

Universidad de
Oviedo

-

Master en Ingeniería
Web

Trabajo Fin de
Master

ARTICULO CIENTIFICO SOBRE LA AUTOMATIZACIÓN DE DRONES PARA LA DETECCIÓN Y EXTRACCIÓN DE MATRICULAS DE VEHÍCULOS

Ángel
Francisco del
Río Álvarez

Dirigido por:

Martín González Rodríguez

Daniel Fernández Lanvín

Javier De Andrés López

RESUMEN

La creciente necesidad de realizar seguimientos a vehículos en múltiples situaciones por razones de seguridad ha permitido la proliferación de, cada vez más sofisticados, sistemas automáticos de reconocimiento de matrículas. Estos sistemas son capaces de reconocer matrículas usando cámaras fijas en puntos estratégicos en instalaciones a controlar (carreteras, zonas de aparcamiento, etc...) o en movimiento pero requiriendo intervención humana para manejarlos (por ejemplo coches de policía).

El artículo resultado de nuestra investigación propone un sistema completamente autónomo capaz de buscar matrículas en un área indicada usando vehículos aéreos no tripulados o drones. El sistema propuesto combina un algoritmo basado en *boosting* para detectar las matrículas durante el vuelo del drone con un algoritmo de procesamiento de imagen que hace uso de momentos invariantes para extraer la numeración de la imagen de la matrícula. El prototipo ha sido desarrollado en un *smartphone* Android conectado que manipula vía WiFi un modelo básico de drone, el Parrot AR Drone que es capaz de enviar al dispositivo 30fps. Los test nos muestran un 97% de acierto con el algoritmo en modo rápido. Este modo necesita un tiempo de reconocimiento medio de 12.6 s por vehículo incluyendo el tiempo que el drone necesita para moverse a una posición cercana a la matrícula de cada coche. Se puede mejorar los resultados hasta el 99% si el algoritmo usa su modo lento. Este modo necesita para cada reconocimiento un tiempo medio de 24.6 s por vehículo.

Palabras clave: Drone, Reconocimiento de matrículas, Reconocimiento óptico de patrones, *boosting*, momentos invariantes, AdaBoost, OCR

ABSTRACT

The growing need to track vehicles in multiple scenarios for security purposes has led to a proliferation of increasingly sophisticated automatic license plates recognition systems. These systems are capable to recognize license plate numbers using cameras fixed to strategic spots in the facilities under control (roads, parking areas, etc.) or using mobile platforms that require human intervention to operate (like police cars).

The paper resulting from our research proposes a fully autonomous system capable to search for license plates in a predefined area using UAVs (Unmanned Aerial Vehicles). The proposed system combines a boosted-based algorithm to detect license plates along the UAV flight path, with an image-processing algorithm based on invariants moments to extract the vehicle identification number from its plate. A prototype was developed on an Android smartphone connected via WiFi with a basic commercial Parrot AR drone delivering 30 fps. Different tests showed a success rate of 97% when the algorithm is set to fast mode. This mode needed an average recognition time of 12.6 seconds per vehicle including the time required to automatically move the UAV to a position close to the car's plate location. This accuracy was e increased to 99% setting the algorithm to its slow mode. This mode required an average recognition time of 24.6 seconds per vehicle.

Keywords: Drone, UAV, License plate, APRN, Optical pattern recognition, boosting, invariant moments, AdaBoost, OCR

TABLA DE CONTENIDO

Resumen	1
Abstract	2
1. Introducción	4
1.1. Motivación	4
1.2. Finalidad del proyecto	5
2. Fijación de objetivos.....	6
2.1. Posibles ámbitos de aplicación	7
3. Estado actual de los conocimientos científico-técnicos	9
3.1. Automatización óptica de drones.....	10
3.2. Extracción de los caracteres de la matrícula	12
4. Descripción del sistema.....	14
4.1. Módulo de búsqueda de matrículas.....	14
4.2. Módulo de extracción de caracteres	17
5. Metodología de trabajo	21
6. Resultados obtenidos.....	23
6.1. Interpretación de resultados	23
6.2. Discusión	24
7. Conclusiones y trabajo futuro	25
7.1. Trabajo futuro	25
7.2. Difusión de los resultados.....	25
8. Presupuesto.....	27
9. Bibliografía	28
10. Anexos	31
10.1. Anexo 1: Algoritmo de Gentle AdaBoost.....	31
10.2. Anexo 2: Momentos Invariantes de Hu	32

1. INTRODUCCIÓN

El enorme crecimiento del número de vehículos a nivel mundial en la segunda mitad del siglo pasado, dispara el número de desplazamientos en carretera, entre ciudades, entrando y saliendo de aparcamientos, sin que sea posible realizar un seguimiento exhaustivo de los mismos.

Múltiples razones han llevado a la necesidad de recoger y procesar esta información. Desde poner multas de aparcamiento, sistemas de cobro automático de peajes, a razones de seguridad como el seguimiento de delincuentes o la previsión de atentados. Incluso muchos países ya obligan a instalar sistemas de reconocimiento de matrículas o APRN (*Automatic number plate recognition*) en aparcamientos públicos de gestión privada, estando obligados dichos gestores a poner esa información al servicio de los cuerpos de seguridad del estado.

1.1. MOTIVACIÓN

Las limitaciones técnicas actuales impiden que estos sistemas estén automatizados en movimiento, siendo principalmente sistemas estacionarios situados en determinados puntos (autopistas, parkings, etc.). Los APRN actuales en movimiento no son completamente automatizados, o bien son conducidos por una persona, o bien ni siquiera se pueden considerar como tales, pues se limitan a sacar imágenes en alta definición en los que tras procesarla, serán personas las que determinen la matrícula.

Mientras haya algún tipo de intervención humana, ningún sistema se podría generalizar su uso de forma masiva en prevención de un atentado o en busca de un delincuente en un momento dado.

En el mes de Enero del 2015 fuimos testigos de estas limitaciones con los atentados sucedidos en Francia, en los que desde el primer momento gracias a una grabación casera se conocía la matrícula de los autores, y su seguimiento y localización no solo duró dos días, sino que puso en peligro la vida de muchos policías. Peligro que se habría evitado, si existiera una forma completamente autónoma de escanear matrículas en cualquier punto del mundo.

1.2. FINALIDAD DEL PROYECTO

La finalidad de la investigación realizada, es hacer un estudio de las tecnologías actuales en varios campos relacionados con la visión artificial, para dar con los algoritmos que nos permitan superar esas limitaciones técnicas, y aprovechando la reciente popularización de los drones, conseguir un sistema de reconocimiento óptico de matrículas aéreo no tripulado, que sea capaz de barrer áreas enteras reconociendo matrículas de forma eficiente y sin intervención humana.

La idea principal es que el drone sea capaz de seguir una ruta de forma automática (predefinida por el usuario) ejecutando un algoritmo que detecte vehículos (o directamente placas de matrícula) y que cuando detecte uno, sea capaz de modificar su comportamiento, deteniéndose y/o acercándose al objetivo, enfocándola y extrayendo sus caracteres, para, tras dicha identificación, seguir con su ruta predefinida en busca de más matrículas.

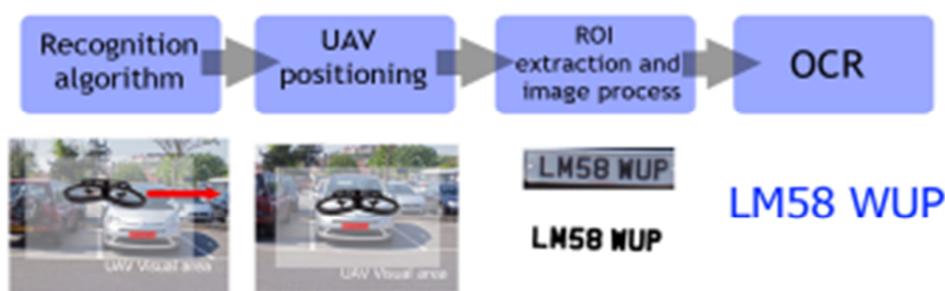


FIGURA 1: FASES DEL PROCESO DE RECONOCIMIENTO DE MATRICULAS

En la Figura 1, podemos ver las fases principales del funcionamiento del sistema a desarrollar independientemente de las tecnologías a usar. Como vemos el objetivo es crear un sistema que, tras definirle una ruta a seguir:

