo es sobre la metodología que comprende los elementos necesarios para el desarrollo de cada etapa planteada en la clasificación de caracteres y detección de patrones. El último capítulo trata sobre los resultados de la clasificación de caracteres y la integración con datos de la aplicación para la visualización de la interacción de las personas y vehículos en la zona.

# CAPÍTULO 1: Protocolo de trabajo práctico

## 1.1 Introducción

Este trabajo se basa en identificar los problemas más comunes de la movilidad en las ciudades urbanas de la República Mexicana. Posteriormente, se complementa con herramientas que sirvan para ayudar a solventar los problemas encontrados como una aplicación de movilidad que tiene el monopolio de gestión de espacios públicos y privados en una de las zonas más importantes del país.

La forma de abordar el protocolo de trabajo comienza por la obtención de información referente a los sistemas de lectura de placa y clasificación de caracteres para conocer las características de la información disponible y las limitaciones inherentes al documento. De esta forma, se determina el objetivo principal que comprende la comparación de la precisión de algoritmos de clasificación de caracteres. En el caso de los objetivos específicos se plantea integrar datos para descubrir patrones de movilidad y características de vehículos con reporte de robo. Al igual, las preguntas del negocio se enfocan a conocer si un sistema de lectura de placas contribuye al crecimiento de la empresa y describe patrones de comportamiento de los usuarios.

Por otro lado, se determinan los alcances del documento que se basan en la comparación de la precisión de los algoritmos de clasificación. También, se establecen las limitaciones encontradas como la calidad del conjunto de datos y la exclusión de la etapa de implementación. De la misma forma, se describe la viabilidad de la investigación que son los recursos para lograr los objetivos como el equipo de cómputo y recursos humanos. Finalmente, se espera obtener una alta precisión de clasificación de los algoritmos para integrar los datos con las operaciones de la aplicación y tener contribuciones originales para la movilidad de la ciudad de Puebla.

## 1.2 Planteamiento del problema

El constante crecimiento de la población urbana y parque vehicular generan un lento desarrollo urbano que se acompaña de soluciones de movilidad erróneas que resultan en dolencias de la sociedad como inseguridad, muertes por accidente, movilidad restringida, contaminación visual, auditiva y atmosférica que permea sobre el bienestar social. Lo anterior, es el resultado de una planeación ineficiente de las ciudades urbanas que

desincentiva el uso de transporte masivo por el particular. Inclusive, según la Secretaria de Desarrollo Agrario Territorial y Urbano (2020) de seguir prefiriendo el transporte privado, este crecerá 5.4% y el uso del transporte masivo tendrá una reducción de 5% para 2030 y la bicicleta de 2%.

Como se mencionó anteriormente, las alternativas de movilidad que se han presentado no son suficientes. El programa *hoy no circula* plantea dejar de utilizar el auto en la ciudad por algunos días, sin embargo, las personas prefieren comprar otro auto para desplazarse, fenómeno que se conoce como incentivo perverso. Esto ha llevado a proponer otros sistemas de control que no restringen la movilidad como los semáforos inteligentes que atienden la demanda en tiempo real o las rotondas en las avenidas que disminuyen los accidentes peatonales en un 75%. Aunque, el Fideicomiso para el Mejoramiento de las Vías de Comunicación del Distrito Federal (2012) habla de que se hacen encuestas de origen – destino cada 15 años para conocer la movilidad de las personas, mecanismo que puede ser reemplazado por un sistema de lectura de placas.

La disponibilidad de la información representa una barrera para la toma de decisiones en las ciudades en crecimiento. En el caso de la ciudad de Puebla, se tiene una zona comercial de alto impacto a nivel nacional que tiene una infraestructura que se divide en zona comercial y residencial que tiende a generar problemas de movilidad en el presente y futuro, López (2019), que no tiene disponibilidad de información para análisis ya que el ultimo reporte con información relevante tiene una diferencia de 6 años en la actualidad.

Actualmente, una empresa de movilidad dedicada a la gestión de espacios públicos y privados como parquímetros, estacionamientos y controles de acceso posee el monopolio de lugares con acceso a través de una aplicación móvil. Sin embargo, los datos no han sido explotados lo suficiente para generar información de valor para la sociedad y que ayude al diseño de estrategias de movilidad urbana y seguridad pública.

### 1.3 Justificación

La disponibilidad de datos se ve limitada en una ciudad con un crecimiento constante como Puebla, razón por lo cual se propone implementar algoritmos de clasificación para un sistema de lectura y reconocimiento de placas que se pueda integrar con los datos de la aplicación de Cargo Móvil para tener datos disponibles y actualizados fáciles de entender en un tablero de inteligencia de negocios con variables como congestiones en espacios públicos o privados, rutas de viaje, permanencia y características de autos con reporte de robo.

La contribución de la implementación de algoritmos de clasificación plantea tener externalidades positivas para el sector público como información relevante y actual para atender problemas del crecimiento de la ciudad, por otro lado, para la empresa Cargo Móvil se plantea la reducción de costos de implementación de un algoritmo de lectura de placas y la integración con datos de la aplicación para conocer las características de los usuarios y aumentar su ventaja competitiva en el mercado.

La idea principal del trabajo es aplicar algoritmos de aprendizaje automático de clasificación para identificar los caracteres de las placas leídas en los controles de acceso de la zona de Angelópolis y comparar la precisión de cada uno para integrar la información con los datos de la aplicación en un tablero de inteligencia de negocios que proporciona lo necesario para solventar los problemas que las ciudades en crecimiento generan.

## 1.4 Objetivos del proyecto

### **OBJETIVO GENERAL**

Integrar las lecturas de placas con la información de las operaciones de los usuarios para detectar patrones de movilidad y características de autos con reporte de robo en un tablero de inteligencia de negocios.

### **OBJETIVOS ESPECÍFICOS**

- a) Comparar la precisión de algoritmos de aprendizaje automático para la clasificación de caracteres de placas en la zona de Angelópolis en la ciudad de Puebla
- b) Detectar los caracteres de las placas que son propensos a no ser clasificados de forma correcta por los algoritmos de aprendizaje automático
- c) Unificar las operaciones de los usuarios de la aplicación según los servicios y tipo de acceso utilizados

## 1.5 Preguntas del negocio

- a) ¿La lectura y reconocimiento de placas contribuye a la estrategia de crecimiento de Cargo Móvil?
- b) ¿La lectura y reconocimiento de placas es una fuente de información confiable para determinar el comportamiento de los usuarios?

## 1.6 Alcances del proyecto

Los alcances del proyecto descansan en entrenar y probar cuatro algoritmos de aprendizaje supervisado como vecinos cercanos, máquinas de soporte vectorial, bosques de clasificación y redes neuronales para clasificar caracteres de las placas obtenidas en los controles de acceso de Cargo Móvil. La precisión de los algoritmos ayuda a integrar los datos de las operaciones de los usuarios con la aplicación para conocer todas las características de movilidad en la zona.

## 1.7 Limitaciones del proyecto

Las limitaciones del proyecto son aquellas que impiden el desarrollo del proyecto en su totalidad. En esta cuestión, las limitantes de este trabajo son la calidad de las imágenes tomadas y la robustez de la clasificación al tener datos para una sola zona del país. También, se trabaja únicamente en la fase de clasificación de caracteres, por lo cual, cualquier otra fase o implementación del sistema de lectura de placas queda fuera de este documento.

## 1.8 Viabilidad de la investigación

El valor fundamental en un proyecto descansa en los recursos que se tienen para lograr el objetivo premeditado. Los recursos responden a los insumos con herramientas, capital humano y tiempo de investigación. Para esta investigación se contempla un equipo de cómputo con características como 8 GB de RAM con Intel® Core™ i5-8265 U CPU @1.60 GHz. También, se tienen cámaras instaladas en los fraccionamientos más grandes de la zona y una base de datos para la extracción de los datos de aplicación. En el lado de recursos humanos se cuenta con un científico de datos que proporciona los datos de la aplicación y al director de innovación para dar acceso a los datos de lectura de placas.

## 1.9 Resultados esperados

Los resultados esperados se basan en la precisión de los algoritmos elegidos para clasificar los caracteres de la placa. Mediante la precisión se espera comparar los resultados de los algoritmos elegidos para poder integrar los datos de lectura con las operaciones de la aplicación. Se espera aumentar el volumen de datos de usuarios con la clasificación de caracteres para encontrar patrones de movilidad en sectores donde el usuario no usa la aplicación para ingresar a lugares públicos o privados.

## 1.10 Contribuciones originales

La contribución original se basa en minimizar los problemas de lectura de caracteres de placas en la empresa; se cuenta con visión computacional, pero no con aprendizaje automático. También, se espera tener una contribución social para descubrir patrones de movilidad y seguridad pública en una ciudad de constante crecimiento como lo es Puebla.

## CAPÍTULO 2: Marco teórico

El marco teórico es el soporte teórico y contextual de los conceptos para el entendimiento del procedimiento a realizar en este trabajo. En el presente documento, se busca el desarrollo de un sistema de lectura y reconocimiento de placas utilizando herramientas de aprendizaje automático como algoritmos supervisados para la zona de Angelópolis en la ciudad de Puebla. La búsqueda de un sistema de lectura de placas nace dada la necesidad de generar información para una zona en constante crecimiento que no tiene una planificación urbana adecuada. Lo anterior, se puede constatar en el último documento con información relevante de movilidad en la ciudad que pertenece al Gobierno municipal de Puebla (2017), sin embargo, el análisis presentado es acotado al tener datos solo hasta el año 2015. En este sentido, se busca que el sistema de lectura de placas ayude a brindar información relevante, accesible y consultable en diferentes periodos de tiempo.

### 2.1 Lectura y reconocimiento de placa

En la vida cotidiana, las personas pasan distintos momentos de convivencia con otras personas o en su caso otros objetos. Esta convivencia es la forma humana de percibir al mundo e interactuar mediante el tacto, el gusto, la vista, entre otros sentidos. Dicho lo anterior, los seres humanos tienen la capacidad de discernir ciertas situaciones con base en su experiencia, como la identificación de los caracteres de una placa, aunque, se llega a un límite de procesamiento y análisis de información cuando la información escala a grandes volúmenes.

La limitante humana de procesamiento y análisis de la información se refiere a la nula capacidad de interactuar con grandes cantidades de datos al mismo tiempo. Capacidad que ha dado el desarrollo de tecnologías computacionales, lenguajes de programación y dispositivos que facilitan el procesamiento de información. Algunos de los dispositivos que capturan parte de lo que un humano puede ver son las cámaras o videos que obtienen diferentes tipos de escenas que auxilian en la identificación de vehículos, monitoreo de seguridad, monitoreo de registro o control del tráfico, Jiménez (2013).

El interés en el procesado de imágenes ha estado presente desde décadas pasadas, sólo que el poder computacional no soportaba los sistemas como el de lectura y reconocimiento de placas. “Es así como en los años sesenta se idean algoritmos para la detección de los bordes de las imágenes como los de Roberts, Sobel o Prewitt. Más adelante, en los años ochenta se plantean algoritmos que ayudan al procesamiento de

imágenes como la detección de texturas, detección de esquinas o representación de las formas. El avance de estos trabajos permitió tener una idea más cercana sobre el procesamiento de imágenes, pero no se tenía una metodología que integrara varios de los algoritmos y fue hasta mediados de la década de los ochenta que se presentó “Visión: a Computational Investigation Into The Human Representation Information And Processing Of Visual Information”; la primera integración de diferentes algoritmos en una metodología para el procesamiento de imágenes”. Jiménez (2013).

Existen diferentes fases en un sistema de lectura de placas como la detección del objeto, la segmentación de caracteres y la clasificación de caracteres. En este trabajo, se enfatiza únicamente en la fase de clasificación lo cual comprende diferentes técnicas para lograr la tarea de asignación de una clase. Algunas de las técnicas de clasificación se basan en el aprendizaje automático con algoritmos supervisados, Gupta et al. (2020). La manera de clasificar los caracteres de la placa es mediante la selección de características de la imagen para después someterse a un algoritmo de clasificación según la etiqueta de correspondencia asignada, Shan et al. (2013). La extracción de características es una forma de reducir los costos computacionales al utilizar un vector de clasificación para el conjunto de datos, Hanke et al. (2014) y Shashirangana et al. (2020).

El proceso de clasificación de un sistema de lectura de placas es la parte que debe tener mayor detalle porque se ven inmersos diferentes factores como selección de características, algoritmo elegido y clasificación lograda. En este sentido, un buen sistema de lectura de placas responde a una alta asertividad en la clasificación de caracteres, es decir que tenga más lecturas positivas que negativas o que la clasificación de los caracteres corresponda a la etiqueta esperada, Penmatasa et al. (2020)

El desarrollo de un sistema de lectura de placas surge desde hace décadas, pero su aplicación tuvo que esperar a los avances computacionales, lenguajes de programación y utilización de dispositivos inteligentes. En la actualidad, el desarrollo de tecnología permite la realización de los sistemas de lectura de placas que solucionan los problemas de contratación de personal y propensión de errores humanos al realizar diferentes tareas, además, de solventar labores como gestión de movilidad, regulación de tránsito, solución a asaltos y reforzamiento de administración pública.

## 2.2 Vecinos cercanos

En los últimos años, la evolución de investigación hacia el aprendizaje automático ha planteado la obtención de características de grandes conjuntos de datos para realizar labores de identificación de patrones y asignación individual de etiquetas. Los resultados de las investigaciones plantean el uso de sofisticadas técnicas computacionales que lidian con problemas multiclase como lo son los vecinos cercanos (*KNN* *K-nearest neighbors*, por sus siglas en inglés) que son un método popular y efectivo para la clasificación de etiquetas (Pandey y Jain 2017).

Los vecinos cercanos según Nu (2019) son una técnica de clasificación del aprendizaje automático para predecir miembros en grupos de datos. El aprendizaje de los vecinos se basa en calcular las distancias entre los puntos de un conjunto de datos para que cuando un dato sin etiquetar sea introducido tome la etiqueta de las distancias más cercanas según el número de vecinos más cercanos, Nu (2019) y Bhatia y Vandana (2010). El enfoque de los vecinos cercanos es no paramétrico que destaca por su usabilidad en la tarea de clasificación.

Desde que Nabi y Ahmed (2013) consideran al enfoque como un reconocimiento de patrones que evalúa las instancias pertenecientes en el conjunto de entrenamiento para asignarlas a una etiqueta, lo primero es tener en cuenta la elección de valores apropiados de vecinos que determine el éxito de la clasificación. Existen diferentes criterios para elegir el número de vecinos adecuados ( $k$ ), pero uno simple es ejecutar el algoritmo tantas veces como sean necesarias con diferentes valores de  $k$  y elegir el que muestre un mejor rendimiento. El segundo criterio de clasificación para este algoritmo es la forma de recuperar los vecinos cercanos de la fase de entrenamiento y someter a votación una nueva instancia según la distancia más corta para elegir la clasificación o grupo perteneciente, Archana y Elangovan (2014). Esta distancia puede variar según el tipo de investigación, aunque lo más común es elegir la distancia euclidiana que mide la distancia entre dos puntos trazando una línea recta, como se expresa en la ecuación 1.

$$d(A, B) = \sqrt{(X_1 - X_2)^2 + (y_2 - y_1)^2} \quad (1)$$

Aunque la técnica de vecinos cercanos es fácil de entender e interpretar, se debe tomar en consideración las ventajas y desventajas que se ofrecen. Dado que los clasificadores de vecinos más cercanos son aprendices perezosos o basados en instancias que almacenan todas las muestras de entrenamiento y no construyen un clasificador hasta que se inserta una nueva muestra sin etiquetas, el costo computacional es alto, en especial cuando el conjunto de entrenamiento es amplio. Por lo cual, se tiene un algoritmo fácil de interpretar, pero con un costo computacional alto si el conjunto de entrenamiento aumenta en volumen.