1. El dron vuela a la altura adecuada ejecutando un algoritmo de búsqueda de matrículas
2. Al detectar una matrícula, se frene e incluso modifique su situación, situándose en una posición óptima y estable para su mejor extracción de caracteres
3. Se procesarán esas imágenes para quitar imperfecciones derivadas de la inestabilidad del dron, así como para resaltar los caracteres facilitando el trabajo al algoritmo de extracción de caracteres
4. Se reconocerán los caracteres de la imagen, dando como resultado final una cadena de texto

2. FIJACIÓN DE OBJETIVOS

1. **El sistema será aéreo, no tripulado, y completamente autónomo.** Este objetivo marca la diferencia con otros sistemas actuales, por lo cual es un objetivo principal e irrenunciable del proyecto.
 - 1.1 **Realizar un estudio sobre la automatización óptica de drones.** Debemos conocer la literatura actual sobre como los drones pueden reaccionar a estímulos visuales, para elegir la mejor manera de que lo haga en nuestro caso, ante la detección de una matrícula.
 - 1.2 **Recibir los estímulos visuales en una unidad con capacidad de procesamiento en tiempo real.** Los drones, para reducir su peso, carecen de unidades de procesamiento, sino que son meros conjuntos de sensores que envían datos y mecanismo de vuelo que recibe órdenes. Para conseguir la total autonomía de vuelo modificando las trayectorias del dron en función a los estímulos visuales es indispensable tratarlos en una unidad de procesamiento y traducirlos en órdenes de vuelo en tiempo real.
2. **El sistema deberá detectar matrículas en el menor tiempo posible.** Otro objetivo principal del proyecto, del que depende su éxito y funcionalidad, es su rendimiento.
 - 2.1 **Realizar un estudio sobre el reconocimiento óptico de patrones.** Se deberá conocer todas las técnicas de reconocimiento de patrones, para poder decidir de forma general la estructura del sistema de búsqueda.
 - 2.2 **Crear y optimizar un algoritmo que detecte matrículas en una imagen en el menor tiempo posible.** Teniendo en cuenta que se realiza un análisis de video en tiempo real, deberemos conseguir descartar las imágenes sin matrículas en el menor tiempo posible para evitar cuellos de botella.
 - 2.3 **Intentar adaptarse a cualquier tipo de hardware, traduciendo en resultados sus posibles mejoras.** Siempre se podrá ejecutar el software en mejores unidades de procesamiento, habrá drones más rápidos, más estables y con mejores cámaras. Pero es indispensable optimizar los algoritmos para aprovechar al máximo cualquier tipo de hardware, haciendo que las mejoras técnicas se traduzcan directamente en mejores resultados.
3. **El sistema deberá ser fiable.** El último objetivo principal del sistema, es que sea fiable, pues al igual que la velocidad, este objetivo está directamente asociado al éxito de la investigación.

3.1 Minimizar el número de matrículas sin reconocer. El algoritmo de búsqueda de matrículas debe escanear toda el área de visión de la cámara sin comprometer el objetivo 2.

3.2 Minimizar el número de matrículas erróneas. Tanto falsos positivos como lecturas de caracteres incorrectas. Debe constar de técnicas que permitan verificar que una matrícula es correcta evitando usar tiempos de reconocimiento (que evitarían la consecución del objetivo 2.2).

2.1. POSIBLES ÁMBITOS DE APLICACIÓN

Como explicamos en la introducción, cada vez es más importante registrar este tipo de información en más lugares. Las razones son muchas, desde detección de coches robados, seguimiento de delincuentes o multas de tráfico, a la cada vez más importante demanda de control en prevención de atentados terroristas. Un sistema como el resultante de esta investigación podría aplicarse en las situaciones enumeradas a continuación.

- **Zonas de aparcamiento sin control de acceso.** Desde hace varios años en diversos estados de la UE (incluido el español) es obligatorio registrar entradas y salidas en aparcamientos. Un APRN estático a la entrada del parking recoge nuestra matrícula en el momento de recoger el ticket en la barrera de acceso, quedando este vinculado a nuestra matrícula y registrándose por lo tanto la hora de nuestra salida en el momento de usarlo para salir. La información quedará a disposición de los cuerpos de seguridad del estado cuando así la requieran. Es presumible, que el mismo interés que hay en aparcamientos de pago con barrera, lo hay para los que no tienen control de acceso, y son las dificultades técnicas y económicas (No se podrían poner APRN en todas las calles) las que lo impiden. Nuestro sistema podría funcionar ininterrumpidamente en aparcamientos de centros comerciales, estaciones, aeropuertos, etc... no solo registrando entradas y salidas, sino registrando de cada pasada la plaza ocupada por cada vehículo a una hora determinada.
- **Zonas de interés puntual.** Las calles alrededor de un lugar donde se va a desarrollar un congreso importante, un acontecimiento deportivo, o un concierto, puede que no tengan el suficiente interés para la colocación de APRN fijos, pero la movilidad de nuestro sistema permitiría solucionarlo. Se configuraría mediante coordenadas GPS la ruta a seguir y se podría poner a registrar matrículas por primera vez en un zona los días u horas previas al acontecimiento de interés.

- **Seguimiento de delincuentes sin riesgos humanos.** Los minutos siguientes al momento de un atentado, atraco a un banco, u otros hechos delictivos de magnitud en los que se pueda suceder una huida del delincuente, son cruciales para evitar que esta se produzca. Un ejemplo reciente está en los atentados de París que comentábamos en la introducción, donde la instalación de APRNs en varias autopistas puso en riesgo a mucha gente, cosa que se habría evitado con nuestro sistema si en los momentos siguientes al atentado distintas comisarías de la ciudad pusieran en funcionamiento varios drones que podrían haber evitado incluso, la salida de la ciudad de los autores del atentado.
- **Uso con mejores resultados en las mismas situaciones donde se usan los actuales APRN móviles.** Los actuales APRN móviles, principalmente en coches o helicópteros, además de la intervención humana necesaria para la conducción o pilotaje del vehículo y lo evidentemente más caros que resultan, también tienen problemas de fiabilidad debido a su tamaño.

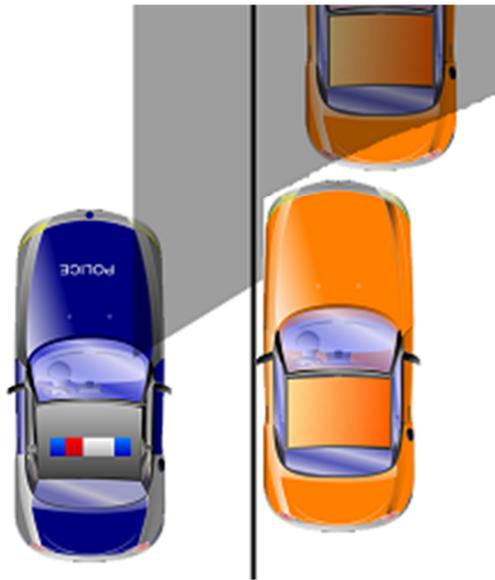


FIGURA 2: SITUACIÓN PROBLEMÁTICA DERIVADA DEL LIMITADO ANGULO DE VISIÓN
DE UN APRN A BORDO DE UN COCHE

En la Figura 2 vemos como un coche de policía se ve incapaz de acceder a una matrícula por falta de ángulo. En situaciones como esta, un coche no tiene movilidad para buscar otro punto de vista e intentarlo desde otro ángulo. Un drone de pequeño tamaño y con total movilidad puede tener algoritmos que ante la aparición de un coche, sea capaz de buscar un punto de vista adecuado para reconocer la matrícula.

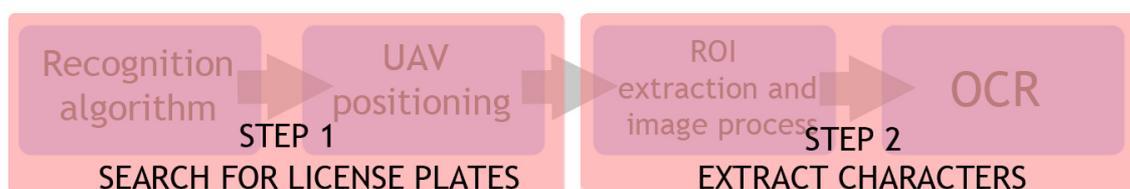
3. ESTADO ACTUAL DE LOS CONOCIMIENTOS CIENTÍFICO-TÉCNICOS

La primera parte de la investigación se basó en hacer un exhaustivo análisis tanto de las tecnologías implicadas en los actuales APRN, como de las de automatización óptica de drones para intentar establecer una base tecnológica sobre la que desarrollar dichas tecnologías con el objetivo de desarrollarlas y adaptarlas para un correcto funcionamiento de forma conjunta.