Dentro del algoritmo de vecinos cercanos existen otros enfoques que toman en cuenta la asignación de pesos por instancia hasta la eliminación de patrones que no afecten los resultados del entrenamiento. Empero, en este documento se trabaja únicamente con la versión general del algoritmo que obtiene buenos resultados, ya que ningún algoritmo es mejor que otro, solo cambian según la tarea a resolver. Finalmente, se destacan los elementos clave para la implementación como un conjunto de datos etiquetados, elección de distancia y valor de  $k$ . Entre las ventajas de este algoritmo están la facilidad de implementar, la tarea multiclase que realiza y que trabaja en diferentes situaciones. La desventaja es el pesado poder computacional que requiere, en especial cuando aumenta el conjunto de datos. Un ejemplo sobre la representación visual del funcionamiento del algoritmo se puede ver en la imagen 1:




Imagen 1. Funcionamiento de KNN  
Fuente: Zhang (2016).

En el ejemplo de vecinos cercanos presentado en la imagen 1, se pueden observar 3 distintos tipos de clasificaciones. Se tienen frutas, granos y vegetales en un espacio que comprende las características dulce y crujiente para cada grupo. En el centro de esta imagen se tiene una nueva instancia que no tiene clasificación, pero le será asignada según el vecino más cercano, si se elige 1, el vecino más cercano es un elote, por lo que la nueva instancia será clasificada como granos.

## 2.3 Bosques aleatorios de clasificación

Los árboles de clasificación son una técnica que surge de la idea de obtener árbol con componentes como raíz, nodos, ramas y hojas. La manera de trabajar de los árboles es clasificar las instancias contenidas basándose en los valores de las características de cada nodo, en cada iteración el algoritmo recorre cada atributo del conjunto de datos de manera recursiva. En este sentido, un árbol de clasificación inicia con el nodo raíz que es un círculo en la parte superior, después se extiende hacia los lados en los nodos de hoja. Así, cada nodo es la característica principal del árbol y por ende del conjunto de datos, el nodo raíz es la característica con mayor peso que ayuda a clasificar las diferentes instancias.

Los árboles de clasificación son una técnica que surge de la idea de obtener un árbol con componentes como raíz, nodos, ramas y hojas. El árbol inicia con el nodo raíz que es la característica más importante de la clasificación, después se extiende hacia los nodos hojas a través de las ramas. Un ejemplo visual que ayuda a la conceptualización de un árbol de clasificación se encuentra en la imagen 2.

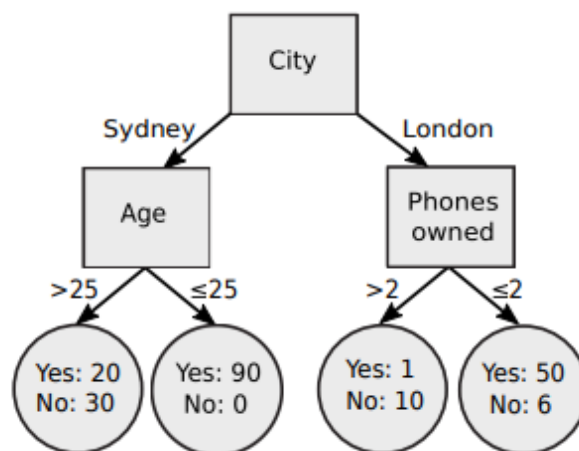


Imagen 2. Funcionamiento de árboles de clasificación  
Fuente: Fletcher y Zahidul, (2019)

En la imagen 2, se puede visualizar como la característica más importante de decisión en ese árbol es la ciudad, después se tienen dos nodos intermedios para la edad y el número de teléfonos que se poseídos. Al final, se encuentran las hojas con los resultados de cada clasificación, por ejemplo, hay diez instancias clasificadas como no de las cuales son de Londres y tienen más de dos teléfonos, caso contrario a los 90 casos clasificado como sí que son de Sídney y tienen menos de 25 años.

La forma de trabajo de los arboles de clasificación es clasificar las instancias contenidas basándose en los valores de las características en cada nodo, de esta manera, en cada iteración el algoritmo recorre las instancias del conjunto de datos de manera recursiva, Nu (2009). La forma recursiva es la capacidad que tiene el algoritmo de navegar por la estructura y pasar por diferentes nodos que tienen información importante para llegar a la etapa final de clasificación que debe tener en cuenta la ganancia de información o entropía que otorga la solidez de las decisiones en un árbol de clasificación, por ejemplo, decidir con mayor asertividad que variables son más eficientes para dividir al árbol respecto a otras.

El algoritmo de árboles de clasificación destaca por su aplicación a problemas multiclase, sin embargo, el proceso de elección de datos para entrenamiento es susceptible de variación en los resultados. De manera que la clasificación se ve afectada dependiendo el conjunto de datos elegido, por esta razón, hay una alternativa conocida bosques aleatorios que plantea agrupar diferentes arboles para obtener un promedio de la clasificación. El agrupamiento de diferentes arboles tiene un sesgo menor derivado de la elección de datos para clasificar, Medina y Ñique (2017).

Para mejorar la clasificación en los bosques aleatorios se utiliza un método llamado Bagging que hace referencia a partir el conjunto de datos en diferentes subconjuntos con reemplazo para cada instancia. También, existe el método de Boosting que tiene como meta clasificar de manera adecuada a las instancias mientras disminuye la tasa de error, lo anterior se hace asignando diferentes pesos a los datos hasta que la tasa de error es mínima para las instancias clasificadas.

Una característica de los bosques aleatorios es el Bagging y Boosting que se enfocan en usar modelos individuales para desarrollar diferentes métodos de clasificación. El primer término llamado Bagging hace referencia a que dado un conjunto de datos se seleccionan diferentes subconjuntos de entrenamiento con reemplazamiento, lo anterior significa que un dato puede estar contenido en diferentes subconjuntos de estimación. Por otro lado, el Boosting hace referencia a que algunos datos pueden ser clasificados de manera errónea, por lo cual, se pone mayor énfasis en la fase de entrenamiento a las instancias que no fueron

clasificadas correctamente, esto se hace con pesos diferentes hasta lograr la mayor clasificación posible.

Una vez determinadas las características de los bosques aleatorios, se da paso a la descripción del algoritmo de clasificación. Se inicia trabajando con diferentes árboles correlacionados como en Bagging para obtener un valor promedio. Este valor es el resultado de la asignación de valores en cada árbol siguiendo una distribución uniforme en el bosque con pruebas binarias en cada nodo hasta que se llega a una hoja del árbol como respuesta. En la etapa de entrenamiento, el bosque aleatorio busca optimizar las divisiones a partir de las muestras de entrenamiento, como se ejemplifica en la ecuación 2.

$$\theta_k^* = \operatorname{argmax}_{\theta_j \in \tau_j} I_j \quad (2)$$

Para poder optimizar las divisiones del conjunto de datos se debe tener en cuenta la función de división de nodos en cada escisión que mide la entropía para cada característica, que se visualiza en la ecuación 3.

$$I_j = H(j) - \sum_{i \in \{1,2\}} \left| \frac{s_j^i}{s_j} \right| H(s_j^i) \quad (3)$$

Finalmente, se destacan las ventajas de trabajar con árboles de clasificación como el factor multiclase y costo relativo menor a otros algoritmos. Aunque se debe considerar el tiempo de la construcción del árbol, al igual que los errores aumentan cuando se incrementa el número de clases.

## 2. 4 Máquinas de soporte vectorial

Las máquinas de soporte vectorial (SVM, *Support Vector Machine*, por sus siglas en inglés) son un algoritmo que trabaja con problemas de clasificación de patrones. El algoritmo fue introducido por primera vez en 1992 para COLT-92 como planteamiento de solución de problemas de clasificación lineal o no lineal. La idea básica de esta herramienta es construir un hiperplano óptimo que pueda separar los distintos tipos de datos maximizando el margen del hiperplano entre los puntos más cercanos, Archana y Elangovan (2014). Para una clasificación lineal, el algoritmo plantea distinguir un conjunto de datos con dos clases diferentes y separar en menos dimensiones, por otro lado, una clasificación no lineal contiene diferentes clases que no son distinguibles tan fácilmente y los datos necesitan ser transformados para poder clasificarse.

Una vez establecido que las máquinas de soporte vectorial buscan encontrar el mejor hiperplano dado un conjunto de hiperplanos para clasificar, lo siguiente es determinar cómo encontrar ese hiperplano, que de acuerdo con Somvanshi et al. (2016) se deben seguir los siguientes pasos:

1. Definir una función que delimite los diferentes conjuntos de datos
2. Seleccionar un hiperplano y calcular la distancia de ambos lados del conjunto de datos
  - 2.1 si la distancia que se calcula de ambos lados es comparada a previos hiperplanos, entonces tomar la distancia como una nueva decisión
  - 2.2 Marcar en los hiperplanos los vectores de soporte
3. Repetir el paso 2 hasta encontrar el hiperplano óptimo

En los pasos anteriores, se detalla cómo encontrar el hiperplano que separe de manera adecuada a los datos. Por lo cual, lo primero es encontrar una función que delimite las diferentes clasificaciones en el conjunto de datos. La función que brinda la separación de las distintas clases en un caso lineal se describe en la ecuación 4:

$$aX + bY = C \tag{4}$$

Con la ecuación 4, se busca solucionar un problema de programación cuadrática debido a la separación lineal de clases. En consecuencia, la determinación de una función de separación lleva a elegir los puntos del conjunto de datos que maximicen el ancho de

pasillo o el ancho de banda que es la distancia entre el hiperplano y los puntos entre cada clase que se conocen como vectores de soporte. En la imagen 3 se representa un caso lineal que contempla dos clases. En esta imagen se dibuja un conjunto de hiperplanos que necesitan de los vectores de soporte para elegir al optimo y poder maximizar la clasificación de instancias.




Imagen 3. Funcionamiento de SVM  
Fuente: Somvanshi et al. (2016)

Las bondades de las máquinas de soporte vectorial contemplan una solución para los casos que no son separables linealmente, es decir, con una recta. Hay funciones de clasificación conocidas como kernel que minimizan los riesgos estructurales mediante el problema cuadrático de programación, Jakkula (2011). La transformación mediante Kernel puede ser radial o polinomial, como en el caso de la imagen 4 que separa al conjunto de datos con una transformación de datos radial.

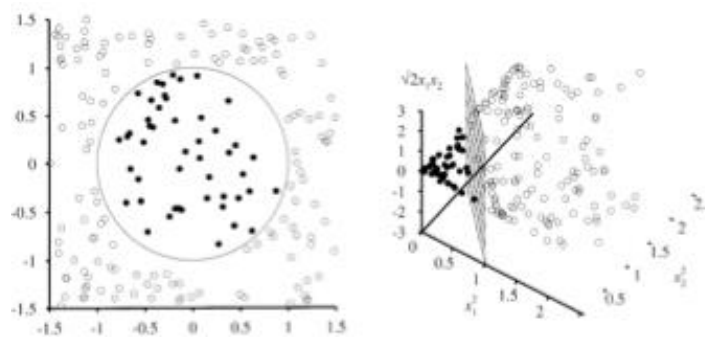



Imagen 4. Funcionamiento SVM Radial  
Fuente: Somvasnshi et al. (2016)

El método de máquinas de soporte plantea una separación lineal o no lineal de clasificación de datos. La tarea principal se basa en resolver problemas a través de la experiencia en una fase de entrenamiento y otra de validación conocida como prueba. De esta forma, se ejecuta un algoritmo potente que lidia con el incremento, variedad y complejidad de datos. Dentro de las ventajas inherentes del algoritmo se encuentran la robustez al ruido, no sobre entrenamiento, solución multiclase y clasificaciones precisas, aunque el poder computacional es una desventaja cuando se lleva a cabo la implementación Burbidge y Buxton (2001).


## 2.5 Redes neuronales

Las redes neuronales son un algoritmo que se aproxima al proceso de aprendizaje de los humanos de manera artificial. En el caso de un niño, se le presentan varios ejemplos de animales entre perros y gatos para que en un futuro cuando vea alguno de estos dos pueda distinguir con facilidad de que especie se trata. El funcionamiento del cerebro en el caso humano es a través de las neuronas que reciben señales de excitación a través de la sinapsis localizada en la membrana de otra neurona. Cuando las señales tienen un impulso suficientemente fuerte la neurona es activada y emite una señal al axioma. La representación de una red neuronal humana se puede observar en la imagen 5.



*Imagen 5. Funcionamiento de red neuronal  
Fuente: Gershenson (2003).*

Para las redes neuronales artificiales se plantea un modelo computacional que similar a las redes neuronales cerebrales. Una red artificial se estructura en entradas (sinapsis) que son multiplicadas por los pesos asignados al inicio (estímulos) y luego computadas por una función matemática que determina la activación de la neurona. El concepto de una red artificial resulta complejo debido a la interacción de los nodos de información para la clasificación de las instancias de entrada. En la imagen 6 se muestra la idea básica de una red que recibe datos en forma multidimensional en las capas de entrada, luego los datos se distribuyen en capas ocultas para que puedan interactuar y tomar decisiones. Al final de la imagen se observa el resultado que es un valor o etiqueta de salida que es la decisión tomada basada en el proceso de aprendizaje.



*Imagen 6. Funcionamiento de una red neuronal  
Fuente: O'Shea, K. y Nash R. (2015)*

Las redes neuronales comenzaron a popularizarse a principios de los noventa para resolver tareas complejas como detección de patrones, visión por computadora, innovación y creatividad. Sin embargo, el computo binario se volvió mas eficiente y los investigadores sugirieron que las redes neuronales tenían ciertas limitantes, Guerriere y Destky (1991). No fue hasta el desarrollo de tecnología computacional que las redes volvieron a cobrar relevancia en las tareas de clasificación como un sistema complejo que puede dividirse en elementos simples o elementos simples que pueden unirse para producir un sistema complejo, Gershenson (2003).

En la actualidad las redes neuronales se utilizan para problemas de clasificación lineales o no lineales mediante hiperplanos de separación. La manera de lograr una clasificación correcta es ajustar los pesos de entrada y el umbral de clasificación para que

pueda trabajar la red. En el caso del umbral, se pueden utilizar diferentes criterios como el de Sigmoid que determina la clase de una instancia según su probabilidad de clasificación.

Una forma de optimizar los resultados de una red neuronal es utilizar el algoritmo de retro propagación que plantea una organización de las capas para enviar señales de excitación hacia adelante y luego los errores de clasificación son propagados hacia atrás. La idea central es reducir los errores de clasificación mientras la red aprende en el entrenamiento con pesos aleatorios que se ajustan hasta que se minimicen los errores.

Las redes neuronales destacan por su efectividad en la clasificación de imágenes, pero hay que tener en cuenta la elección de parámetros porque pueden hacer lento el aprendizaje, sobre ajustar los datos y clasificar las instancias en más falsas que positivas. En el campo de las desventajas, sobresale la explicación conceptual de la arquitectura y funcionamiento de la red neuronal que puede ser muy abstracto, tal como los sicilianos tenían la habilidad de la observación y contemplación de la persona para detectar padecimientos, pero el conocimiento no era traspasable.

## 2.5 Tableros

En los años ochenta, los directivos de las empresas buscaban formas de transformar los objetivos de la empresa en un comportamiento organizacional. Para dar solución al comportamiento organizacional, los investigadores de Harvard, Kaplan y Norton crearon los tableros de control como un sistema que transforma los datos en estrategias listas para tomar decisiones, Bradea et al. (2014). El propósito general de un tablero es brindar información disponible a cualquier momento y facilidad de entendimiento para todas las personas interesadas de una forma interactiva. El entendimiento de los datos lleva a desarrollar métricas de seguimiento como indicadores clave de rendimiento que se basan en el comportamiento de variables de interés para la organización.

La evolución de la tecnología y el rendimiento de las empresas al usar los datos como estrategia de negocio lograron integrar la información en tres formas de análisis como tableros operacionales, tácticos y estratégicos. El éxito de la integración de la información beneficia a empresas de distintas industrias para tomar decisiones basadas en datos prácticamente desde cualquier lugar.

Los tableros de control permiten tener información disponible en cualquier momento incluso de sistemas de lectura de placas como un monitor de operaciones. En esta situación un tablero de control ayuda a detectar

Los tableros de control permiten tener información disponible en cualquier momento, incluso para los sistemas de lectura de placas como un monitor de operaciones. En este sentido, para este documento, un tablero de operaciones es la representación de las lecturas obtenidas del proceso de clasificación de caracteres. La asertividad de los algoritmos se transmite al número de placas identificadas de la aplicación en la zona de Angelópolis para determinar estrategias de movilidad y seguridad pública. La visualización de un ejemplo de tablero se encuentra en la imagen 7.

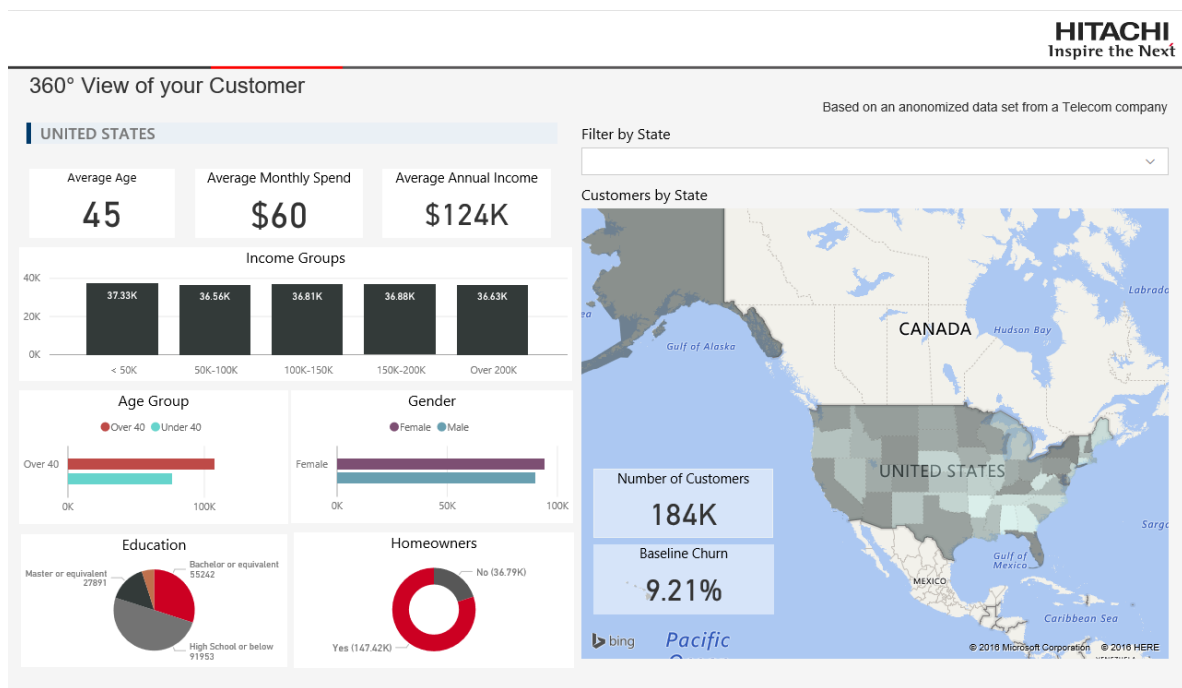


Imagen 7. Representación de tablero  
Fuente: <https://bit.ly/3wliM9J>

En la imagen 7 se puede observar el comportamiento de los usuarios en Estados Unidos. Para este ejemplo, se tiene datos sobre edad, gasto, ingreso, género y educación. Es a través del análisis de la información como se pueden hacer interesantes estadísticas como la edad, salario e ingreso promedio para segmentar por cada estado del país. También se puede conocer el porcentaje de usuarios según su género, educación y edad.

## CAPÍTULO 3: Revisión del estado del arte

El sistema de lectura y reconocimiento de placas fue introducido en 1979 para aliviar temas de seguridad por una subdivisión de desarrollo científico de la policía británica. A partir de ese momento, el sistema ha tenido diferentes usos y fines en la solución de problemas de la vida real que van desde la reducción de tiempos de viaje hasta la preservación ambiental disminuyendo la contaminación de las ciudades Marzuki et al. (2019). Sin embargo, el sistema de lectura de placas se ha implementado con mayor fuerza en la gestión de espacios públicos y privados que a su vez tienen la bondad de generar información para la seguridad pública y movilidad urbana.

El correcto funcionamiento de un sistema de lectura y reconocimiento de placas depende de las técnicas y metodologías usadas para identificar los caracteres de la placa en los vehículos. En la época reciente, los sistemas de lectura y reconocimiento de placas utilizan algoritmos de aprendizaje supervisado o aprendizaje profundo para segmentar, reconocer y clasificar los caracteres de una placa teniendo en cuenta los cambios en las escenas como son intensidad, luz, sombras, entre otros. En este apartado, se revisan diversos documentos relacionados a la clasificación de caracteres de las placas vehiculares con algoritmos de aprendizaje supervisado como vecinos cercanos, máquinas de soporte vectorial, bosques de clasificación y redes neuronales.

Los sistemas de lectura y reconocimiento de placas no necesariamente trabajan con algoritmos complicados o sofisticados para la clasificación de caracteres de una placa. Como ejemplo, se encuentra lo realizado por Azher et al. (2016) que crea un sistema de reconocimiento de placas para el pago automático en las autopistas de Indonesia. El sistema se divide en identificar el objeto y reconocer los caracteres con algoritmos de vecinos cercanos. Los resultados se comparan con el número de vecinos utilizados que son 1 y 5 que se entrenan con 360 tipos de caracteres. De esta manera, con 1 vecino cercano se obtiene 92.72% de acierto y con 5 vecinos se obtiene 93%. Se demuestra que 5 vecinos cercanos son un buen elemento de implementación para reconocimiento de caracteres.

Continuando la idea de trabajar con vecinos cercanos, Tabrizi y Cavus (2016) presentan un método que mejora el sistema de reconocimiento de placas en Irán con clasificación híbrida. Las fases del proceso se centran en procesar la placa, segmentar los caracteres, extraer el valor de las características y reconocer los caracteres con vecinos cercanos y máquinas de soporte vectorial. En la fase de clasificación se inicia con vecinos cercanos y en caso de que los caracteres sean similares la clasificación se hace con máquinas de soporte vectorial, es así como entrenando con 257 imágenes, 1 vecino cercano y kernel radial se obtiene 97% de acierto, un 3% más que el sistema anterior.

Inquiriendo en diferentes condiciones de características como ángulos, luz, y escenas complejas. Azher et al. (2016) sugiere un sistema de reconocimiento de placas para ciudades metropolitanas en Bangladesh con máquinas de soporte vectorial, un algoritmo de clasificación discriminativa. El procedimiento planteado es detectar a la placa, segmentar y reconocer los caracteres. De esta manera, se ejecuta un entrenamiento del algoritmo con 100 imágenes que tienen reducción de dimensionalidad por componentes principales y que se segmentan en 900 caracteres. Al probar el algoritmo con 8,253 caracteres nuevos se obtiene una precisión promedio de 93.2%.

Por otro lado, el trabajo de Ali et al. (2018), desarrolla una solución novedosa para reconocer placas de automóviles en China con redes neuronales profundas. El sistema consta de tres etapas como detección de placa, ajuste de características y reconocimiento de caracteres. La red neuronal se entrena con 40,000 caracteres procedentes de conjuntos de datos como Caltech Cars 1999 y PingAnCarPL. Los resultados del sistema cumplen de manera sobresaliente a comparación de algoritmos comerciales obteniendo un 91.88% de efectividad en reconocimiento de caracteres utilizando la optimización por gradiente estocástico y de Adam. Se destaca que, la clasificación se ve mermada por cambios en características de las escenas como al ambiente, la luz o la orientación de la imagen.

La falta de un sistema capaz de adaptarse a cualquier ambiente llevó a Laroca et al. (2018) a presentar un sistema de reconocimiento automático de placas robusto y eficiente para distintos conjuntos de datos. Lo anterior lo logra con un diseño de segmentación y reconocimiento de caracteres integrando el sistema YOLO. La tasa de acierto con los datos de entrenamiento brinda un 93.53% de efectividad; resultado superior a sistemas comerciales que tienen un promedio de 89.90% y 93.03% de acierto. Para probar la robustez del sistema se utilizan datos públicos llamados UFPRALPR que contienen 150 videos y 4,500 capturas de cámaras con un acierto de 78.3% contrario a sistemas comerciales que dan un promedio de 70% de efectividad.

La capacidad de un sistema de placas puede representar distintos enfoques en la sociedad, no solo la lectura como identificación, sino también detectar placas de vehículos que violen reglas de tráfico, tal como lo hace Gunawan et al. (2019). El desarrollo del proyecto se basa en capturar la imagen, mejorar la calidad de imagen, segmentar caracteres y clasificar caracteres según etiqueta. En la última etapa se utiliza el algoritmo de vecinos cercanos con entrenamiento en 100 imágenes que obtiene un 92.86% de éxito en datos de prueba. Al igual que los otros trabajos, se encuentran dificultades en caracteres similares o intensidad de luz.

Regresando a la lectura de placas como control vehicular, Park et al. (2019) explica un sistema de reconocimiento de placas multi estilo implementado con un algoritmo de vecinos cercanos. La estructura del sistema se basa en detectar la placa, clasificar la

estructura, segmentar y reconocer los caracteres. Los resultados derivan de entrenar al algoritmo con un video de 50 minutos que contiene 138 vehículos de 6 diferentes tipos de placa teniendo especial atención en las dimensiones de placa para evitar disparidades en el tamaño, de esta manera al pasar el algoritmo por datos de prueba se obtiene 99% de acierto.

En un intento por tener un sistema robusto, Laroca et al. (2019) formula un sistema de reconocimiento automático de placas con detección YOLO. Se plantean dos etapas en el diseño del sistema como la detección de placas con YOLO y reconocimiento de caracteres mediante el aprendizaje profundo. Para obtener un sistema robusto, se entrena la red neuronal con 772 imágenes diferentes obteniendo un 96.9% de acierto con un diseño de clasificación final y 94.8% sin el diseño de clasificación. Las ventajas del sistema desarrollado es el reconocimiento de hasta 4 placas en una misma instancia, sin embargo, la detección de placa se ve comprometida en condiciones de poca luz. Como recomendación final, los autores proponen extender la clasificación a marca y modelo de automóvil en diferentes escenas para lograr un sistema más robusto.

Para reconocer placas mediante el procesamiento frontal de la imagen de un auto, los autores Akhtar y Ali (2020) prueban distintos algoritmos de aprendizaje supervisado para comparar la efectividad de cada uno de ellos. Para poder realizar la comparación del algoritmo, se procesa la calidad de la imagen, se localiza la placa, se segmentan los caracteres y se clasifican con algoritmos de aprendizaje supervisado. En el estudio, se utilizan vecinos cercanos, máquinas de soporte vectorial, redes neuronales y bosques de clasificación. El proceso de entrenamiento de un bosque de clasificación con 200 imágenes obtiene la mejor tasa de acierto con 90.9%. Se concluye que los bosques de clasificación son la mejor herramienta para esta labor debido a su segmentación multiclase.

Siguiendo los esfuerzos por encontrar un sistema robusto, Ali et al. (2020) busca una solución general a la lectura y reconocimiento de placas robusta y aplicable en cualquier lugar del mundo. Empleando una etapa de segmentación por polaridad con mapa RGB para homogeneizar y otra etapa de reconocimiento de caracteres con redes neuronales y clasificación de etiquetas con máquinas de soporte vectorial, se logra reconocer el 98% de los caracteres en una matrícula vehicular. En el trabajo se destaca la efectividad del sistema derivada del cambio de color a blanco y negro que permitió reducir el ruido de las características en la escena y el entrenamiento del algoritmo con 84,058 caracteres diferentes.

Utilizando librerías abiertas como OpenCV y Tensor Flow, Fang et al. (2020) implementa una red neuronal para identificar caracteres después de segmentar la placa por el sistema YOLO. Se entrena una red convolucional con 5,780 caracteres diferentes garantizando una tasa de acierto de 98% con velocidad superior a R-CNN, Fast R-CNN y

Faster R-CNN de 7, 80 y 7 veces respectivamente. Aun cuando, la tasa de acierto disminuye si se aplica en otro conjunto de datos.

Examinando otras vías para mejorar la efectividad en el reconocimiento de caracteres, Poltavskiy et al. (2020) expone un sistema inteligente de reconocimiento considerando los estándares para placas en diferentes continentes y países con las dificultades de localización, clima, luz y deformaciones en la placa. El marco del sistema se divide en tres etapas: detección de vehículo, detección de objeto y reconocimiento de los caracteres. Los resultados de aplicar redes neuronales convolucionales con entrenamiento en diferentes condiciones y estándares en 2,409 imágenes se traducen en un acierto de 94%. La sugerencia de los autores es aumentar el conjunto de datos de entrenamiento para lograr mayor efectividad, aunque, el modelo presentado muestra una calidad de reconocimiento superior a paquetes comerciales.

Los sistemas de lectura y reconocimiento de placas, de manera general, basan su diseño en detectar la placa de un vehículo, segmentar los caracteres y clasificar por etiquetas. La detección de placa puede ser desarrollada dentro del algoritmo o se pueden usar sistemas como YOLO (*You Only Look Once*, por sus siglas en inglés). La integración con YOLO permite concentrarse en solo segmentar y clasificar los caracteres de la placa sin la necesidad de realizar un proceso de visión computacional.