Como decíamos, muchos APRN actuales son estacionarios. La mayoría de estos, se desentienden de la labor de localizar la matrícula en las imágenes, puesto que se conoce la zona por donde debe aparecer, y simplemente se intenta delimitar la placa y separar los caracteres mediante funciones matemáticas que detecten características visuales de bajo nivel como el color, las esquinas, o los bordes [1],[2],[3] o de medio nivel como la forma, textura o simetría [4]. Muchos de estas técnicas consiguieron grandes resultados como el análisis de texturas mediante filtro de Gabor [5], transformada de Walvelet [6] , y transformada de Hough [7]. Este tipo de técnicas que recurren a las características de imagen a bajo-medio nivel requieren un alto nivel de computación, pues suelen trabajar a nivel de pixel y por eso obtienen grandes resultados solo en imágenes donde se puede presuponer la posición de la matrícula, utilizarlas para recorrer una gran imagen sin saber en qué zona, ángulo o tamaño puede aparecer la matrícula, tendría un coste muy alto. Esto las hace perfectas para APRNs situados, por ejemplo, en barreras de aparcamientos.

Creando un APRN a bordo de un drone, ninguna de estas técnicas nos sirve en primera instancia, pues se deben de analizar todos los *frames* recibidos desde el drone, teniendo en cuenta que no solo es desconocida la situación y tamaño de la matrícula, sino, que la mayoría de *frames* analizados no contendrán ninguna matrícula. Por esta razón se decide, en una primera fase, observar las técnicas utilizadas para la automatización óptica de drones, ver como se analizan los *frames* en otros proyectos en busca de estímulos en tiempo real para intentar adaptarlo a la búsqueda de matrículas.

Como ya sabemos que no hay ningún sistema similar, se decide el estudio del estado del arte en dos partes, por un lado estudiar todo lo relativo a la automatización óptica de drones, y por otro las técnicas de extracción de la matrícula de la imagen.



En la primera parte, estudiaremos los sistemas de automatización de vuelo existentes poniendo especial interés en las técnicas utilizadas para reconocer los patrones en tiempo real, en la segunda las técnicas utilizadas para extraer los caracteres de una imagen y el pre procesamiento necesario.

3.1. AUTOMATIZACIÓN ÓPTICA DE DRONES

Principalmente, en la búsqueda de patrones en tiempo real, se utilizan técnicas basadas en inteligencia artificial, tales como redes neuronales o arboles de decisión. Lo bueno de la inteligencia artificial es que permite evaluar la situación en cada iteración del algoritmo, tomando una decisión en base a distintos parámetros, lo que permite descartar una imagen sin necesidad de examinar todos los *pixels* a bajo nivel.

Son muy usadas en reconocimiento de patrones, las técnicas basadas en *boosting*, por ejemplo es muy usado el algoritmo propuesto por Viola y Jones [8] para la rápida detección de objetos usando cascadas de características simples mediante *boosting*. En concreto Viola y Jones utilizan la técnica AdaBoost [9], el cual genera clasificadores más robustos a partir de la conjunción de muchos clasificadores débiles (los cuales son muy rápidos ya que son poco más que aleatorios). Estos clasificadores generan una respuesta binaria y al ir combinándose entre sí, la tasa de error (En torno al 50% en los débiles) va bajando. Viola y Jones, aparte de elegir este algoritmo, diseñaron sus tipos de características, que son áreas con formas rectangulares donde se mide la intensidad de los pixeles que la componen

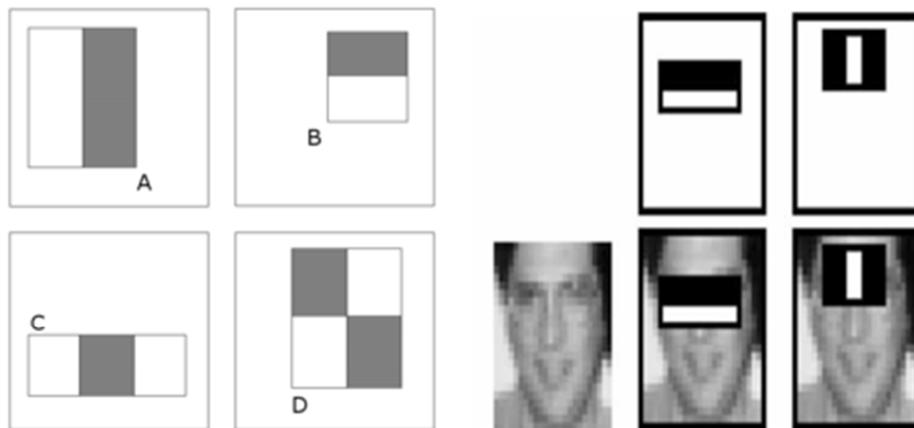


FIGURA 3: TIPOS DE CARACTERÍSTICAS DE VIOLA Y JONES

La velocidad de descarte de imágenes que no contienen el patrón hizo a esta técnica óptima para aplicaciones en tiempo real. Por ejemplo para la detección de caras [10] consiguiendo muy buenos resultados, para la detección de peatones [11] o incluso para reconocer cráteres en Marte [12].

Técnicas de reconocimiento óptico en tiempo real, como *AdaBoost* pueden ser utilizadas en automatización de drones. El funcionamiento es simple; casi todos los drones comerciales están provistos de cámara y de una tecnología (normalmente WiFi) para enviar los *frames* detectados por la cámara a un dispositivo donde un piloto humano pueda interpretarlos y manejar el aparato. Capturando y procesando esos *frames*, y combinándolos con los datos de otros sensores y dispositivos del dron como el GPS (Sistema de posicionamiento geográfico), altímetro o sensor de infrarrojos, es posible, por ejemplo pilotar el dron sin colisionar entre edificios en un entorno urbano [13] o sortear obstáculos entre dos puntos [14]. Para solucionar problemas más específicos que evitar cualquier obstáculo, a esos *frames* recibidos se les puede aplicar alguna técnica de detección de patrones como las explicadas previamente. Usando estas técnicas y analizando correctamente la información recibida podemos conseguir que el dron sepa “elegir” entre varios objetivos cual es el correcto. De esta forma un dron puede realizar automáticamente cosas como aterrizar en un punto concreto, recoger un paquete determinado, o contar el número de personas que se encuentran en un área.

La naturaleza de nuestro objetivo, nos hace pensar en el uso de técnicas de inteligencia artificial para buscar la matrícula, el problema es que estas técnicas no dieron demasiado buenos resultados en los intentos previos de llevarlas al mundo de los APRN. Dlagnekov trató de aplicar *AdaBoost* al reconocimiento de matrículas consiguiendo 95.6% pero con una tasa de falsos positivos del 5.7% [15] y Zhang et al. en 2010 consiguieron un 92.6% [16]. Estos datos demuestran que estas técnicas son muy buenas para la detección rápida de objetos, pero no tan buenas detectando los símbolos a bajo nivel. Esto nos hace ir pensando en que quizás sea recomendable, dividir el reconocimiento de matrículas en dos módulos, uno que busque el patrón genérico de una matrícula mediante técnicas de inteligencia artificial, y otro, que una vez detectada extraiga sus caracteres.

Masselli et al. [17] publicaron una comparación entre distintas técnicas basadas en señales visuales para el vuelo autónomo de drones comparando una técnica basada en las imágenes de la cámara tratadas mediante inteligencia artificial con otras dos: Patrones IR-LED y segmentación de color. La primera usa un patrón de leds infrarrojos, los cuales son seguidos mediante una cámara infrarroja obtenida de un mando de Nintendo Wii. Este tipo de técnica se usa en [18], y es el método más rápido aunque nosotros debemos descartarlo porque no sirve ante la luz del sol, por lo que no se puede utilizar en exteriores. La segunda técnica usa segmentación de color, para ello

solo necesita la propia cámara VGA del drone usado en las pruebas. Se basa en diferencias muy grandes de color en vez de buscar un patrón o forma concreto, en las pruebas utilizaron pelotas de tenis pintadas de naranja. Esta técnica resulto ser la segunda más rápida y dar bastante buenos resultados, pero nosotros tenemos que descartarla debido a que nosotros no podemos usar colores en nuestro patrón, ya que este no es elegido por nosotros. La última técnica que prueban es una red neuronal optimizada y entrenada para detectar un patrón, en concreto el símbolo de helipuerto, una H rodeada de un círculo. Obtiene buenos resultados, aunque es la que ultima en rendimiento. Usando esta técnica, Saripalli et al. crearon también un sistema autónomo de aterrizaje para drones [19]. Se detecta el símbolo desde la distancia, se aproxima, y cuando el drone está correctamente alineado, el sistema comienza la maniobra de aterrizaje.