El estado del arte incorpora fuentes de estudio con metodologías, procesos y resultados que enriquecen el contenido de esta tesis. De manera particular, se destacan ideas que ayudan al diseño de estrategias y procesos para la aplicación de algoritmos de aprendizaje supervisado en la lectura y reconocimiento de placas. Como complemento a los trabajos revisados de aplicación de algoritmos, Parvin et al. (2021) explica que el crecimiento en la era moderna y el estilo de vida de las personas hace que aumente el número de vehículos en las calles; generando congestiones viales o problemas de movilidad. Como respuesta al crecimiento de las grandes ciudades, Lubna et al. (2021) inspecciona diferentes documentos de sistemas de lectura de placa que concuerdan en dividir al sistema en extraer la imagen, segmentar caracteres y reconocer caracteres. Además, se enfatiza en el beneficio de algoritmos de aprendizaje supervisado para clasificar caracteres como vecinos cercanos, máquinas de soporte vectorial, bosques de clasificación y redes neuronales.

La tabla 1 muestra las características de la revisión de literatura para el procesamiento adoptado, número de instancias de entrenamiento, algoritmos utilizados y porcentaje de acierto logrado. Con el resumen de los documentos, se enfatiza únicamente en la clasificación de caracteres de la placa con cambios de tamaño y de color con algoritmos de vecinos cercanos, máquinas de soporte vectorial, bosques de clasificación y redes neuronales.

Tabla 1. Revisión de literatura

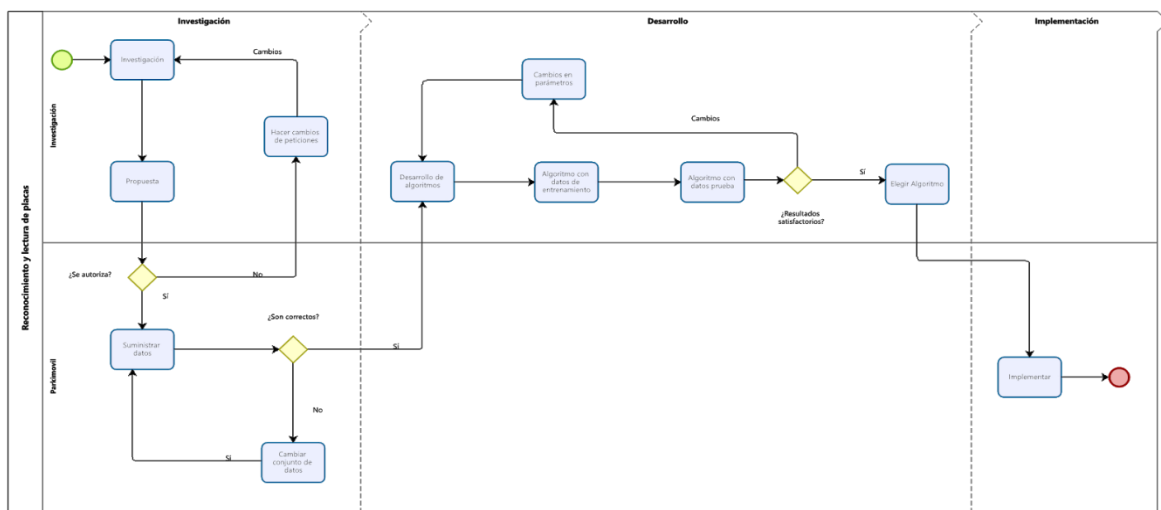
Autores	Etapas	Número de datos	Algoritmos	Resultados
Azher et al. (2016)	<ol style="list-style-type: none"> <li>1. Identificar objeto</li> <li>2. Reconocer caracteres</li> </ol>	360 caracteres	KNN	93%
Tabrizi y Cabvus (2016)	<ol style="list-style-type: none"> <li>1. Procesar placa</li> <li>2. Segmentar caracteres</li> <li>3. Extraer características</li> <li>4. Reconocer caracteres</li> </ol>	257 imágenes	KNN-SVM	97%
Azher et al. (2016)	<ol style="list-style-type: none"> <li>1. Detectar placa</li> <li>2. Segmentar caracteres</li> <li>3. Reconocer caracteres</li> </ol>	900 caracteres	SVM	93.20%
Ali et al. (2018)	<ol style="list-style-type: none"> <li>1. Detección de placa</li> <li>2. Ajuste de características</li> <li>3. Reconocimiento de caracteres</li> </ol>	40,000 caracteres	Nnet	91.88%
Laroca et al. (2018)	<ol style="list-style-type: none"> <li>1. Detección objeto (YOLO)</li> <li>2. Segmentar caracteres</li> <li>3. Clasificar caracteres</li> </ol>	4,500 imágenes	Nnet	93.03%
Gunawan, et al. (2019)	<ol style="list-style-type: none"> <li>1. Mejorar calidad</li> <li>2. Segmentar caracteres</li> <li>3. Clasificar caracteres</li> </ol>	100 imágenes	KNN	92.86%
Park et al. (2019)	<ol style="list-style-type: none"> <li>1. Detectar placa</li> </ol>	138 vehículos	KNN	99%

	<ol style="list-style-type: none"> <li>2. Clasificar estructura</li> <li>3. Segmentar caracteres</li> <li>4. Reconocer caracteres</li> </ol>			
Laroca et al. (2019)	<ol style="list-style-type: none"> <li>1. Detección objeto (YOLO)</li> <li>2. Reconocimiento de caracteres</li> </ol>	772 imágenes	Nnet	96.99%
Akhtar y Ali (2020)	<ol style="list-style-type: none"> <li>1. Mejorar calidad</li> <li>2. Localizar placa</li> <li>3. Segmentar caracteres</li> <li>4. Clasificar caracteres</li> </ol>	200 imágenes	RFC-SVM-KNN-Nnet	90.9%
Ali et al. (2020)	<ol style="list-style-type: none"> <li>1. Segmentar placa</li> <li>2. Segmentar caracteres</li> <li>3. Reconocimiento de caracteres</li> </ol>	84,058 caracteres	Nnet	98%
Fang et al. (2020)	<ol style="list-style-type: none"> <li>1. Detección objeto (YOLO)</li> <li>2. Segmentar caracteres</li> <li>3. Reconocimiento de caracteres</li> </ol>	5,780 caracteres	Nnet	98%
Polanski et al. (2020)	<ol style="list-style-type: none"> <li>1. Detección de vehículo</li> <li>2. Detección objeto</li> <li>3. Reconocimiento de caracteres</li> </ol>	2,409 imágenes	Nnet	94%

## CAPÍTULO 4: Metodología

La metodología del presente trabajo reúne los elementos necesarios para el desarrollo de cada etapa. En concreto, se formula un documento sustentando en la revisión de literatura para clasificar caracteres de una placa. La metodología comprende la investigación, obtención de datos, desarrollo de la clasificación de algoritmos y la implementación del sistema. Por otro lado, la primera etapa consta de la investigación y revisión de literatura respecto a los trabajos con menos de 5 años que tienen relación con la lectura y reconocimiento de placas utilizando algoritmos de aprendizaje automático. La segunda etapa se basa en obtener los datos de Parkimovil, en este caso imágenes de automóviles en controles de acceso. La tercera etapa es el entrenamiento de algoritmos como vecinos cercanos, máquinas de soporte vectorial, bosques aleatorios de clasificación y redes neuronales con los caracteres extraídos para clasificar las etiquetas. Finalmente, la última etapa no es alcanzable de este trabajo, debido a factores externos que impiden la implementación del aprendizaje supervisado.

El proceso de desarrollo de la tesis se visualiza en la imagen 7. Esto es una representación de los pasos a seguir en cada etapa para poder lograr las metas y propósitos propuestos.



Presented by  
**bizagi**  
Modeler

Imagen 7. Metodología

## 4.1 Metodología KDD para clasificación de caracteres

La metodología para la clasificación de caracteres funda las bases para el desarrollo de la última etapa de un sistema de lectura y reconocimiento de placas. En consecuencia, la metodología apropiada para este trabajo se basa en la comprensión de los alcances del trabajo: los esfuerzos se concentran en desarrollar únicamente la fase de clasificación de caracteres sin tomar en cuenta técnicas de reconocimiento de objeto o segmentación de caracteres. De modo que la metodología elegida es la conocida como KDD (*Knowledge Discovery in Databases*, por sus siglas en inglés). La metodología KDD comienza con la recolección y descripción del conjunto de datos, enseguida se continúa con la selección de datos basados en criterios de visualización, un tercer paso es procesar y transformar los datos para tener imágenes homogéneas, después de los pasos anteriores se aplica el aprendizaje automático de 4 algoritmos supervisados, el penúltimo paso es la interpretación de la aplicación de algoritmos y finalmente el descubrimiento de conocimiento que deja la laboriosidad de todos los pasos descritos.

### **Conjunto de datos**

La primera parte de esta metodología contempla la recolección y descripción de los datos con que se va a trabajar en los siguientes pasos. En esta circunstancia, se van a recolectar los datos de una página web que sirve como consola de control para los fraccionamientos de control de acceso. Los datos proporcionados por la consola de control son fotografías de los vehículos que transitan por la zona con un campo de fecha y hora que fueron tomadas. Las fotografías son tomadas de manera frontal al vehículo en diferentes días de la semana y horas del día.

Las fotografías para recolectar contienen información de diferentes características de la placa en cualquier momento del día. Por consiguiente, el conjunto de datos goza de riqueza de información que se expresa en diversos caracteres relacionados. Entonces, se necesita estructurar el sistema de lectura de placas considerando todas las variables inmersas que se encontraron en la revisión de literatura. En esta revisión se encontró que la mayoría de los sistemas se dividen en identificar la placa, segmentar los caracteres y clasificar los caracteres, aunque dados los objetivos de este documento, únicamente se contempla la clasificación de caracteres que se apoya del aprendizaje supervisado. En la imagen 8 se detallan las clásicas etapas del desarrollo de un sistema de lectura de placas.

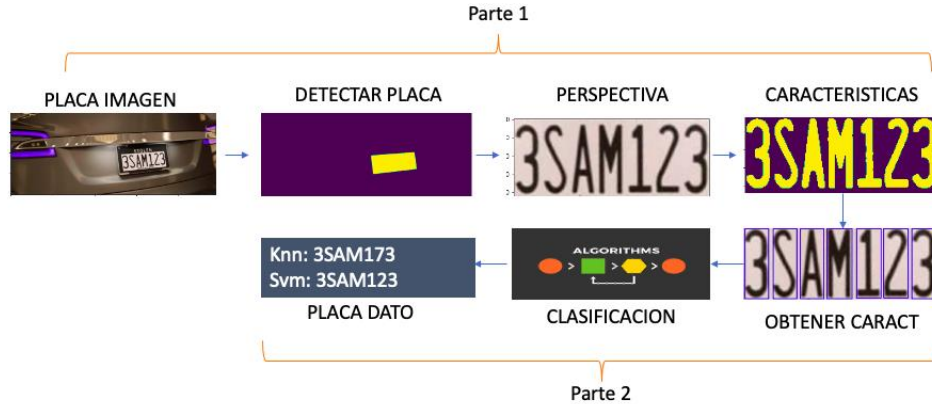


Imagen 8. Sistema de lectura de placas

En la imagen 8, se visualizan las etapas del desarrollo de un sistema de lectura de placas eficiente, de acuerdo con la literatura encontrada: la mayoría de los documentos encontrados dividen un sistema en tres etapas. Pero, en los alcances de este trabajo se omiten las etapas de detección del objeto y se ejecuta la etapa de clasificación. En el siguiente apartado de la metodología se detallan los pasos a seguir para clasificar a los caracteres de cada placa.

### Selección de datos

Después de la recolección de datos, se obtiene un conjunto de imágenes con una enorme riqueza de información sobre automóviles en controles de acceso. Se contempla seleccionar las imágenes que no causen demasiado ruido al clasificar por los caracteres de la placa. El ruido antes mencionado puede traducirse como interferencias en la placa, poca legibilidad de los caracteres, distancias de la toma que complican la lectura y cambios en la escena que provocan distorsiones en la imagen. Además, como se mencionó anteriormente, el objetivo es clasificar los caracteres, sin embargo, para poder desarrollar esa etapa se necesita segmentar a los caracteres que no tengan ruido y sean legibles manualmente.

La segmentación de caracteres comienza por el conocimiento del conjunto de datos que se conforma de 30 instancias para cada carácter. La extracción de los caracteres deriva de seleccionar las imágenes de la placa con el menor ruido posible. Cabe recalcar, que este proceso se repite para 34 etiquetas diferentes que deja un conjunto de datos de 1,020 objetos de estudio. En la búsqueda de las etiquetas en las placas de la base de datos se encuentra que no existen caracteres para letras como I, Ñ, O y Q. En contraste, se identifica

al guion que separa las letras y números de las placas como una etiqueta más que ayude a clasificar todos los caracteres, la lista de los que están disponibles es la siguiente:

'0','1','2','3','4','5','6','7','8','9','A','B','C','D','E','F','G','H','J','K','L','M','N','P','R','S','T','U','V',  
'W','X','Y','Z','GU'

Es así cómo se seleccionan las imágenes más idóneas para analizar con criterios basados en contraste, luz o distancia. Una vez seleccionado este proceso, se procede a segmentar los caracteres de las imágenes antes guardadas para obtener un conjunto de datos como imágenes organizado por la etiqueta y el número de instancia correspondiente. Este paso es vital para la realización del proyecto debido a la importancia de las entradas de entrenamiento a los algoritmos de aprendizaje supervisado, sin embargo, en la siguiente sección se exploran los procesos y cambios que necesita el conjunto de datos para pasar a la etapa de clasificación de caracteres.

### **Procesamiento y transformación (Proceso ETL)**

La etapa de procesamiento y transformación de datos examina los métodos idóneos según la revisión de literatura para integrar una base de datos que ayude a obtener resultados de clasificación altos. Por lo anterior, en esta etapa se extraen las imágenes y sus respectivas etiquetas, en el siguiente paso se cambia la dimensión de las imágenes para tener homogeneidad y finalmente se experimenta con un cambio de RGB a blanco y negro.

Para obtener los datos y etiquetas de las imágenes de caracteres se planea hacer un llamado a la carpeta de origen que contiene 1,020 instancias. La forma de dividir a los datos es extraer la imagen como dato y el nombre de la imagen como etiqueta, de esa manera se pueden identificar los 34 diferentes tipos de caracteres propuestos. La siguiente parte consta de analizar la dimensión de cada imagen de los caracteres, esto de acuerdo con la revisión de literatura que plantea tener instancias con la misma dimensión, ya que los algoritmos pueden encontrar problemas en la clasificación de etiquetas. Para tener un conjunto de datos homogéneo se proponen imágenes de 20x20, las imágenes con dimensiones más amplias se reducen y aquellas con dimensiones menos amplias aumentan de tamaño. En el último paso, la literatura no tiene un veredicto general sobre la escala de colores a utilizar en el conjunto de datos, por esta razón, se plantea cambiar el color de las imágenes a RBG y blanco y negro.

La extensa revisión de literatura comenta que las imágenes homogéneas logran mejores resultados en la fase de prueba del algoritmo que aquellas que no tienen la característica de homogeneidad. Por lo cual, volver homogéneas a las imágenes de los caracteres es vital en la transformación de datos para clasificación con algoritmos. Finalmente, el algoritmo necesita clasificar las características de las imágenes, es decir, los píxeles y los cambios de color de cada carácter, es por ello, que se ejecuta el histograma del gradiente para obtener las características en los cambios de color.

### **Aprendizaje automático**

La etapa del aprendizaje automático comprende las técnicas a utilizar para lograr el propósito de esta tesis: clasificar los caracteres de la placa. Aunque, la clasificación depende de un correcto entendimiento de los algoritmos y configuración de parámetros que ayuden a tener una tasa de acierto más alta. Los algoritmos descritos a continuación son una recopilación de la revisión de literatura que contempla algoritmos sencillos, pero efectivos, así como algoritmos avanzados de aprendizaje profundo. En el caso del conjunto de datos, se hace una partición de entrenamiento a 75% y prueba a 25%.

### **Vecinos cercanos**

De acuerdo con Akhtar et al. (2020), los vecinos cercanos son un algoritmo de enfoque de clasificación no paramétrico. En otras palabras, los grupos de entrenamiento se entrenan en clases similares, de manera que cuando una nueva instancia es añadida, el número de vecinos más cercanos eligen la clasificación de la imagen. Esta definición, hace énfasis en la importancia de la etapa de entrenamiento del algoritmo, que coincide en lo dicho por Gunawan et al. (2019), donde los vecinos cercanos clasifican al objeto según el número de objetos más cercanos basado en el conjunto de entrenamiento.

En esta etapa de implementación de vecinos cercanos para clasificación de caracteres, algunos autores comparten el número de vecinos cercanos que ayudó a tener un modelo óptimo para la tasa de acierto. Autores como Akhtar et al. (2020) muestra como 3 vecinos cercanos son suficientes para tener resultados de acierto altos, por otro lado, Azher et al (2016) compara el desempeño de la tasa de acierto con 1 y 5 vecinos obteniendo un porcentaje con mejor desempeño en 5 vecinos. Dado lo anterior, la aplicación de un algoritmo de vecinos cercanos debe guiarse por los resultados en entrenamiento, pero sobre todo en los resultados de prueba ya que estos son los que aún no ha visto el algoritmo y plantea clasificar. Es por ello por lo que este trabajo desarrolla diferentes estimaciones

con vecinos del 1 al 30, esperando determinar qué vecino tiene la tasa de acierto más alta para ambos casos de prueba.

Las máquinas de soporte vectorial en palabras de Akhtar et al. (2020), son un algoritmo de clasificación discriminativo que categoriza los datos formando un hiperplano, que es la forma de trabajo adecuada para clasificar datos binarios, en este caso, las máquinas de soporte vectorial se pueden extender a la clasificación de clases. En orden de obtener un modelo de máquinas de soporte vectorial óptimo en clasificación, la literatura propone establecer ciertos parámetros como el Kernel y el pasillo de clasificación conocido como 'C'. Los parámetros de clasificación son muy importantes para tener resultados robustos, como en el caso de Tabrizi y Cavus (2016) que, mediante un sistema híbrido clasifica a los caracteres similares obteniendo un 97% de acierto en datos de prueba. Los parámetros de Kernel cambian según el conjunto de datos, pero la literatura está de acuerdo en que un valor de pasillo más alto supone mejores resultados. Para Armogan et al. (2020) los cambios en parámetros y consideraciones en el color de las imágenes llevan a tener un contraste más amplio y por ende una clasificación del 98%.

Como se pudo leer, las máquinas de soporte vectorial son un gran auxiliar para clasificar caracteres de una placa. En este documento, se propone trabajar con las máquinas de soporte vectorial como método de clasificación por clases en sus diferentes kernels como lineal, polinomial y radial. Además, se planea cambiar el valor del pasillo en diferentes rangos para comparar los resultados de cada modelo. Al igual, los modelos van a incorporar validación cruzada para obtener un promedio de acierto según los parámetros elegidos cambiando las instancias de entrenamiento y prueba.

Los bosques de clasificación son una herramienta versátil que procede de los árboles de clasificación. Los árboles se basan según Akhtar et al. (2020) en escoger de manera aleatoria un conjunto de datos y tomar decisiones a través de nodos principales. Sin embargo, este enfoque es susceptible de cambios por los datos seleccionados, por ello, nacen los bosques de clasificación que recogen el resultado de diferentes árboles de clasificación para dar una tasa de acierto promedio. Este algoritmo es idóneo para el problema de clasificación de caracteres porque su trabajo es una segmentación multiclase que pasa por todos sus nodos. De esta manera, el autor ejecuta un modelo con diferentes características que ayudan a ajustar los parámetros para obtener una tasa de acierto alta. Las características de los modelos son utilizar la técnica de bagging para promediar los resultados de diferentes árboles de clasificación y partir los nodos sobre la raíz cuadrada del número de características del modelo. Los bosques de clasificación son una aproximación adecuada al problema de clasificación debido al trabajo que tiene su estructura multiclase. Lo anterior, sustenta las bases para la aplicación de los bosques con las técnicas mencionadas, además, se propone hacer diferentes modelos con los valores de

bagging, separación y validación cruzada en un rango de 100 500, 1,000, 2,000, 5,000 y 10,000 árboles de clasificación.

Las redes neuronales son un algoritmo de aprendizaje profundo que basa su trabajo en replicar el comportamiento del cerebro humano. Akhtar et al. (2020) menciona que las redes neuronales se desarrollan en 3 tipos de categorización llamadas neuronas de entrada, capas ocultas y neuronas de salida. Las neuronas de entrada es la dimensión de los datos proporcionados a la red, las capas ocultas se encargan de ayudar al entrenamiento de clasificación y las neuronas de salida son las diferentes clases de las etiquetas.

En este mismo sentido, Ali et al. (2020) menciona que cambios en las características de entrada tienen influencia en la estimación de etiquetas. Por ello se siguen las sugerencias de la revisión de literatura donde las neuronas de entrada es la dimensión de las imágenes y las neuronas de salida las etiquetas a clasificar que en este caso son 34. Además, algunos documentos proponen una función de activación logística y establecer el aprendizaje en 0.001, empero, se propone hacer diferentes modelos con activación logística, de adam, adam max, gradiente y tasa de aprendizaje de 0.001 a 0.1.

## **Interpretación**

De acuerdo con la investigación de literatura realizada, el factor que miden los documentos es la tasa de acierto que tienen los algoritmos al detectar un carácter de manera correcta o incorrecta. Es, por ende, la tasa de acierto la interpretación central de los resultados a obtener en esta tesis, en el entendido de que tener una tasa de acierto alta en los datos de prueba significa que el algoritmo clasifica de manera correcta a la mayoría de los datos y en caso contrario es tener una tasa de acierto baja que clasifica de manera incorrecta a la mayoría de los datos.

Por lo tanto, la vía de análisis en la clasificación de caracteres para la zona de Angelópolis es la tasa de acierto más alta comparando los algoritmos aplicados en la etapa de entrenamiento y prueba. Lo anterior, integra el análisis del desempeño de diversos algoritmos sustentados en la revisión de literatura que van de los más básicos como los vecinos cercanos a los más avanzados como las redes neuronales, sin embargo, como se sustentó en los documentos encontrados, la dificultad del algoritmo no determina la efectividad de los resultados. Es decir, los resultados se basan en la interacción y recolección de datos particulares y no en el método de clasificación elegido.

## **Descubrimiento de conocimiento**

El sistema de lectura y reconocimiento de placas es un gran auxiliar como contribuyente a la inseguridad pública y movilidad de las ciudades urbanas. En esta situación, la etapa de clasificación que se va a aplicar en este documento es un motor de conocimiento para los datos de la empresa de movilidad. Después de exhaustivas aplicaciones de algoritmos de aprendizaje supervisado se buscará encontrar una tasa de acierto para la clasificación de caracteres que permita identificar patrones de movilidad y contribuir a la seguridad pública de la zona de Angelópolis.

Se busca que la etapa de clasificación sea lo bastante robusta para clasificar caracteres de la placa y se puedan integrar los datos de la aplicación Parkimovil con la lectura de placa. Lo anterior, se sustenta en que usuarios de la aplicación interactúan en diferentes servicios con un identificador como el teléfono celular. Aunque, algunos usuarios registran las placas de sus automóviles y es en este escenario donde se hace un esfuerzo por encontrar operaciones de usuarios identificándolos por la placa para después construir un modelo multidimensional que mida la vida del usuario en un tablero de inteligencia de negocios que proporcione toda la información necesaria para identificar patrones de movilidad.

En un caso similar, la lectura de placas en una zona tan importante como la de Puebla tiene millones de lecturas de automóviles que transitan por algunos fraccionamientos. En este sentido, tener una clasificación adecuada de los caracteres de la placa es un pilar central en la lectura de placa que contribuya a identificar en una mayor proporción a los autos que pasan por la zona. Además, la empresa cuenta con una extensa base de datos que se puede complementar con verificación de las placas con REPUVE para dar información verídica de los automóviles y si estos han tenido un reporte de robo. Lo anterior se refuerza con un tablero de control para la organización donde se pueden revisar diversos factores para extraer información que sirva para la seguridad pública de los lugares.

## CAPÍTULO 5: Resultados

En este capítulo se describen los resultados encontrados en la detección de caracteres aplicando algoritmos de aprendizaje supervisado para un conjunto de datos de 34 etiquetas con diferentes diseños de modelos para lograr la mayor eficiencia posible. También se mencionan los patrones de comportamiento de los usuarios en los distintos servicios y proyectos ofrecidos, evidenciando que la lectura de placas es un factor importante para la identificación de factores de movilidad. Finalmente, el apartado de tablero de seguridad desvela información sobre las características de los vehículos y si estos cuentan con reporte de robo para conocer la hora, día y zona de mayor concurrencia.

### 5.1 Detección de caracteres

La detección de caracteres en una placa aplicando algoritmos de clasificación es el principal objetivo de este trabajo con datos y etiquetas como extracción de escenas tomadas por la empresa de movilidad. En este apartado se enlistan los resultados de diferentes modelos en algoritmos de clasificación como vecinos cercanos, máquinas de soporte vectorial, bosques de clasificación y redes neuronales.

#### 5.1.1 Clasificación de caracteres con vecinos cercanos

Emplear un algoritmo de vecinos cercanos contempla la distancia de medición y el número de vecinos cercanos óptimos que permitan clasificar a las instancias de forma correcta. El número de vecinos cercanos sirve para hacer un voto mayoritario de un nuevo dato, de esta manera, la mayoría de los vecinos con distancia más corta deciden la clasificación. Dado lo anterior, este apartado resume diferentes modelos con técnicas como validación cruzada para obtener la mejor estimación de caracteres de la placa.

Iniciando la aplicación de los vecinos cercanos se trabaja con un conjunto de datos partido en 75% para entrenamiento y 25% de prueba. El primer modelo de este algoritmo se trabaja en Python con parámetros por defecto de la librería KNN teniendo un 89.7% de acierto identificando las etiquetas de entrenamiento y 87.9% en la identificación de los datos de prueba. No obstante, se plantea cambiar el número de vecinos en un rango de 1 a 30 para visualizar el comportamiento de la predicción en entrenamiento y prueba para conocer el vecino que más se ajusta a los datos. La imagen 9 expone el número de vecinos en el eje horizontal y la precisión para entrenamiento y prueba en el eje vertical.




Imagen 9. Selección de vecinos óptimos

La imagen 14 indica que la predicción en ambos conjuntos es mejor para vecinos impares como 1, 3 y 5, mientras para vecinos superiores a 10 la predicción disminuye de manera considerable hasta alcanzar valores entorno al 82%. En la tabla 2 se resumen las predicciones de cambiar el número de vecinos cercanos de 1 a 10 utilizando la distancia euclidiana para predecir los valores de entrenamiento y prueba.

Tabla 2. Selección vecinos cercanos

Vecinos	Entrenamiento	Prueba
1	100%	84.90%
2	91.07%	82.40%
3	92.05%	87.86%
4	89.12%	83.68%
5	89.67%	87.44%
6	89.81%	87.43%
7	89.67%	86.61%
8	89.53%	87.43%
9	89.26%	85.35%
10	88.44%	84.51%

La imagen 9 y la tabla 2 confirman que la predicción aumenta utilizando 1,3 y 5 vecinos cercanos. En consecuencia, se hacen otras estimaciones con vecinos de 1 a 30 aplicando la validación cruzada obteniendo una predicción promedio de 87.88% para 9 vecinos. Los resultados de la estimación de la validación cruzada pueden ser visualizados en una gráfica de la matriz de confusión en la imagen 10 que deja en el eje vertical las etiquetas reales y en el horizontal la clasificación encontrada.

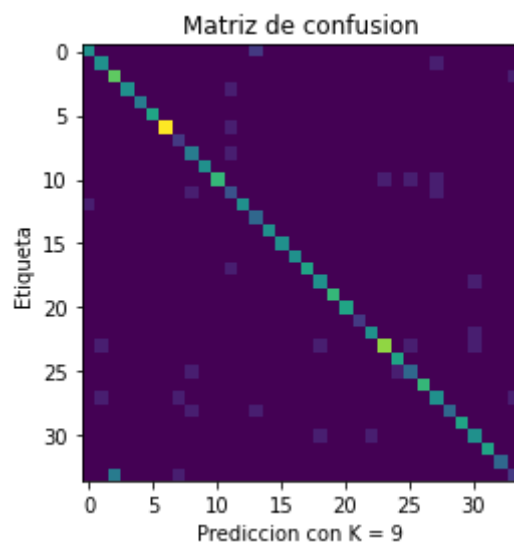


Imagen 10. Matriz de confusión

En un escenario ideal la gráfica de la matriz de confusión debe mantener una línea de color en forma vertical y pendiente negativa para clasificar a las etiquetas de manera correcta. En el caso de la imagen 10, los números van del 1 al 9 y las letras comienzan con la A y el número 10. De esta manera, la imagen 16 exhibe que los números 4 y 5 fueron clasificados correctamente, pero letras como B (11), D (13) y Z (33) tienen errores en clasificación.

Finalmente, la tabla 3 sintetiza los resultados en el comportamiento de la clasificación cambiando parámetros como el número de vecinos y la aplicación de la validación cruzada para comparar la efectividad en la predicción de cada modelo presentado. Se encuentra que la clasificación de caracteres es menor para valores como 2, 4 o 10, contrario a valores impares como 1, 3, 5 y la aplicación de validación cruzada con 9 vecinos cercanos.

Tabla 3. Resultados de vecinos cercanos

Parámetros	Entrenamiento	Prueba
Defecto	89.7%	87.9%
K=1	100%	84.90%
K=2	91.07%	82.40%
K=3	92.05%	87.86%
K=4	89.12%	83.68%
K=5	89.67%	87.44%
K=6	89.81%	87.43%
K=7	89.67%	86.61%
K=8	89.53%	87.43%
K=9	89.26%	85.35%

K=10	88.44%	84.51%
Validación Cruzada, K = 9		87.88%

### 5.1.2 Clasificación de caracteres con máquinas de soporte vectorial

La clasificación de caracteres con máquinas de soporte vectorial descansa en separar las características de los datos mediante un hiperplano ya sea con un método lineal, radial o polinomial. Para este apartado se trabaja con la librería de Sklearn en Python y el mismo conjunto de datos de vecinos cercanos, pero aplicando el método lineal, radial y polinomial con cambios en un rango del kernel que ayudan a encontrar el modelo con mejor estimación.

Utilizando los parámetros por defecto de la librería de máquinas de soporte vectorial, se ejecuta el primer modelo que tiene en cuenta método radial con predicción del 89.95% con datos de prueba. Enseguida, se cambia únicamente el método de estimación a lineal y polinomial con los mismos valores para obtener una precisión de 90.07% y 90.03% respectivamente.