3.2. EXTRACCIÓN DE LOS CARACTERES DE LA MATRÍCULA

Una vez reconocida la parte de la imagen donde se ha detectado una matrícula, debemos identificar su numeración extrayendo sus caracteres. Para hacer un estudio de las posibilidades, podemos fijarnos tanto en la literatura genérica sobre la extracción de texto en imágenes, como en las técnicas que se usan específicamente para la extracción de matrículas en APRN estáticos.

Si nos fijamos en la extracción de caracteres aplicada a matriculas de coche, Xu et al. [20] proponen un complete sistema que localiza y extrae la numeración de una matrícula de cualquier imagen. Para ello utilizan dos pasos principales, una binarización adaptativa y una segmentación para extraer los caracteres uno a uno.

De forma general, Jung et al. [21] hacen un completo estudio de técnicas usadas para extraer texto de imágenes. En su estudio hacen una gran revisión de técnicas usando una batería de pruebas para dar resultados concretos. Diferencian entre detección de texto, localización de texto, extracción de texto y reconocimiento de caracteres. Una de las conclusiones del citado artículo, es que no hay un método perfecto que tenga un mejor comportamiento en todas estas fases, sino que cada uno ofrece mejores resultados en circunstancias concretas, lo que viene a potenciar nuestra decisión de separar en dos módulos la búsqueda del texto y la extracción de sus caracteres. Por otra parte, fijándonos únicamente en la fase de extracción de caracteres del citado estudio, tampoco se elige un método concreto, sino que en función de las variaciones de los caracteres en base al tamaño, textura, fuente, color, etc. los resultados son completamente diferentes.

Si volvemos a centrarnos en la aplicación de estas técnicas a las matrículas de coche, encontramos por ejemplo un sistema propuesto por Draghici et al. [22] que se basa en segmentar la matrícula en caracteres en base a los espacios en blanco y posteriormente utiliza una red neuronal entrenada con dichos caracteres para intentar descifrarlos individualmente. Más recientemente, Abo et al. [23] propusieron un sistema basado en algoritmos genéticos que consigue una extracción de caracteres con buenos resultados e independiente de las condiciones de luz o ángulo

Como vemos ninguna técnica de las estudiadas para extraer los caracteres de una matrícula se ha puesto a prueba a bordo de un dron. Todo lo estudiado nos sirve para hacernos una idea de que técnicas y en qué momentos dan mejores resultados, para a partir de ahora intentar adaptarlo a nuestra situación concreta. La inestabilidad que genera un dron creará muy probablemente imágenes borrosas y estelas en los caracteres, que supondrán una dificultad añadida.

4. DESCRIPCIÓN DEL SISTEMA

El estudio realizado sobre todas las tecnologías que pudieran ser de nuestro interés, nos llevó finalmente a decidimos por dividir el trabajo en dos grandes módulos, ya que no se pudo encontrar ninguna técnica que diera buenos resultados tanto para la búsqueda de la imagen, como para la extracción de sus caracteres.

Para cumplir el objetivo 1.2 tenemos un protocolo de comunicación con el dron vía WiFi, mediante el mismo obtendremos las imágenes captadas por la cámara del dron en tiempo real y le emitiremos ordenes de movimiento. En un bucle principal, en el dron estará continuamente haciendo la misma ruta se estará procesando cada *frame* mediante el módulo de búsqueda, en el momento que este confirme una identificación de matrícula, el segundo módulo tomará el control.

4.1. MÓDULO DE BÚSQUEDA DE MATRICULAS

El estudio realizado, nos hace decantarnos claramente por alguna técnica de inteligencia artificial bien sea basada en redes neuronales o en arboles de decisión, pues son la mejor opción para una búsqueda de patrones en tiempo real. En concreto, estudios como [24], nos hacen escoger un algoritmo entrenable basado en *AdaBoost*. La razón para elegir basar nuestro algoritmo en *AdaBoost*, es que permite descartar muy rápido los *frames* que no contienen nuestro patrón. De esta forma conseguimos cumplir uno de los objetivos principales, el 2.2, puesto que si los *frames* sin patrón son descartados rápidamente casi sin carga computacional evitamos sobrecargas reservando la capacidad de procesamiento para las imágenes que si contengan una matrícula.

Para seleccionar las características que vamos a entrenar, nos limitamos a seguir el trabajo de Viola y Jones [8] y sus cuatro tipos de características comentadas previamente. Estas se han usado satisfactoriamente para la localización de texto [25] con muy buenos resultados, por lo que es razonable pensar que ocurra igual para detector una matrículas.

Para crear un clasificador para un patrón, necesitamos entrenarlo. Esto significa que debemos conseguir un número considerable de imágenes donde aparezca el patrón del que queremos crear un clasificador e indicar para cada una, la posición del patrón a buscar. Mediante el entrenamiento se consiguen extraer esas características que más se repiten en cada una de las imágenes de entrenamiento. A partir de ellas, se crea un árbol de decisión binario de clasificadores débiles (Poco más del 50% de acierto) que

se comporta como un clasificador más robusto. Cuantos más nodos tenga (mayor entrenamiento), más robusto será.

En nuestro caso contemplamos dos tipos de recorrido del dron, ya que el ángulo de enfoque no será el mismo si los coches están aparcados en fila o en batería, y por lo tanto, también necesitamos dos clasificadores diferentes.



FIGURA 4: LOS DOS TIPOS DE RECORRIDO CONTEMPLADOS

Como podemos ver en la Figura 4, si los coches están aparcados en batería (izquierda), el dron realizará una ruta lateral y el ángulo con las matrículas es prácticamente frontal. En cambio si están en batería, deberá sobrevolar los coches, y para evitar errores en los casos donde haya poco espacio entre los coches y estemos forzados a identificar con un ángulo más vertical, deberemos entrenarlo con imágenes con similar perspectiva. Además teniendo en cuenta que la matrícula puede estar en sombra, se decide incluir como patrón toda la parte de alrededor de la matrícula de faro a faro. De esta forma es más sencillo reconocer que hay una matrícula cuando esta está en penumbra, si es capaz de reconocer los faros y en cierto modo, situar la zona donde está dicha matrícula. Por lo tanto se deciden realizar dos clasificadores distintos para usar uno u otro en función del tipo de aparcamiento que presente la zona.

Como indicamos, el algoritmo de AdaBoost se encarga de seleccionar un pequeño número de clasificados débiles representativos de la muestra del total de posibilidades existente. Estos clasificadores representativos, son los que tienen un poco más del 50% de índice de acierto y que corresponden cada uno a una característica, combinándolos es cuando se reduce el índice de error y vamos contemplando distintas características. Nosotros vamos a utilizar una pequeña variación del algoritmo denominada Gentle AdaBoost [26], podemos verlo resumido en el Anexo1, Anexo 1: Algoritmo de Gentle AdaBoost. La principal característica de esta variación es la fórmula con la que actualizamos los pesos en cada iteración del boosting. Para cada iteración m para la imagen de muestra i , la actualización de pesos vendría dada por:

$$w_{i,m+1} = w_{i,m} \exp(-y_i f_m(x_i))$$

Ha sido probado [26] que usando esta pequeña variación de AdaBoost es posible reducir la carga computacional y conseguir mejores tasas de clasificación correcta considerando tiempos de ejecución similares.

Para entrenar los clasificadores, se obtuvieron 2000 imágenes positivas (que incluyen el patrón) y 5000 negativas (sin el patrón) para cada uno de los dos clasificadores contemplados. Las imágenes negativas sirven para mejorar los falsos negativos, indicándole al algoritmo que cosas no son el patrón, por ello se intentaron poner como negativas, calles vacías o zonas de aparcamiento sin coches, intentando de esta forma mejorar la calidad de los clasificadores.

Se normalizó la muestra positiva a un tamaño de 50x10px y 40x30px para cada uno de los clasificadores (Al incluir un área mayor del vehículo, el clasificador para aparcamiento en línea tiene unas muestras ligeramente más anchas). Se definió una tasa de detección del 99.9% en cada capa para que el algoritmo pasara a la siguiente, y una tasa de falsos positivos del 0.5. El resultado fueron dos clasificadores de 18 capas.