Para mejorar la predicción del modelo se opta por validación cruzada para los tres tipos de métodos obteniendo 91.01% en lineal, 89.63% en radial y 91.32 en método polinomial. Los resultados de esta aproximación sugieren que la validación cruzada es un buen aliado para mejorar la estimación de clasificación. En una siguiente etapa se ejecuta la validación cruzada, pero cambiando los valores del ancho del pasillo en un método lineal de 1 a 25 para observar el comportamiento de la predicción en la imagen 11.

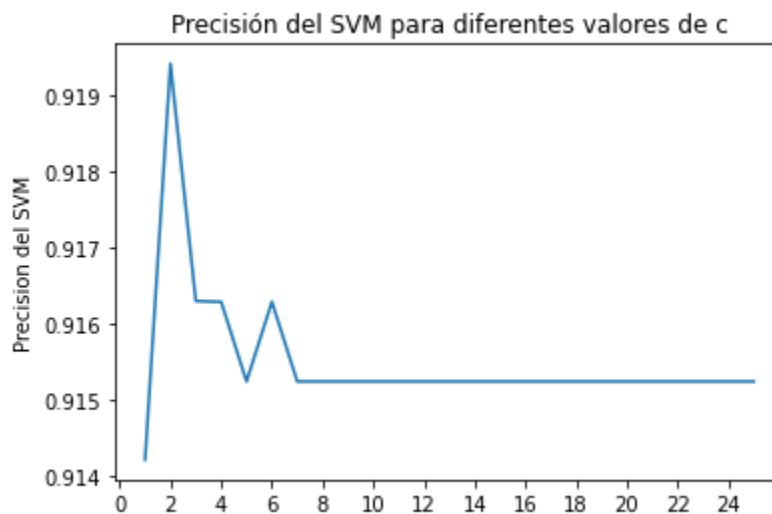


Imagen 11. Precisión del SVM

La precisión de un método lineal con diferentes valores de ancho de pasillo disminuye a partir del valor 2 y después del valor 7 no hay ninguna ganancia presente. La visualización permite tomar el valor de 2 para el ancho del pasillo y estimar la predicción del modelo con validación cruzada obteniendo 91.94% en datos de prueba.

Para una estimación radial se emplea un rango de gamma en kernel de 0.001 a 10 que se visualiza en la imagen 12. La precisión del modelo se ve reducida a partir del valor 2 y luego no existe alguna ganancia, por esta razón se emplea un kernel de 0.1 con validación cruzada que da una precisión de 90%.




Imagen 12. Precisión Gamma

Finalmente, para terminar con el algoritmo de SVM se hacen estimaciones con diferentes valores polinomiales de 2 a 10 obteniendo resultados plausibles que tienen un acierto por encima del 90% vistos en la imagen 13. En un último ejercicio se ejecuta un modelo con un valor polinomial de 6 y validación cruzada teniendo 91.83%.




Imagen 13. Precisión Polinomial

La tabla 4 es una representación comparativa de los diferentes modelos presentados con cambios en método, kernel y validación cruzada.

Tabla 4. Resultados SVM

Kernel	Parámetros	Entrenamiento	Prueba
Lineal	Defecto	92%	90.07%
	Validación Cruzada		91.01%
	Validación Cruzada y C=2		91.94%
Radial	Defecto	90.5%	89.95%
	Validación Cruzada		89.63%
	Validación Cruzada y gamma = 0.001		90%
Polinomial	Defecto	92%	90.03%
	Validación Cruzada		91.32%
	Validación Cruzada y K=6		91.83%

Las máquinas de soporte vectorial tienen un comportamiento estable con cualquiera de los métodos aplicados. Sin embargo, en el caso lineal la predicción mejora con validación cruzada y ancho de pasillo 2, en el método radial la predicción llega a 90% con validación cruzada y gamma de 0.001, por último, el método polinomial tiene una mejora en la predicción cuando se hace validación cruzada y un valor polinomial de 6.

### 5.1.3 Clasificación de caracteres con árboles y bosques aleatorios

Los árboles de clasificación funcionan eligiendo a la característica que tiene mayor incidencia en el modelo dejándola como un nodo raíz, de manera que la elección de un carácter sigue una ruta establecida en el árbol que pasa por nodo principal, nodos intermedios y hojas. En este caso, la clasificación de caracteres con árboles no es un buen algoritmo debido a la sensibilidad de datos elegidos para predecir. Por esta razón, después de explorar los árboles, se ejecutan los bosques aleatorios para obtener el promedio de clasificación según el número de árboles indicados. Los resultados de utilizar la entropía como criterio de ganancia dejan un 62% para los árboles e incluso con validación cruzada se obtiene 61.2%, resultados por debajo de lo obtenido con bosque aleatorio de 5,000 árboles que representa una estimación de 89.64%. Esto deja en claro la sensibilidad de los árboles y la bondad de los bosques con los datos suministrados de entrenamiento y prueba a razón de 75-25.

La primera ejecución de un árbol de clasificación tiene parámetros por defecto y la ganancia del modelo como entropía. En el modelo de entrenamiento tiene un valor de 81% y para prueba 62% de predicción. Para aliviar la situación de sensibilidad de los datos se ejecuta una validación cruzada a subgrupos teniendo 61% de acierto en la clasificación de etiquetas.

Es notable que la clasificación es baja debido al problema de selección de cada árbol, sin embargo, hay una alternativa que propone estimar un bosque de clasificación: distintos árboles, tantos que se pueda emular un bosque de estimaciones, de esta manera se obtiene el promedio del bosque para clasificar los caracteres de la placa. En la tabla 5 se tiene la comparativa de ejecutar bosques aleatorios con valores de 100, 500, 1,000, 2,000, 5,000, 10,000, 30,000 y los resultados de estimación promedio.

Tabla 5. Resultados bosques de clasificación

Método	Parámetros	Entrenamiento	Prueba
Árboles de Clasificación	Entropía	81%	62%
	Validación Cruzada		61%
Bosques de Clasificación	Árboles = 100	88.21%	85.04%
Bosques de Clasificación	Árboles = 500	89.53%	87.87%
Bosques de Clasificación	Árboles = 1,000	89.95%	89.12%
Bosques de Clasificación	Árboles = 2,000	90.03%	87.71%
Bosques de Clasificación	Árboles = 5,000	89.95%	89.64%
Bosques de Clasificación	Árboles = 10,000	90.37%	89.33%
Bosques de Clasificación	Árboles = 30,000	90.37%	88%

Los resultados de bosques aleatorios mejora lo mostrado por arboles de decisión. El mal desempeño de los árboles se ve mejorado en casi 25% comparado a los árboles que para 5,000 y 10,000 árboles se obtienen 89.65% y 89.33%. Las estimaciones altas provienen de tener un bosque más amplio, aunque hay un punto de inflexión donde aumentar el tamaño del bosque disminuye las ganancias como se ve en la tabla 41 con 30,000 árboles.

#### 5.1.4 Clasificación de caracteres con redes neuronales

Las redes neuronales son un algoritmo supervisado muy utilizado para la clasificación de imágenes que ayude a detectar nuevas instancias en conjuntos de datos. De manera general una red neuronal emula el funcionamiento de las neuronas humanas que se comunican entre ellas por estímulos eléctricos. La estructura de una red neuronal tiene neuronas de entrada que reciben información del exterior y neuronas de salida que transmiten información al exterior y luego están las ocultas que intercambian información con otras neuronas de la red que pueden tener una o muchas capas interconectadas. Una vez que la estructura de la red esta lista se procede al aprendizaje para detectar patrones en el aprendizaje mientras se modifican los nodos con los valores de pesos asignados y que estimulan a la neurona.

Al aplicar una red neuronal estructurada con 900 datos suministrados y 34 variables de salida con softmax para clasificar se logran buenos resultados en los datos de prueba, pero existe una perdida significativa respecto al conjunto de entrenamiento donde se ve reducida la estimación en un promedio de 8%.

Se ejecutan diferentes modelos de redes neuronales con cambios en parámetros como la función de perdida, el optimizador, las épocas, el lote de entrenamiento y lotes de muestra. Un primer modelo arroja datos interesantes con predicción en entrenamiento de 99.58% y prueba 91.22% utilizando el optimizador de Adam. En la tabla 6 se muestra el resultado de los modelos con cambios en los parámetros y la eficiencia en los mismos.

*Tabla 6. Resultados de redes neuronales*

Optimizador	Función Perdida	Epocas	Batch_size	Steps_per_epoch	Entrenamiento	Prueba	Layers
Adam	MSE	43	100	10	99.58%	91.22%	200
Adam	MSE	43	50	10	99.52%	90.58%	200
Adam	MSE	43	20	20	99.58%	91.22%	200
Adam	MSE	20	20	25	98.19%	90.80%	200
Adam	MSE	20	20	25	98.19%	90.80%	200,150
Adam	CROSSE	10	10	100	99.99%	90.80	200
Adamax	BINARY	100	100	100	99.99%	91.22%	200
Adamax	MSE	43	50	25	99.58%	90.80%	200,150

La tabla 6 muestra como agregar más neuronas no ayuda a la segmentación en datos de prueba porque los valores son muy cercanos que sino no se agregaran (modelo 5 y 8). Los estimadores con mayores ganancias en los modelos son para Adam y Adamax con una función de perdida binaria, de validación y error cuadrático medio utilizando la propagación hacia atrás. Por otro lado, cuando se hacen combinaciones con otras funciones de perdida, optimizadores o propagación hacia adelante los resultados se ven mermados y tienen una precisión promedio de 20%.

En resumen, se presenta una comparativa de los resultados de clasificación obtenidos en los modelos ejecutados con la revisión de literatura expuesta. En la tabla 7 se encuentran las etapas en el sistema de lectura de placas, el numero de datos utilizados y el resultado de la precisión con datos de prueba.

Tabla 7. Comparación de resultados

Autores	Etapas	Número de datos	Algoritmos	Resultados
Azher et al. (2016)	3. Identificar objeto 4. Reconocer caracteres	360 caracteres	KNN	93%
Tabrizi y Cabvus (2016)	5. Procesar placa 6. Segmentar caracteres 7. Extraer características 8. Reconocer caracteres	257 imágenes	KNN-SVM	97%
Azher et al. (2016)	4. Detectar placa 5. Segmentar caracteres 6. Reconocer caracteres	900 caracteres	SVM	93.20%
Ali et al. (2018)	4. Detección de placa 5. Ajuste de características 6. Reconocimiento de caracteres	40,000 caracteres	Nnet	91.88%

Laroca et al. (2018)	<ol style="list-style-type: none"> <li>4. Detección objeto (YOLO)</li> <li>5. Segmentar caracteres</li> <li>6. Clasificar caracteres</li> </ol>	4,500 imágenes	Nnet	93.03%
Gunawan, et al. (2019)	<ol style="list-style-type: none"> <li>4. Mejorar calidad</li> <li>5. Segmentar caracteres</li> <li>6. Clasificar caracteres</li> </ol>	100 imágenes	KNN	92.86%
Park et al. (2019)	<ol style="list-style-type: none"> <li>5. Detectar placa</li> <li>6. Clasificar estructura</li> <li>7. Segmentar caracteres</li> <li>8. Reconocer caracteres</li> </ol>	138 vehículos	KNN	99%
Laroca et al. (2019)	<ol style="list-style-type: none"> <li>3. Detección objeto (YOLO)</li> <li>4. Reconocimiento de caracteres</li> </ol>	772 imágenes	Nnet	96.99%
Akhtar y Ali (2020)	<ol style="list-style-type: none"> <li>5. Mejorar calidad</li> <li>6. Localizar placa</li> <li>7. Segmentar caracteres</li> <li>8. Clasificar caracteres</li> </ol>	200 imágenes	RFC-SVM-KNN-Nnet	90.9%
Ali et al. (2020)	<ol style="list-style-type: none"> <li>4. Segmentar placa</li> <li>5. Segmentar caracteres</li> <li>6. Reconocimiento de caracteres</li> </ol>	84,058 caracteres	Nnet	98%
Fang et al. (2020)	<ol style="list-style-type: none"> <li>4. Detección objeto (YOLO)</li> <li>5. Segmentar caracteres</li> </ol>	5,780 caracteres	Nnet	98%

	6. Reconocimiento de caracteres			
Polanski et al. (2020)	4. Detección de vehículo 5. Detección objeto 6. Reconocimiento de caracteres	2,409 imágenes	Nnet	94%
Muñoz, L (2021)	Reconocimiento de caracteres	1,020	KNN	87.86%
Muñoz, L (2021)	Reconocimiento de caracteres	1,020	SVM	91.94%
Muñoz, L (2021)	Reconocimiento de caracteres	1,020	RFC	89.64%
Muñoz, L (2021)	Reconocimiento de caracteres	1,020	Nnet	91.22%

La comparación de los algoritmos con la revisión de literatura muestra que enfoques como vecinos cercanos y bosques de clasificación tienen menor precisión que otros trabajos, sin embargo, los enfoques de máquinas de soporte vectorial y redes neuronales son competitivos con su precisión en la fase de prueba. Con lo anterior, se puede reconocer que los modelos computacionales de este documento cumplen con la tarea de clasificación de caracteres en placas y las máquinas de soporte vectorial son el algoritmo que tiene un comportamiento sobresaliente sobre los otros 3 algoritmos propuestos con 91.94% de precisión de clasificación.

## 5.2 Tablero de movilidad

La flexibilidad del negocio de la empresa permite al usuario desplazarse de manera rápida y eficiente en la ciudad mientras se generan nodos de movilidad que dan información valiosa sobre posibles rutas de viaje, conmutación diaria o congestiones en ciertas zonas. En este apartado se explora la movilidad de los usuarios y si la lectura de placas es un contribuyente a la generación de información que permita el crecimiento y por ende los efectos en red. En la zona de Angelópolis se tienen estacionamientos y controles de acceso para plazas comerciales, hospitales, pensiones, centros de trabajo y residenciales que han captado cada vez más usuarios diferentes con el paso del tiempo, como se puede visualizar en la imagen 14.




Imagen 14. Usuarios activos

En enero de 2020 se tenían 21,000 usuarios de la zona y para mayo de 2021 aumentó a 35,000; hubo un crecimiento de 66%. Los usuarios acumularon un total de operaciones de 11 millones divididas en 50% para lectura de placas, 40% para control de acceso y 10% para estacionamiento digital. En sentido de ver la distribución de la información para usuarios y operaciones la imagen 15 ejemplifica una gráfica de burbujas con los proyectos y servicio al que pertenecen.


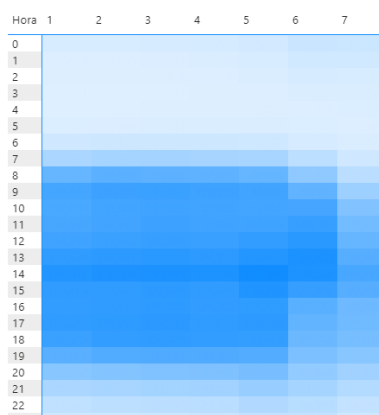


Imagen 15. Operaciones contra usuarios

Se puede notar como hay más operaciones para lectura de placa en accesos como Lomas de Angelópolis y más usuarios para los estacionamientos digitales como Angelópolis que goza de tener más usuarios que otros proyectos. Un dato interesante es que la lectura de placas en algunos controles de acceso tiene más usuarios identificados que su homólogo en lectura de QR. De la manera anterior se puede dar fe de la concurrencia de los usuarios en ciertos proyectos, pero para tener datos específicos, se plantea un mapa de calor en la imagen 16 respecto a los días y las horas disponibles. Lo anterior se entiende como un rastro de movilidad que van dejando los usuarios con las operaciones que realizan en su día a día y como se pueden encontrar patrones de comportamiento en los horarios antes mencionados.