Estos clasificadores en cascada, fueron utilizados varias veces para la detección de matrículas con excelentes resultados de detecciones [15], [16], [27], pero sin embargo también suele ser alto el número de falsos positivos. Así pasa con los creados para este proyecto, detectan que hay una matrícula con extrema velocidad, pero también generan falsos positivos con letreros, carteles y similares. La forma de corregirlo, es aumentar el número de capas (hacer un entrenamiento más largo), pero esto implicaría unos mayores tiempos de clasificación, y un descenso de las clasificaciones correctas. Como no podemos permitirnos mucho margen en el tiempo de clasificación ya que podríamos conseguir que el dron perdiera de vista la matrícula en el tiempo que analiza los *frames*, y tampoco podemos permitirnos la no detección de alguna por crear un clasificador demasiado estricto, decidimos descartar la posibilidad de modificar el clasificador porque lo que buscamos es esa velocidad y precisión.

La forma en la que intentamos compensar la alta tasa de falsos positivos es mediante un índice interno de acierto. Gracias a la velocidad del clasificador somos capaces de analizar una gran cantidad de *frames* sin perder de vista la placa de matrícula. En base a nuestras pruebas podemos asegurar que el número de veces que registra una detección teniendo delante una matrícula real es muy superior al de registradas cuando se trata de un falso positivo, por lo que estableciendo un mínimo de detecciones iguales para considerarlo un reconocimiento real, conseguimos reducir muchísimo los falsos positivos manteniendo la alta tasa de éxito. La determinación de este valor será objeto de nuestras pruebas, pero será dependiente de muchos factores

tales como la velocidad, los *fps* que recibamos, o la capacidad del hardware para procesarlos.

El número de *frames* por segundo (*fps*) es un valor sumamente determinante para nosotros, ya que las opciones de reconocimiento que tengamos pasan directamente por este valor. Siendo *v* la velocidad del dron y *d* la distancia recorrida por el dron con la señal en el ángulo de visión, el número de oportunidades de éxito (OE) será:

$$OE = \frac{d}{v} * fps$$

Esto quiere decir que un dron que pueda suministrar 30*fps* y lleva una velocidad de 2 m/s, si mantiene en el objetivo una matrícula durante 5m, tendrá 75 oportunidades de reconocimiento. Podemos comprobar lo determinante que son los *fps*, teniendo en cuenta que para obtener el mismo número de opciones de éxito, el tiempo se reduce directamente en función de los *fps*:

$$t = \frac{OE}{fps}$$

Con esta visión conseguimos cumplir con el objetivo 2.3, permitiendo que un hardware superior no solo tenga unos mejores resultados, sino que incluso podamos calcularlos y predecir su rendimiento en base a las formulas anteriores. Teniendo en cuenta que por cada oportunidad de éxito, las posibilidades de detección son independientes del hardware (únicamente dependen del clasificador), el poder calcular las diferencias de oportunidades se traduce en poder calcular el número de reconocimientos predecible con una mejora de hardware.

Con cada reconocimiento, obtenemos las coordenadas de la zona donde se produjo. Esta zona se denomina región de interés o ROI (*Region of Interest*). En el momento en el que haya un positivo, recortaremos esta zona de interés y la pasaremos al siguiente modulo.

4.2. MÓDULO DE EXTRACCIÓN DE CARACTERES

La calidad de la sub imagen que compone el ROI depende de muchos factores como la luz, el tiempo, contraste, brillo, ángulo, etc. Estos factores al igual que la propia inestabilidad del dron pueden distorsionar la imagen generando una dificultad añadida para la extracción de caracteres. La manera de compensar estas

imperfecciones es mediante una fase de procesado de imagen en la que intentemos eliminar estas imperfecciones sin desfigurar los caracteres.



FIGURA 5: EJEMPLOS DE ROI DETECTADOS MEDIANTE AMBOS CLASIFICADORES

Antes de la fase de procesado de imagen, es necesario un pre procesado en el caso de utilizar el clasificador para coches en línea. Como podemos ver en la Figura 5, el ROI que devuelve dicho clasificador se diferencia bastante del ROI devuelto con el clasificador que solo se encarga de buscar la matricula. Para que el uso de uno u otro no afecte al resto del trabajo, en esta fase de pre procesado se intentan igualar. Para ello, y teniendo en cuenta que los ROI obtenidos mediante el clasificador de batería tampoco son perfectos (nunca recorta completamente la matricula, sino que incluye un margen variable), realizamos un recorte genérico calculado en base a pruebas. Este recorte resultó ser del 25% por cada lado y el 50% superior (zonas en rojo en la Figura 5). Tras este recorte, se comprobó que los ROI generados por un clasificador o por el otro son similares.

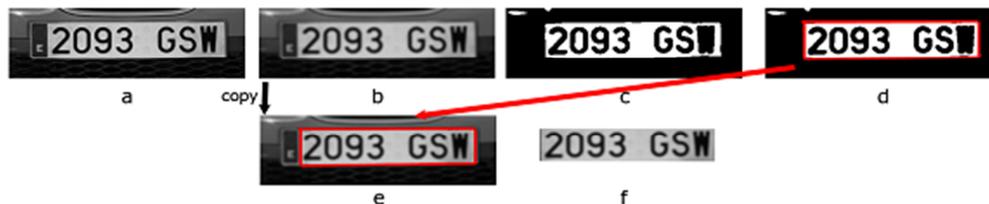


FIGURA 6: FASES DEL PROCESADO DE IMAGEN

Para procesar la imagen y contrarrestar imperfecciones, primero se aplica un filtro gaussiano de 9x9 píxeles para remover el ruido superficial de la imagen, posteriormente, se hace una copia. El objetivo ahora es recortar exactamente la zona con caracteres. Para ello se binariza la imagen (Se pone en dos tonos) utilizando un valor muy bajo como umbral (exactamente se coge el 90% de la intensidad del valor más claro), de forma que cualquier color de la imagen salvo el blanco pasa a ser negro, incluyendo brillos, sombras o marcas de matrículas (como el identificador azul de la UE) y la imagen queda con el aspecto que muestra la Figura 6 (d). Ahora es cuando habiendo resaltado de forma inequívoca el rectángulo central delimitamos esa zona usando el algoritmo para la detección de bordes propuesto por Suzuki [28]. Este algoritmo examina la imagen pixel a pixel buscando correspondencias y determinando

cuáles de ellos pueden pertenecer a un mismo borde, para más seguridad por si en algún caso detectara algún otro borde, de entre la colección de bordes devuelta buscamos el más grande y comprobamos que es de un tamaño superior al 60% del tamaño del ROI, en otro caso, no lo consideramos. Como esta imagen quedo deteriorada tras una binarización a tan bajo umbral, recogemos las coordenadas del borde y recurrimos a la copia que habíamos realizado. Hacemos el recorte y obtendremos la zona exacta de la matrícula donde están contenidos los caracteres como vemos en la Figura 6 (f).



FIGURA 7: BINARIZACIÓN ADAPTATIVA Y EXTRACCIÓN Y DIVISIÓN EN CARACTERES

Con la imagen recortada, debemos hacer una nueva binarización, pero en este caso no podemos fijar un umbral, puesto que en cualquier caso en el que hubiera diferencias de iluminación, sombras o brillos en la matrícula, cosa que es muy común, habría caracteres que quedarían irreconocibles tras la binarización. Por eso, decidimos utilizar una binarización adaptativa, en concreto utilizamos la binarización de Sauvola [29] donde el valor de umbral es recalculado para cada pixel de la imagen adaptándolo a las condiciones de cada área de la imagen.

Una vez con la imagen preparada, es cuando procedemos a extraer los caracteres. Teniendo en cuenta que los caracteres son exactos en cualquier matrícula (no hay tipos de fuente), y con la imagen procesada simplemente se tratan de figuras en negro sobre blanco, decidimos usar el método de los momentos invariantes de Hu [30]. Estos no son más que siete funciones que se calculan para una imagen, y cuyos resultados son invariantes ante la translación, rotación y rescaldo, lo que quiere decir que para un mismo símbolo, obtendremos un mismo resultado independientemente del tamaño, ángulo o posición. Para una breve descripción de la base teórica de los momentos invariantes de Hu, consultar el Anexo 2: Momentos Invariantes de Hu.

Lo primero que hacemos es dividir la imagen en caracteres. Tras la binarización es una tarea bastante sencilla pues simplemente debemos recorrer la imagen de izquierda a derecha formando una sub imagen por cada bloque de columnas seguidas cuya intensidad global es mayor que cero.

ABCDEFGHIJKLMNOPQRSTUVWXYZ
0123456789

FIGURA 8: SET DE CARACTERES CON LOS QUE REALIZAMOS EL ENTRENAMIENTO DE LOS MOMENTOS DE HU

Una vez con una sub imagen por carácter, debemos aplicarle los siete momentos de Hu, que se traducirán en siete resultados numéricos y comparables. Previamente, al empezar a funcionar el sistema se calcularán los resultados de control con las imágenes de todos los caracteres considerados (Figura 8), por lo que simplemente tenemos que escoger el carácter cuyos momentos den resultados más aproximados al actual.

Una vez finalizada la fase de extracción de caracteres, se decide hacer una modificación para hacer el sistema más robusto. Nos damos cuenta que si se filtra a este módulo un falso positivo, la condición inicial de que sea detectado un borde de un rectángulo con área superior al 60% del área del ROI, consigue descartarlo rápidamente, por lo que no se traduce prácticamente en carga computacional el que pasen falsos positivos a este módulo. En base a esa comprobación se decide reubicar el número mínimo de reconocimientos a este módulo, traduciéndose en “número mínimo de lecturas iguales”. Es decir, si en una primera versión era necesario un número de reconocimientos seguidos para pasar el ROI al segundo módulo, ahora pasan todos los reconocimientos, y es en el segundo módulo donde se necesita un número de lecturas iguales. Las ventajas de esta decisión fueron evidentes desde las primeras pruebas:

- Los falsos positivos, aparte de ser pocos, no darán trabajo al módulo porque son evitados al no encontrarse el rectángulo de la matrícula. Nunca se llega al cálculo de los momentos.
- Obtenemos muchas más posibilidades de lectura. Para una misma matrícula, solo pasaban al OCR un *frame* de cada *x* analizados (siendo *x* el número mínimo establecido)
- No había ningún sistema de confirmación de lectura. Antes si solo llegaba un *frame* y por lo tanto una sola lectura, esta se consideraba correcta sin ningún mecanismo posible de confirmación.
- Se cumple el objetivo 3 por completo, puesto que estableciendo un número mínimo, por ejemplo de 10, resulta casi imposible que un drone en vuelo detecte exactamente los mismos caracteres en 10 *frames* diferentes sin que esa sea la lectura correcta.

5. METODOLOGÍA DE TRABAJO

Una vez terminado el prototipo, la realización de las pruebas de un proyecto como este conlleva determinadas decisiones que hubo que tomar.

En primer lugar, se decide descartar las pruebas con coches en fila. La razón es la imposibilidad de obtener resultados científicamente objetivos, debido a la cantidad de variables ajenas al sistema que influyen directamente en los resultados. Las dos principales variables por las que descartamos las pruebas son las siguientes:

- Distancia entre vehículos: Si dos coches están demasiado cerca o pegados, independientemente del diseño de cualquier sistema, no se podrá acceder a la matrícula. Este valor, en un principio, se pensó en que podría ser interesante de calcular, saber a qué distancia es necesaria separar las plazas para que funcione correctamente. Pero esta posibilidad fue descartada al comprobar las siguientes variables.
- Altura de los vehículos: Aunque haya espacio entre dos vehículos, tal y como se definió el algoritmo si un coche es lo suficientemente más alto que el siguiente, la matrícula puede no entrar en el ángulo de visión del dron (Lo cual se incrementa en el caso de tratarse de furgonetas o camiones)

En aparcamientos con plazas marcadas y suficientemente separadas, los resultados obtenidos son completamente distintos a los de una calle cualquiera con los vehículos aparcados "sin control", es por esta razón por la que no se consideran objetivos los posibles resultados obtenidos.

En segundo lugar, se decide intentar determinar el valor mínimo de lecturas correctas. Tras la modificación de este mecanismo de control, cobra aún más interés poder determinarlo, debido a que es un valor mucho más pequeño y cuantificable que está aún más ligado que antes a los resultados finales y al tiempo transcurrido.

Por último lugar, cabe resaltar en la metodología, la relación comentada entre las oportunidades de éxito y los *fps* que nos suministre el dron. Estas son independientes a la modificación del mínimo de aciertos, y por supuesto también al OCR. Por cada oportunidad, existen las mismas opciones de hacer una lectura correcta independientemente del hardware. Por ello, calculando el porcentaje de mejora experimentado en las opciones de éxito al aumentar los *fps* del dron, tendremos exactamente la mejora global de aciertos del sistema.

$$OE = \frac{d}{v} * fps \quad t = \frac{OE}{fps}$$

Una vez determinadas las condiciones generales de las pruebas, se procede a definir el experimento. Las pruebas se realizarán con un AR Drone 2 capaz de suministrar 30 *fps*, conectado vía WiFi a un Smartphone Android OnePlus One con 3Gb de RAM y un procesador Quad-Core Snapdragon a 2.5GHz.

Se utiliza una muestra de 100 vehículos aparcados en batería en un recinto comercial. Se deciden realizar pasadas de reconocimiento y conseguir datos de tiempo y reconocimientos correctos. Se irá variando el número mínimo de lecturas iguales, aumentándolo de cinco en cinco, hasta que los tiempos globales sean demasiado grandes para considerarse eficiente, o bien se consiga el 100% de éxito.

6. RESULTADOS OBTENIDOS

N (frames)	Acierto (%)	Tiempo total (min)
5	88	13
10	97	21
15	98	32
20	99	41

TABLA 1: RESULTADOS OBTENIDOS PARA 100 VEHICULOS

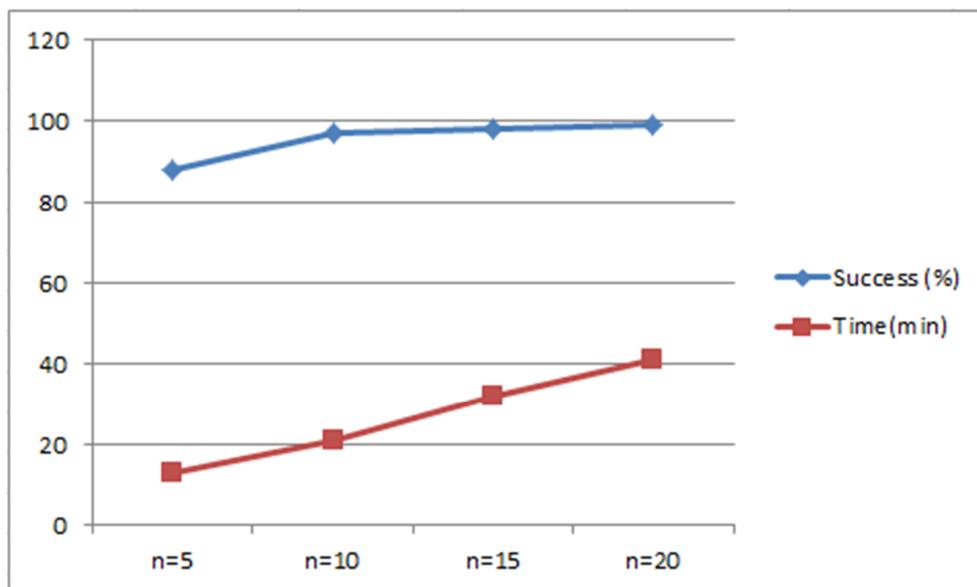


FIGURA 9: RELACIÓN DEL TIEMPO Y EL NUMERO DE ACIERTOS CON N

6.1. INTERPRETACIÓN DE RESULTADOS

Los resultados en la Tabla 1, siendo N el número mínimo de *frames* con la misma lectura establecidos por el usuario, evidencian de que el punto de inflexión se encuentra entre 5 y 10 *frames*. Con 10 se logra un nivel de exactitud del 97%. Los incrementos de ese umbral requieren una inversión de importante de tiempo para una no tan grande mejora de los resultados. Por ejemplo, un 2% de mejora en el número de aciertos, requiere el doble de tiempo.

La relación entre el tiempo total en cada modo con el número de reconocimientos con éxito se muestra en la Figura 10. En ella se puede ver como a partir de ese punto de inflexión la gráfica de exactitud tiende a mantenerse constante, mientras la progresión del tiempo continúa creciendo con igual proporción.

6.2. DISCUSIÓN

Al principio no podíamos hacernos una idea de los resultados obtenidos puesto que no sabíamos que íbamos a implementar ese número mínimo de lecturas iguales que es, como vemos en los resultados, tan determinante. Pero creemos que para cumplir con los objetivos 2 y 3 sin que la solución de uno comprometa al otro, esta es la única solución.

Estos resultados además si seguimos las fórmulas de rendimiento explicadas previamente, podemos intuir que si un drone en vez de 30fps, nos da 60fps, si tenemos un hardware capaz de procesarlos, podríamos alcanzar el mismo nivel de aciertos justamente en la mitad de tiempo. Pero en todo caso, el punto de inflexión es el mismo, y por tanto la estimación de N para optimizar el sistema, estaría en torno a los 10 *frames* independientemente del hardware.