*Imagen 16. Mapa de calor*

La imagen demuestra como hay un color más intenso para un viernes a las 2 de la tarde con más usuarios con uso de la aplicación. Lo que motiva a segmentar por ese día y hora para un estacionamiento que tiene a la mayoría de los usuarios como lo es Angelópolis con una gráfica de origen destino que se visualiza en la imagen 17.




Imagen 17. Origen – destino

Tal como se observa en ese horario las personas visitan el estacionamiento digital y después lo hacen en estacionamientos como Adagio, Vía San Ángel, Sinfonía, Solesta, Paseo Destino, Marsala o van a controles de acceso como Anáhuac, La Vista, Lomas o Las Animas. Otra forma de representar visualmente la movilidad de los usuarios es con ayuda de un mapa para ver las zonas con más operaciones, la imagen 18 ejemplifica como existen nodos de interacción más fuertes en la zona, principalmente en Angelópolis, Vía San Ángel y Lomas.

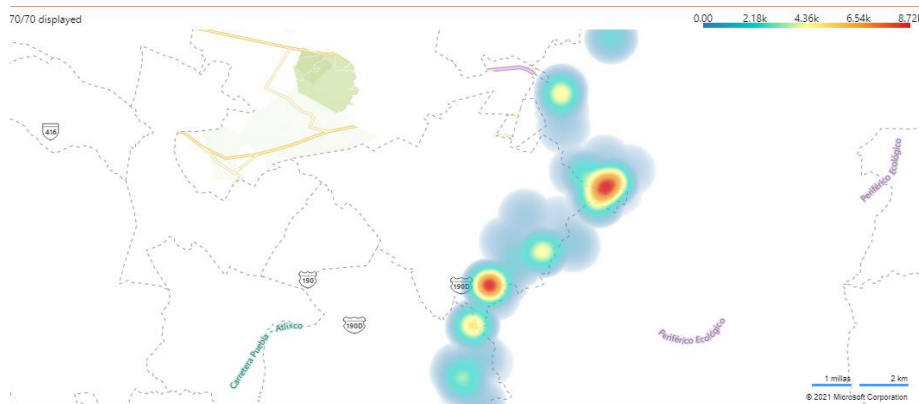


Imagen 18. Mapa de calor sobre zonas

Finalmente se muestra una gráfica para visualizar los nodos de movilidad entre los usuarios de una forma origen – destino. La imagen 19 representa la movilidad de los usuarios en otro horario concurrido como un viernes a las 6 de la tarde, donde las personas a esa visitan lugares como Vía San Ángel para enseguida conectar con otros como Opera, Torres Medicas, Punta o Natura. Se encuentran grandes nodos de movilidad para



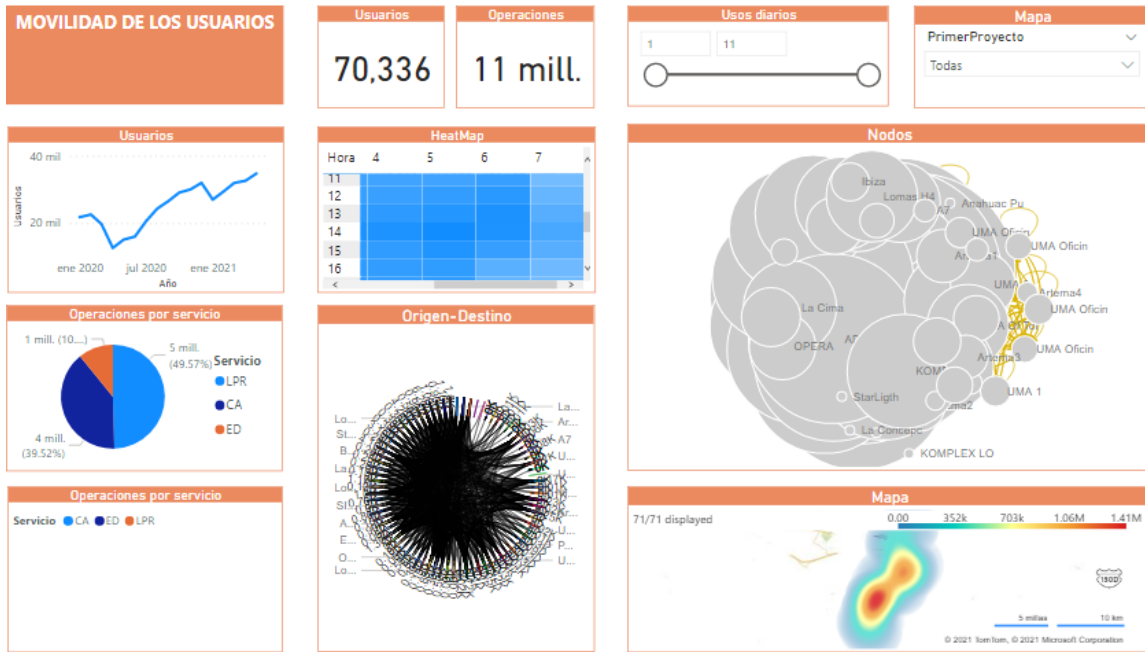


Imagen 20. Tablero de movilidad

### 5.3. Tablero de seguridad

Los datos generados por la lectura de placas ayudan a diseñar estrategias de movilidad y de seguridad pública en el hecho de que se leen placas de los vehículos que pasan por la zona. En esta ocasión en la zona de Angelópolis se generaron casi 23 millones de lecturas de escenas para las placas de los vehículos lo que deja basta información que con datos de REPUVE se indaga sobre el estatus de un vehículo pasando de la marca, modelo, año hasta si tiene reporte de robo.




Imagen 21. Marca de autos

Para iniciar a visualizar los resultados, la imagen 21 tiene al top diez de marcas con más lecturas de placa teniendo a Volkswagen, Nissan, Chevrolet y Toyota entre las destacadas. Las operaciones son menores a las de lectura de placa original porque únicamente se segmentan aquellas que tienen coincidencia con los datos de REPUVE que por razones externas a este trabajo no siempre existe un resultado de consulta.

En el caso de la distribución del modelo del automóvil se propone una gráfica que mida el año del vehículo segmentado por el top 10 de modelo en la imagen 22. Se encuentra que la mayoría de los automóviles son 2018 y modelos como Tiguan, Vento, Versa o Aveo. En otro caso, el año del modelo es en su mayoría superior a 2005. Los vehículos más recientes comprendiendo que son del año 2021 son de autos como CX-5, Sportage y March que son muy diferentes a los que se leen de años anteriores.




Imagen 22. Modelo de autos

Por otro lado, la segmentación por estado de procedencia deja a la entidad de Puebla como el que alberga más autos, seguido de Jalisco, Morelos, Veracruz, entre otros. También, se muestra a los proyectos con más operaciones de lectura de placas teniendo a las entradas de lomas, la vista y las fuentes como las que generan más escenas de placas como se muestra en la imagen 23.




Imagen 23. Proyectos con lecturas

El tablero de seguridad cuenta con filtros para dejar únicamente a vehículos con reporte de robo y si la lectura de placa es posterior a la fecha de reporte de robo. Al igual, se tienen intervalos entre la fecha de actualización de datos del automóvil y la lectura de placas. De manera que podemos identificar automóviles robados que siguen con reporte y han sido leídos en diferentes proyectos para ver las características que tienen y si presentan algún patrón de comportamiento en común.

La imagen 24 representa a las operaciones en el eje horizontal y las placas en el eje vertical que cuentan con reporte de robo después de la actualización de información. Se encuentra que lugares como Lomas Volcanes Norte, Lomas Europa y Lomas Zona Azul tienen más operaciones de placas con robo, pero Bosques de Angelópolis, La Concepción y La Cima tienen más placas con reporte y menos operaciones.




Imagen 24. Operaciones contra placas

Siguiendo la idea de visualizar datos respecto a los proyectos de lectura, se calcula el primer proyecto donde se leyó la placa y el ultimo que tuvo una lectura. La imagen 25 muestra como las placas que tienen reporte de robo que han sido leídas en Bosques de Angelópolis no tienen lectura en otro proyecto, contrario a lo que sucede en Lomas Domino que tiene conexiones con otros proyectos como La Cima, Las Fuentes u otros lugares de Lomas.

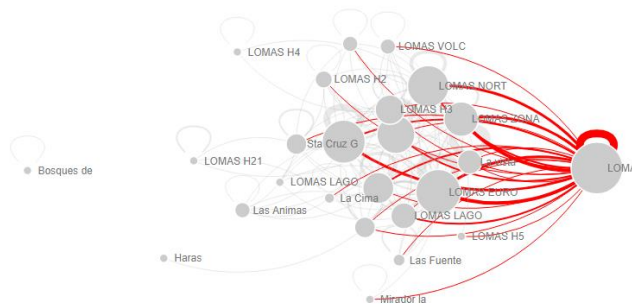


Imagen 25. Nodos de proyectos

Para determinar posibles horas o días de mayor incidencia de lectura se grafica un mapa de calor con los días de la semana comenzando por lunes (1) a domingo (7) durante las 23 horas del día disponibles. En la imagen 26 no se observa un patrón de

comportamiento de lectura marcado, sin embargo, las lecturas de automóviles robados en su mayoría suceden entre 9 de la mañana y 6 de la tarde de lunes a sábado.




Imagen 26. Mapa de calor de lecturas

Mediante una gráfica que muestra en el eje horizontal las operaciones y en el vertical los días diferentes de lectura se plasman las placas que cuentan con reporte de robo. Además, el tamaño de la burbuja indica el número de proyectos diferentes donde se ha leído es placa, por ejemplo, un auto con reporte de robo puede transitar por 30 días diferentes en la zona y ser captado en 5 fraccionamientos diferentes. Para esta última grafica algunas placas cuentan con más de 1,000 lecturas en más de 100 días diferentes que han sido captadas entre 7 y 13 proyectos diferentes. Mientras la mayoría han sido leídas menos de 400 veces en menos de 100 días diferentes. La imagen 27 da muestra del caso anterior.




Imagen 27. Operaciones contra días diferentes

El tablero diseñado para autos con reporte de robo con lectura de placa de la empresa de movilidad permite conocer características desde la marca, modelo hasta la fecha de actualización de los datos para saber el estado de cada placa. En este sentido, el tablero propuesto se compone de filtros para el estatus, tiempo de lectura o el rango de fechas de actualización y operaciones de lectura. Además, hay graficas interesantes en diferentes representaciones como barras, mosaico, mapas, burbujas y nodos que se pueden ver en la imagen 28.

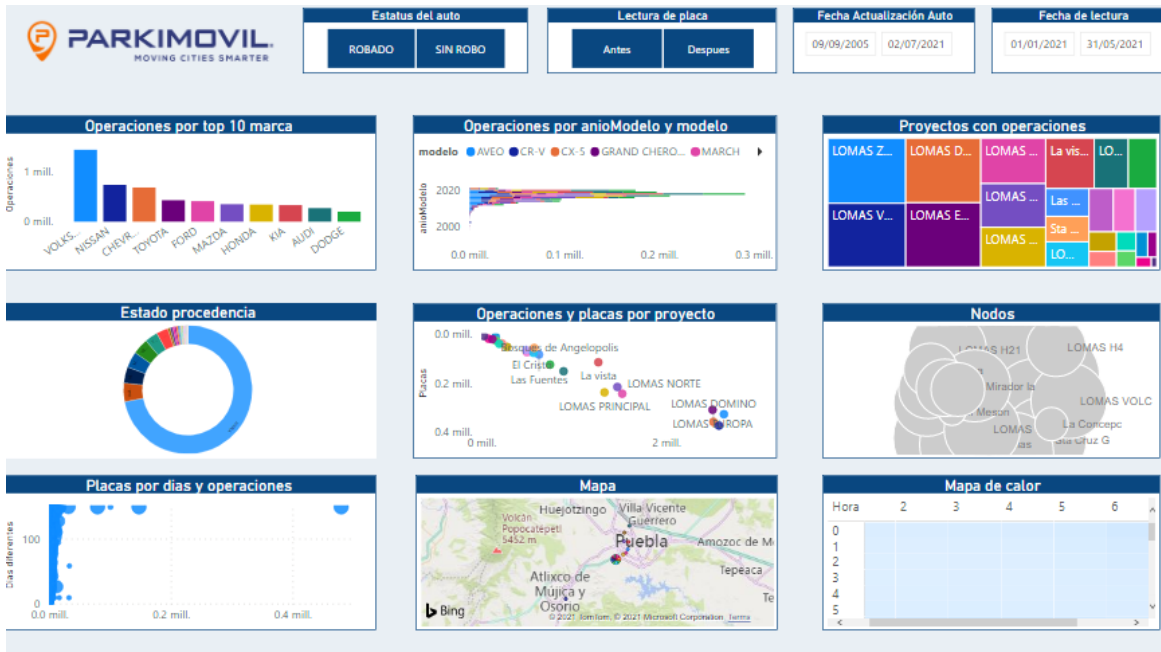


Imagen 28. Tablero de seguridad pública

## Resumen de resultados

Esta investigación tuvo como objetivo implementar algoritmos de aprendizaje automático para la clasificación de caracteres sobre imágenes de automóviles en la zona de Angelópolis, Puebla. Con base en una implementación de algoritmos de clasificación para 34 caracteres identificados en las placas de las fotografías de la empresa Cargo Móvil se puede concluir que la clasificación de caracteres tiene la precisión más alta para máquinas de soporte vectorial con un kernel polinomial y redes neuronales con propagación hacia atrás con una tasa de acierto de 91.93% y 91.22% respectivamente.

Los resultados de clasificación de los algoritmos de aprendizaje supervisado muestran que las máquinas de soporte vectorial son capaces de hacer una clasificación multiclase con una precisión del 91.94% para los caracteres relacionados de una placa. Lo anterior, permite identificar patrones de movilidad con las operaciones de la aplicación que realizan los usuarios. En concreto, para un periodo de 17 meses, se rescatan aproximadamente 7 millones de lecturas de placa pertenecientes a los usuarios en controles de acceso de la zona. Esto permite aumentar el conjunto de datos para obtener características de la movilidad de las personas. Se encuentran horarios de congestión a las 2 de la tarde de lunes a viernes en zonas como Lomas de Angelópolis y La vista, los dos fraccionamientos mas importantes de la ciudad.

Por otro lado, la identificación de los caracteres de la placa permite indagar sobre las características de automóviles con reporte de robo en la zona. De esta manera, se mencionan a los autos con reporte de robo anterior a la lectura de placa que tienen. Es así, como algunos fraccionamientos tienen autos con reporte de robo que no son leídos en otras partes, también se encuentra que la zona de Lomas Zona Azul tiene un tránsito de autos con reporte de robo más alto que circulan a las 9 y 10 de la mañana.

La información obtenida por la clasificación de caracteres es primordial para solventar los problemas de movilidad de la ciudad. Este aporte abarca la movilidad de una de las zonas más importantes del país y contribuye a la seguridad pública de la misma. además, se encuentra que la lectura de placas es un contribuyente al crecimiento de Cargo Móvil; aumentan las operaciones y los usuarios activos de la aplicación que permite tomar decisiones estratégicas sobre el comportamiento de los usuarios y la aplicación.