7. CONCLUSIONES Y TRABAJO FUTURO

Este trabajo analiza la idoneidad y exactitud del sistema propuesto, que no es más que una combinación de algoritmos y tecnologías orientadas a resolver los problemas de reconocimiento de matrículas en entornos estáticos existentes a un escenario nuevo hasta la fecha, como es el uso de vehículos aéreos no tripulados con el fin de poder realizar actividades de seguridad o control. Las características específicas de estos nuevos escenarios (inestabilidad de la cámara, diferentes condiciones de luz, dispositivos de potencia reducida, etc.) requerirían una evaluación exhaustiva variando cada una de esas condiciones. Decidimos realizar las pruebas en condiciones óptimas (nublado, sin viento y en un entorno controlado) ya que contamos con un pequeño dron, que obviamente no sería el utilizado si el sistema se pusiera en explotación y más aún en condiciones adversas. Existen drones preparados para la lluvia, dotados de gran estabilidad, con cámaras HD y objetivos gran angular que mediante las correcciones que hacemos mediante software, es evidente que registrarían mejores resultados en dichas condiciones. A pesar de si las limitaciones del prototipo (un barato Parrot AR Dron comercial), los resultados son prometedores, se consiguen resultados de gran exactitud en un tiempo que podemos considerar viable.

7.1. TRABAJO FUTURO

Mejorar el algoritmo en aparcamientos en fila es uno de los objetivos futuros. Como apuntábamos antes de realizar las pruebas, hay muchos casos en los que directamente es imposible reconocer una matrícula porque esté completamente tapada. En estos casos, intentar reconocer la parte contraria del coche e intentar reconocer la otra placa, solucionaría un alto porcentaje de casos. Otra posible mejora sería reconocer la parte superior de un coche, para hacer que el dron descienda hasta donde sea posible, en los casos que el vehículo anterior sea de tal altura que rompe el ángulo de visión.

Otra línea de investigación, sería replantear el sistema para vehículos en movimiento, registrando el tráfico que pase por ciertas carreteras.

7.2. DIFUSIÓN DE LOS RESULTADOS

Se propusieron distintas publicaciones como aptas para intentar publicar nuestro trabajo. Se barajaron revistas relacionadas con tecnologías del transporte, con robótica o con inteligencia artificial. Al final nos decantamos por "Pattern Recognition Letters" puesto que aunque la mayor innovación de nuestro trabajo sea su utilización a través

de un drone, ambos módulos principales son dos técnicas de reconocimiento de patrones, dejando el manejo del drone a un segundo plano que no entraña dificultad ni avance alguno, los movimientos del drone se traducen en simples instrucciones de desplazamiento o parada. La interpretación de los estímulos que lanzan estas órdenes al drone, son la verdadera aportación de este artículo, y no son más que complejos sistemas de reconocimiento de patrones, tanto en un primer nivel con el patrón genérico de una matrícula mediante clasificadores en cascada generados por Boosting, como en un segundo nivel en el reconocimiento de los caracteres mediante momentos invariantes.

Actualmente, el artículo se encuentra aprobado para su revisión por la revista y por los autores, y está en espera de la misma.

The screenshot shows the 'Pattern Recognition Letters' journal submission interface. At the top, there is a navigation bar with the journal title, a 'Contact us' link with an envelope icon, a 'Help' link with a question mark icon, the Elsevier logo, and a note: "'My EES Hub' available for consolidated view". Below this, a secondary navigation bar includes links for 'home', 'main menu', 'submit paper', 'guide for authors', 'register', 'change details', and 'log out'. On the right side of this bar, the user's 'Username: delrioalvarez@gmail.com' is displayed, along with a 'Switch To:' dropdown menu currently set to 'Author' and a 'Go to: My EES Hub' link.

The main content area is titled 'Submissions Being Processed for Author Angel Del Rio Alvarez'. It indicates 'Page: 1 of 1 (1 total submissions)'. Below this is a table with the following structure:

Action	Manuscript Number	Title
Action Links		An UAV based license plate vehicle recognition system with a boosting approach

At the bottom of the table area, it again shows 'Page: 1 of 1 (1 total submissions)'.

8. PRESUPUESTO

- Hora de trabajo del Alumno: 30€
- Hora de trabajo de Profesor: 40€
- Los ordenadores valen un total de 950€ cada uno. Estimándoles una vida útil de 7 años, el precio de uso por hora es de 0.02€
- Los sistemas operativos y programas de ofimática estaban incluidos en el precio de los ordenadores ya que venían preinstalados.
- Dispositivo Android OnePlus One: 299€
- Parrot AR Drone 2: 295€
- Las licencias necesarias para el desarrollo del proyecto son gratuitas (OpenCV, JavaOCR, SDK Parrot e IDE Android en Eclipse)

CONCEPTO	HORAS	PRECIO	TOTAL
180 días de trabajo autónomo del alumno a una media de dos horas al día	360	30	10.800
17 reuniones del alumno con director/es	17	30	510
10 reuniones del director	10	40	400
7 reuniones director y codirectores	7	120	840
Trabajo de revisión de director y codirectores	30	120	3.600
Uso de ordenadores	407	0,02	8,14
Parrot AR Drone	-	295	295
OnePlus One	-	299	299
Licencias	-	0	0
TOTAL			16.752,14

NOTA: La gran diferencia existente con lo presupuestado al principio en la solicitud de lectura, fue el que calculo anterior se realizó erróneamente en función a una jornada laboral de 8h.

9. BIBLIOGRAFÍA

- [1] C.-N. E. Anagnostopoulos, I. E. Anagnostopoulos, I. D. Psoroulas, V. Loumos, and E. Kayafas, "License Plate Recognition From Still Images and Video Sequences: A Survey," *IEEE Trans. Intell. Transp. Syst.*, vol. 9, no. 3, pp. 377–391, Sep. 2008.
- [2] B. Hongliang and L. Changping, "A hybrid license plate extraction method based on edge statistics and morphology," in *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004.*, 2004, vol. 2, pp. 831–834 Vol.2.
- [3] D. Zheng, Y. Zhao, and J. Wang, "An efficient method of license plate location," *Pattern Recognit. Lett.*, vol. 26, no. 15, pp. 2431–2438, Nov. 2005.
- [4] D.-S. Kim and S.-I. Chien, "Automatic car license plate extraction using modified generalized symmetry transform and image warping," in *ISIE 2001. 2001 IEEE International Symposium on Industrial Electronics Proceedings (Cat. No.01TH8570)*, 2001, vol. 3, pp. 2022–2027.
- [5] A. Yazıcı and C. Şener, Eds., *Computer and Information Sciences - ISCIS 2003*, vol. 2869. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003.
- [6] C.-T. Hsieh, Y.-S. Juan, and K.-M. Hung, "Multiple License Plate Detection for Complex Background," in *19th International Conference on Advanced Information Networking and Applications (AINA'05) Volume 1 (AINA papers)*, vol. 2, pp. 389–392.
- [7] C.-D. Nguyen, M. Ardabilian, and L. Chen, "Real-time license plate localization based on a new scale and rotation invariant texture descriptor," in *2008 11th International IEEE Conference on Intelligent Transportation Systems*, 2008, pp. 956–961.
- [8] P. Viola and M. Jones, "Rapid object detection using a boosted cascade of simple features," in *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, 2001, vol. 1, pp. I–511–I–518.
- [9] Y. Freund and R. E. Schapire, "A Decision-theoretic Generalization of On-line Learning and an Application to Boosting," *J. Comput. Syst. Sci.*, vol. 55, no. 1, pp. 119–139, 1997.
- [10] P. Viola and M. J. Jones, "Robust Real-Time Face Detection," *Int. J. Comput. Vis.*, vol. 57, no. 2, pp. 137–154, May 2004.
- [11] P. Viola, M. J. Jones, and D. Snow, "Detecting Pedestrians Using Patterns of Motion and Appearance," *Int. J. Comput. Vis.*, vol. 63, no. 2, pp. 153–161, Feb. 2005.