## CONCLUSIONES

El estudio de la integración de las lecturas de placas con la información de las operaciones de los usuarios para detectar patrones de movilidad y características de autos con reporte de robo en un tablero de inteligencia de negocios obtuvo resultados satisfactorios con las tres áreas de conocimiento como ciencia de datos, modelos computacionales e inteligencia de negocios. Según el objetivo principal, se detectaron patrones de movilidad en la zona entre estacionamientos privados, fraccionamientos y torres de negocios, además, se describieron las características de automóviles con reporte de robo. Con esta información se detecta una contribución de 7 millones de operaciones de placas a los datos de la aplicación y la detección de patrones de usuarios como horarios de congestión, rutas de origen-destino y saturación de zonas.

El cumplimiento del objetivo principal se debe a la contribución de los objetivos secundarios planteados. Para detectar las placas de los automóviles que transitan en la zona se comparan algoritmos de aprendizaje automático para clasificar los caracteres inmersos en las placas. Se ejecutan 4 diferentes enfoques de modelos computacionales como vecinos cercanos, maquinas de soporte vectorial, bosques de clasificación y redes neuronales. Los resultados de la comparación de algoritmos se guían a utilizar las maquinas de soporte vectorial con su clasificación por hiperplanos óptimos de forma lineal al obtener un 91.94% de precisión en el conjunto de datos de prueba. La precisión obtenida de la aplicación de algoritmos brinda la posibilidad de integrar las lecturas de placas con las operaciones de los usuarios en distintos servicios como parquímetros, controles de acceso y estacionamientos privados.

Los resultados del estudio coinciden con los relacionado al marco teórico, en el sentido del soporte teórico y conceptual. Lo anterior, se puede relacionar con el alcance que tienen los sistemas de lectura de placas para solventar tareas laboriosas y propensas a errores humanos con herramientas tecnológicas como modelos computacionales que lo pueden hacer más rápido y con mayor precisión. El enfoque de aprendizaje automático supervisado permite entrenar modelos para clasificar los caracteres de nuevas placas; se facilita el trabajo de captura de placas mientras el tiempo transcurrido se puede emplear en otras actividades.

Es vital reconocer que existen limitantes en la investigación como la obtención y procesamiento de datos. En esta situación, se obtuvo un conjunto de datos de 1,020 caracteres que fueron segmentados de forma manual, porque no se tuvo en cuenta la visión computacional para utilizar algoritmos que hagan esta tarea, además, solo se utilizó el histograma del gradiente para obtener características del conjunto de datos y no se

probaron otros enfoques para el procesamiento de los datos porque estudios recientes como el de Lubna et al. (2021) concuerdan que este es el método más usado y efectivo. En el caso de querer implementar la clasificación de caracteres descrita en el estudio se debe tener en cuenta que no es un sistema robusto que se pueda replicar, porque las escenas tomadas por la empresa de movilidad tienen ciertas características en la cámara como altura, resolución e iluminación que son especiales para su correcto funcionamiento.

Aún con ciertas limitantes encontradas, la importancia del estudio no disminuye el alcance que puede tener. La información que se tiene para una ciudad urbana en crecimiento como Puebla es limitada y restringida por el levantamiento de encuestas y procesamiento de la información que toma varios años. Este estudio confiere la posibilidad de tener información relevante, actual y disponible para la detección de patrones de movilidad. Además, se amplía el conocimiento disponible integrando una plataforma de lectura de placas con una aplicación que gestiona el acceso a lugares públicos y privados mientras se pueden obtener características inherentes a la movilidad como características de los vehículos que transitan por la zona.

Por otro lado, se consideran los resultados inesperados que puede tener la clasificación de caracteres como la aparición de caracteres no considerados en lista propuesta, esto puede ocurrir por la lectura de vehículos con placas de otro país. Otro resultado inesperado es la asignación de vehículos para los usuarios de la aplicación, esto sucede porque un usuario puede tener más de un auto para moverse, pero en la lectura de placa se asigna el último registro en la aplicación. Por último, se pueden identificar placas de un automóvil ajeno a la zona de estudio, esto porque no se tiene una precisión del 100% y puede ocurrir una coincidencia de lectura con una placa que no tiene operaciones en la zona elegida.

Los modelos computacionales propuestos fueron aplicados para clasificar caracteres de imágenes tomadas por la empresa de movilidad. La implementación de los modelos computacionales impactó en el orden de obtener lecturas de placa de los vehículos que transitan en la zona con cámaras para el acceso a determinados lugares. El conjunto de datos resultante de la lectura de placas se puede integrar con otras fuentes de datos utilizando técnicas de ciencia de datos. De tal forma, que la ciencia de datos impacta en la transformación e integración de fuentes de datos estructuradas y no estructuradas para su análisis. Y es en este último punto es donde la inteligencia de negocios toma lugar para visualizar las relaciones entre los diferentes datos e impactar en la toma de decisiones para la movilidad y seguridad pública.

Para futuras investigaciones se recomienda utilizar otro conjunto de datos como la toma de escenas en vía pública para el control de velocidad en la ciudad. En el caso de

Puebla, las cámaras para el control de velocidad se encuentran localizadas en diferentes avenidas y pueden expandir el conocimiento sobre los patrones de movilidad. También, se recomienda un sistema de control de velocidad diferente al actual que pueda calcular la velocidad promedio de automóvil con lecturas en entrada y salida en avenidas que lo permitan como lo es periférico.

## REFERENCIAS

- Akhtar Z. y Ali, R. (2020). Automatic Number Plate Recognition Using Random Forest Classifiers. *SN COMPUT. SCI*, 1(120). <https://bit.ly/3kzqwB3>
- Ali, M., Arshad, H., Siddiqui, T. Ahmed, R. y Shabbir, J. (2018). Deep Learning Based Smart License Number Plate Recognition System for Moving Cars. *NED University Journal of Research-Thematic Issue on Advances in Image and Video Processing*, 8(E16), 1-7. <http://bit.ly/2OXtiCP>
- Ali, M., Qi. C., Rizwan, M. y Armoghan, M. (2020). An Adaptive Approach for Multi-National Vehicle License Plate Recognition Using Multi-Level Deep Features and Foreground Polarity Detection Model. *Applied Sciences*, 10(2165), 1-21. <https://bit.ly/3seVPT4>
- AL-Nabi, D. y Ahmed, S. (2013). Survey on Classification Algorithms for Data Mining: (Comparison and Evaluation). *Computer Engineering and Intelligent Systems*, 4(8), 18-25.
- Archana, S, y Elangovan, K. (2014). Survey of classification Techniques in Data Mining. *International Journal of Computer Science and Mobile Applications*, 2(2), 65-71. <https://bit.ly/3GKjthV>
- Azher. M., Bibi. J. y Ameen. S. (2016). Bangladeshi Vehicle Digital License Plate Recognition for Metropolitan Cities Using Support Vector Machine. <https://bit.ly/3wn76Sz>
- Azher. M., Bibi. J. y Ameen. S. (2016). Indonesian license plate recognition based on area feature extraction. *TELKOMNIKA*, 17(2), 620-627. <https://bit.ly/3AAlk5L>
- Bhatia, N. y Vandana. (2010). Survey of Nearest Neighbor Techniques. *International Journal of Computer Science and Information Security*, 8(2), 302-305.
- Bradea, I., Sabau-Popa, A. y Bolos, M. (2014). Using dashboards in business analysis. *Annals of the University of Oradea*, <https://bit.ly/3nYHVU9>
- Burbidge, R. y Buxton, B. (2001). An Introduction to Support Vector Machines for Data Mining. *Computer Science Dept.* <https://bit.ly/3GEmwYO>
- Chen, H., Yang, C. y Xu, X. (2017). Clustering Vehicle Temporal and Spatial Travel Behavior Using License Plate Recognition Data. *Journal of Advanced Transportation*, 2017. <http://bit.ly/3vHYre6>
- Dominguez, L., Perez, A., Rubiales, A. y Barbuzza, R. (2018). Running License Plate Recognition (LPR) algorithms on smart surveillance cameras. A feasibility analysis. *Iberian Conference on Information Systems and Technologies*, 1-5. <http://bit.ly/3sbuf9b>

- Fang, W., Yi, W., Pang, L. y Hou, S. (2020). A Method of License Plate Location and Character Recognition based on CNN. *Transactions On Internet and Information Systems*, 14(8), 3488-3500. <http://bit.ly/314BP9s>
- Fideicomiso para el Mejoramiento de las Vías de Comunicación del Distrito Federal. (2012). *Diagnóstico de la Movilidad de las Personas en la Ciudad de México*. Recuperado el 25 de enero 2021. <https://bit.ly/3c6RX0H>.
- Gershenson, C. (2003). Artificial Neural Networks for Begginers. *ArXiv*. <https://bit.ly/3GNYAIG>
- Gobierno municipal de Puebla. (2017). Programa de movilidad urbana sustentable. Recuperado el 20 de marzo 2021, de <https://bit.ly/2ZZHbWD>
- Guerriere, M. y Detsky, A. (1991). Neural networks: what are they?. *Annals of Internal Medicine*, 115(11). <https://bit.ly/2ZKPSnT>
- Gunawan, D., Rohimah, R. y Rahmat F. (2019). Automatic Number Plate Recognition for Indonesion License Plate by Using K-Nearest Neighbor. *Conf. Series: Materials Science and Engineering*, 648. <https://bit.ly/3kvAJyl>
- Gupta, S., Singh, R. y Mandoria, H. (2020). A Review Paper on License Plate Recognition System. *International Journal of Innovative Research in Computer and Communication Engineering*, 5(1.4)
- Hadke, V. y Ajmera, P. (2014). Comparative study of License Plate Recognition. *International Journal of Engineering Research & Technology(IJERT)*, 3(3), 2079-2083.
- Instituto Nacional de Estadística y Geografía (2019). *Seguridad Pública y Justicia*. Recuperado el 25 de enero 2021, de <http://bit.ly/31cCiq9>
- Jakkula, V. (2011). Tutorial on Support Vector Machine (SVM). <https://bit.ly/2ZldWrz>
- Jimenez, L. (2013). Automatic Number Plate Recognition.
- Krogh, A. (2008). What are artificial neural networks?. *Nature Biotechnology*, 26(2)
- Laroca, R., Severo, E., Zanlorensi, L., Oliveira, L., Resende, G., Robson, W. y Menotti, D. (2018). A Robust Real-Time Automatic License Plate Recognition Based on the YOLO Detector. *International Joint Conference on Neural Networks (IJCNN)*, 1-10. <http://bit.ly/3ti9hz1>
- Laroca, R., Zanlorensi, A., Gonç alves, G., Todt, E., Robson, W. y Menotti, D. (2019). An Efficient and Layout-Independent Automatic License Plate Recognition System Based on the YOLO detector. *IET Intell. Transp. Syst*, 15, 483-503. <http://bit.ly/2PhnLXP>
- López, V. (2019). Puebla, en proceso de colapso urbano por el crecimiento poblacional. Milenio. Recuperado el 25 de enero 2021, <http://bit.ly/3snYTE5>

- Lubna, & Mufti, Naveed y Shah, Syed. (2021). Automatic Number Plate Recognition: A Detailed Survey of Relevant Algorithms. *Sensors*, 21(3028) <https://bit.ly/3EE88Pj>
- Marzuki P., Syafeeza, A., Wong, C., Alisa, A., y Ibrahim, M. (2019). A Design of License Plate Recognition System Using Convolutional Neural Network. *International Journal of Electrical and Computer Engineering*, 9(5). <http://bit.ly/2Phln32>
- Medina, R. y Ñique, C. (2017). Bosques aleatorios como extensión de los bosques de clasificación con los programas R y Python. *Interfases*,
- Morales, G., Mora, J y Vargas H. (2008). Estrategia de regresión basada en el método de los K vecinos más cercanos para la estimación de la distancia de falla en sistemas radiales. *Rev.Fac. Ing.Univ. Antioquia*, 45, 100-108. <https://bit.ly/3ocziVN>
- Nu, T. (2009). Survey of Classification Techniques in Data Mining. *Proceedings of the International MultiConference of Engineers and Computer Scientist*, 1.
- O'Shea, K. y Nash R. (2015). An Introduction to Convolutional Neural Networks. *ArXiv*. <https://bit.ly/3mDsocV>
- Pandey, A. y Jain, A. (2017). Comparative Analysis of KNN Algorithm Using Various Normalization Techniques, *I. J. Computer Network, and Information Security*, 11, 36-42.
- Park, S., Yoon, H. y Park, S. (2019). Multi-Style License Plate Recognition System Using K-Nearest Neighbors. *Transactions on Internet and Information Systems*,13(5), 2509-2528. <http://bit.ly/2QuJkVp>
- Parvin, S., Jude. L. y Ezahuril, M. (2021). Vehicle Number Plate Detection and Recognition Techniques: A Review. *Advances in Science, Technology and Engineering Systems Journal*, 6, 423-348. <https://bit.ly/3hTPSaT>
- Penmatsa, R., Ganta, K., Krishna, H y Svsrk, P. (2020). A Novel Method for Indian Vehicle Registration Number Plate Detection and Recognition using Image Processing Techniqes. *International Conference on Computational Intelligence and Data Science*, 167(2020), 2623-2633.
- Poltavskii, T., Yurushkina, G. y Yurushkin. M. (2020). Automatic License-Plate Recognition. *Vestnik of Don State Technical University*, 20(1), 93-99. <https://bit.ly/3cSEdpC>
- Secretaria de Desarrollo Agrario, Territorial y Urbano. (2018). *Anatomía de la movilidad en México. Hacia Dónde vamos*. Tinta Roja Editoras. <http://bit.ly/3vZgKMa>
- Shan, D., Mahmiund, I., Mohemaed, S. y Wael B. (2013). Automatic License Plate Recognition (ALPR): A State-of-the-Art Review. *IEE Transaction on Circuits and Systems for Video Technology*, 23(2), 311-325.
- Shashirangana, H., Padmasiri, D., Meedeniya y C. Perera. (2020). Automated License Plate Recognition: A Survey on Methods and Techniques. *IEEE Access*, vol. 9, 11203-11225.

- Somvanshi, M., Chavan, P., Tambade, S. y Shinde, S. (2016). A Review of Machine Learning Techniques using Decision Tree and Support Vector Machine. *International Conference on Computing Communication Control and Automation*, 1-7. <https://bit.ly/31hsvT7>
- Tabrizi, S. y Cavus, N. (2016). A Hybrid KNN-SVM Model for Iranian License Plate Recognition. *Procedia Computer Sciencia*, 102, 588-594. <https://bit.ly/3AxoBIP>
- Tan, C. y Steinbach. (2004). Data Mining Classification: Basic Concepts, Decision Trees, and Model Evaluation. <https://bit.ly/3DU0n6D>
- Türkyılmaz, I. & Kaçan, K. (2016). A New License Plate Recognition System Using Artificial Neural Networks. *ETRI Journal*, 39, 163-172. <https://bit.ly/394YNSr>
- Zhang, Z. (2016). Introduction to machine learning: k-nearest neighbors. *Annals of Transnational Medicine*, 4(11). <https://bit.ly/3GvKRjk>