- [12] R. Martins, P. Pina, J. S. Marques, and M. Silveira, "Crater Detection by a Boosting Approach," *IEEE Geosci. Remote Sens. Lett.*, vol. 6, no. 1, pp. 127–131, Jan. 2009.
- [13] S. Hrabar, G. S. Sukhatme, P. Corke, K. Usher, and J. Roberts, "Combined optic-flow and stereo-based navigation of urban canyons for a UAV," in *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2005, pp. 3309–3316.
- [14] B. Sinopoli, M. Micheli, G. Donato, and T. J. Koo, "Vision based navigation for an unmanned aerial vehicle," in *Proceedings 2001 ICRA. IEEE International Conference on Robotics and Automation (Cat. No.01CH37164)*, 2001, vol. 2, pp. 1757–1764.
- [15] L. Dlagnekov, "License plate detection using adaboost," *Comput. Sci. Eng. Dep. San Diego*, 2004.
- [16] X. Zhang, P. Shen, Y. Xiao, B. Li, Y. Hu, D. Qi, X. Xiao, and L. Zhang, "License plate-location using Adaboost algorithm," in *2010 IEEE International Conference on Information and Automation, ICIA 2010*, 2010, pp. 2456–2461.
- [17] A. Masselli, S. Yang, K. E. Wenzel, and A. Zell, "A Cross-Platform Comparison of Visual Marker Based Approaches for Autonomous Flight of Quadcopters," *J. Intell. Robot. Syst.*, vol. 73, no. 1–4, pp. 349–359, Oct. 2013.
- [18] K. E. Wenzel, A. Masselli, and A. Zell, "Automatic Take Off, Tracking and Landing of a Miniature UAV on a Moving Carrier Vehicle," *J. Intell. Robot. Syst.*, vol. 61, no. 1–4, pp. 221–238, Oct. 2010.
- [19] S. Saripalli, J. F. Montgomery, and G. S. Sukhatme, "Visually guided landing of an unmanned aerial vehicle," *IEEE Trans. Robot. Autom.*, vol. 19, no. 3, pp. 371–380, Jun. 2003.
- [20] Z. Xu and H. Zhu, "An Efficient Method of Locating Vehicle License Plate," in *Third International Conference on Natural Computation (ICNC 2007)*, 2007, vol. 2, pp. 180–183.
- [21] K. Jung, K. In Kim, and A. K. Jain, "Text information extraction in images and video: a survey," *Pattern Recognit.*, vol. 37, no. 5, pp. 977–997, May 2004.
- [22] S. Draghici, "A Neural Network Based Artificial Vision System for Licence Plate Recognition," *Int. J. Neural Syst.*, vol. 08, no. 01, pp. 113–126, Feb. 1997.
- [23] G. Abo Smara and F. Khalefah, "Localization of License Plate Number Using Dynamic Image Processing Techniques and Genetic Algorithms," *IEEE Trans. Evol. Comput.*, vol. 18, no. 2, pp. 244–257, Apr. 2014.

- [24] G. Kogut, F. Birchmore, E. Biagtan Pacis, and H. R. Everett, “<title>Using advanced computer vision algorithms on small mobile robots</title>,” in *Using advanced computer vision algorithms on small mobile robots*, 2006, pp. 623021–623021–13.
- [25] X. C. X. Chen and A. L. Yuille, “Detecting and reading text in natural scenes,” *Proc. 2004 IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognition, 2004. CVPR 2004.*, vol. 2, 2004.
- [26] R. Lienhart and J. Maydt, “An extended set of Haar-like features for rapid object detection,” in *Proceedings. International Conference on Image Processing, 2002*, vol. 1, pp. I–900–I–903.
- [27] R. Wang, N. Sang, R. Huang, and Y. Wang, “License plate detection using gradient information and cascade detectors,” *Opt. - Int. J. Light Electron Opt.*, vol. 125, no. 1, pp. 186–190, Jan. 2014.
- [28] S. Suzuki and K. be, “Topological structural analysis of digitized binary images by border following,” *Comput. Vision, Graph. Image Process.*, vol. 30, no. 1, pp. 32–46, Apr. 1985.
- [29] J. Sauvola and M. Pietikäinen, “Adaptive document image binarization,” *Pattern Recognit.*, vol. 33, no. 2, pp. 225–236, Feb. 2000.
- [30] M.-K. Hu, “Visual pattern recognition by moment invariants,” *IEEE Trans. Inf. Theory*, vol. 8, no. 2, pp. 179–187, Feb. 1962.

10. ANEXOS

10.1. ANEXO 1: ALGORITMO DE GENTLE ADABOOST

La parte principal de nuestro primer módulo reside en este algoritmo. Su ejecución correcta con un adecuado conjunto de imágenes de muestra es lo que reparte pesos a cada característica contemplada y conforma el clasificador que se utilizará para la detección de matrículas.

El artículo completo que describe este algoritmo, puede encontrarse en la bibliografía [26] bajo el título de *“An extended set of Haar-like features for rapid object detection”*, Lienhart et al. describen un nuevo conjunto de características que aumenta el de Viola y Jones, además de mejorar el algoritmo inicial de AdaBoost consiguiendo unos mejores resultados.

1. Partimos de n imágenes $(x_1, y_1), \dots, (x_N, y_N)$ donde cada imagen x_i tiene una clase asociada y_i , y donde $x \in \mathbb{R}^k, y_i \in \{-1, 1\}$
2. Empezamos asignando los pesos $w_i = \frac{1}{N}, i = 1, \dots, N$.
3. Y repetimos para $m=1, \dots, M$
4. Se calcula la función de regresión $f_m(x)$ mediante mínimos cuadrados ponderados de y_i a x_i con pesos w_i
5. Actualizamos $f(x) = f(x) + f_m(x)$
6. Actualizamos $w_{i,m+1} = w_{i,m} \exp(-y_i f_m(x_i))$
7. Obtenemos $f(x) = \text{sign}(\sum_{m=1}^M f_m(x))$

10.2. ANEXO 2: MOMENTOS INVARIANTES DE HU

Al igual que en el primer módulo es de especial importancia el algoritmo de *AdaBoost*, en el segundo la parte principal es la utilización de los momentos invariantes de Hu.

Toda la información sobre el método de Hu la podemos encontrar en la bibliografía Hu [30] mediante el título "*Visual pattern recognition by moment invariants*". A continuación describiremos de forma superficial los siete momentos de Hu.

Partimos de la definición de un momento geométrico que para un nivel $(p + q)$ se define mediante

$$m_{pq} = \sum_{x \in R} \sum_{y \in R} x^p y^q f(x, y), \quad p, q = 0, 1, 2, \dots$$

Donde R es el conjunto de todos los pixeles pertenecientes a la imagen y $f(x, y)$ es el brillo del pixel de coordenadas (x, y) en la imagen. El centro de gravedad de R es definido por

$$\bar{x} = \frac{m_{10}}{m_{00}}, \quad \bar{y} = \frac{m_{01}}{m_{00}}$$

De esta forma, si movemos el origen de coordenadas al centro de gravedad, se obtiene invariancia de momentos geométricos con respecto a la ubicación de R dentro de la imagen. Tales momentos geométricos se llaman momentos geométricos centralizados de nivel $(p + q)$

$$\mu_{pq} = \sum_{x \in R} \sum_{y \in R} (x - \bar{x})^p (y - \bar{y})^q f(x, y)$$

Para mayor garantía de invariabilidad de los momentos geométricos con respecto al tamaño de R , los normalizamos como se muestra en la siguiente fórmula. Esto nos da momentos geométricos centralizados normalizados.

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^r}, \quad (p + q) = 2, 3, \dots, \quad r = \frac{p + q}{2} + 1$$

Por último, los parámetros de Hu se definen con las fórmulas siguientes.

$$\phi_1 = \eta_{20} + \eta_{02}$$

$$\phi_2 = (\eta_{20} + \eta_{02})^2 + 4\eta_{11}^2$$

$$\phi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$$

$$\phi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2$$

$$\begin{aligned} \phi_5 = & (\eta_{30} + 3\eta_{12}) \cdot (\eta_{30} + \eta_{12}) \cdot ((\eta_{30} + \eta_{12})^2 - 3 \cdot (\eta_{21} + \eta_{03})^2) + \\ & + (3\eta_{21} + \eta_{03}) \cdot (\eta_{21} + \eta_{03}) \cdot (3 \cdot (\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2) \end{aligned}$$

$$\phi_6 = (\eta_{20} - \eta_{02}) \cdot ((\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2) + 4\eta_{11} \cdot (\eta_{30} + \eta_{12}) \cdot (\eta_{21} + \eta_{03})$$

$$\phi_7 = (3\eta_{21} - \eta_{03}) \cdot (\eta_{30} + \eta_{12}) \cdot ((\eta_{30} + \eta_{12})^2 - 3 \cdot (\eta_{21} + \eta_{03})^2) + (3\eta_{12} + \eta_{30}) \cdot (\eta_{21} + \eta_{03}) \cdot (3 \cdot (\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2)$$

Además son invariantes a la rotación de R. Esta invariancia es en realidad el punto más fuerte de los parámetros de Hu; con ellos podemos comparar objetos de diferentes tamaños sin preocuparse por la normalización de los parámetros.