

Sistema de coordinación de semáforos inteligentes con algoritmos de inteligencia artificial

Intelligent traffic light coordination system with artificial intelligence algorithms

Santiago San Miguel

sanmisanti@gmail.com

Ingeniería en Informática, Facultad de Ingeniería - Universidad Católica de Salta

Resumen

En este artículo se presenta un sistema de semáforos inteligentes basado en algoritmos de detección de vehículos y coordinación dinámica. El sistema utiliza el modelo YOLOv5 junto con OpenCV para la detección precisa de vehículos en tiempo real a fin de ajustar la coordinación de semáforos según la demanda de tráfico.

El sistema realiza una evaluación constante de los niveles de congestión en cada sentido de una intersección, al priorizar la reducción de los tiempos de espera de los conductores y la maximización del flujo de tráfico en toda la ciudad. Con el objetivo de lograr esta meta, el sistema emplea técnicas de reconocimiento de imágenes en tiempo real a fin de adaptar de manera dinámica la operación de los semáforos y así optimizar el flujo de vehículos, al contribuir a la mitigación de la congestión.

Palabras clave: aemáforo, inteligencia artificial, seguridad vial, YOLO, opencv, Python.

Abstract

This article presents an intelligent traffic light system based on vehicle detection algorithms and dynamic coordination. The system uses the YOLOv5 model in conjunction with OpenCV for accurate real-time vehicle detection and adjusts traffic light coordination according to traffic demand.

The system continuously evaluates congestion levels in each direction of an intersection, prioritizing the reduction of driver wait times and maximizing traffic flow throughout the city. In order to achieve this goal, the system employs real-time image recognition techniques to dynamically adapt traffic light operations, thereby optimizing vehicle flow and contributing to congestion mitigation.

Key words: traffic light, artificial intelligence, road safety, YOLO, Python

Introducción

Las rutas y las calles de una ciudad son la columna vertebral del tránsito y lo que permite el flujo y desplazamiento de sus habitantes. Sin embargo, por desgracia el tráfico y, en particular la congestión vehicular, conlleva una serie de desafíos que resultan en pérdida de tiempo y frustración para los conductores que buscan desplazarse de un punto a otro de manera eficiente. La necesidad de replantear la forma en que las personas conducen y de hallar soluciones más efectivas para abordar los problemas de tráfico se ha vuelto imperante.

Este proyecto se propone abordar estos desafíos a través de la implementación de técnicas de modelado. El objetivo primordial es la concepción y el desarrollo de una solución tecnológica que permita la identificación y el seguimiento de los vehículos presentes en las vías urbanas y la coordinación de cruces por medio de algoritmos basados en demanda. Este seguimiento se lleva a cabo mediante técnicas de reconocimiento de imágenes con el propósito de lograr una sincronización precisa de las operaciones de tráfico, reduciendo de manera significativa los tiempos muertos y los períodos de espera para los conductores. Se implementó un sistema basado en el modelo YOLOv5, que utiliza algoritmos de detección de objetos a fin de identificar vehículos en intersecciones urbanas. Esto permite la recopilación de datos precisos sobre el flujo de tráfico y la demanda en cada momento.

El sistema también incorpora un enfoque de coordinación dinámica de semáforos, al ajustar los ciclos en función de la demanda actual de tráfico. Esta coordinación se basa en datos en tiempo real y permite priorizar los sentidos de tráfico más congestionados.

Mediante la introducción de sistemas inteligentes de gestión del tráfico que utilizan la inteligencia artificial, se espera lograr una mejora considerable en las condiciones de tráfico. Esta investigación se llevó a cabo con el propósito de demostrar la efectividad y la eficiencia del sistema propuesto, sirviendo de modelo para futuras implementaciones de soluciones avanzadas de gestión del tráfico en entornos urbanos.

Al analizar proyectos previos de naturaleza similar, destaca el proyecto titulado "Diseño de un sistema de semaforización inteligente para controlar el flujo vehicular mediante procesamiento de imágenes," desarrollado por la Universidad Piloto de Colombia en el año 2020 [1]. El objetivo primordial consistió en la interpretación de datos visuales con el fin de modificar los patrones de funcionamiento de los semáforos, lo cual demostró ser factible y efectivo.

Por otra parte, un sistema adicional utiliza cámaras de vigilancia del tráfico con el objetivo de incrementar la seguridad en entornos urbanos. Estas cámaras permiten al personal encargado de la seguridad llevar a cabo un monitoreo continuo y en tiempo real de las vías, además de registrar secuencias de video que no solo mejoran la eficiencia de las operaciones, sino que también proporcionan evidencia en caso de eventos como accidentes o delitos. Según un estudio respaldado por el Instituto de Seguros para la Seguridad en las Carreteras (IIHS) [2], las intersecciones equipadas con cámaras han experimentado una notable disminución del 21 % en la probabilidad de ocurrencia de accidentes en comparación con aquellas que carecen de este sistema de vigilancia. Estos hallazgos subrayan el impacto positivo de la tecnología de vigilancia en la seguridad vial en zonas urbanas y proporcionan una base sólida para futuras implementaciones y desarrollos en este ámbito.

A partir de estas investigaciones y al reconocer la creciente importancia de la tecnología en la seguridad y en la vida moderna, se propone el desarrollo de un sistema de identificación y coordinación de semáforos que busca maximizar el flujo vehicular y la seguridad vial.

1. Marco teórico

1.1. Modelo YOLO

You Only Look Once (YOLO, por su sigla en inglés) es un modelo popular de detección de objetos y segmentación de imágenes. Joseph Redmon y Ali Farhadi lo desarrollaron en la Universidad de Washington [3]. Lanzado en 2015, YOLO ganó rápidamente popularidad debido a su alta velocidad y precisión.

La metodología YOLO ("solo miras una vez" en español), es una técnica de detección de objetos en imágenes y videos que se basa en una red neuronal convolucional (CNN, por su sigla en inglés) especializada en la tarea de detección de objetos en tiempo real. Joseph Redmon y Santosh Divvala la crearon y ha evolucionado a través de varias versiones, siendo YOLOv5 una de las más conocidas hasta la fecha. La principal característica distintiva de YOLO es el enfoque en la velocidad y la eficiencia, ya que es capaz de detectar objetos en una sola pasada a través de la imagen, a diferencia de enfoques anteriores que requerían múltiples pasadas.




Figura 1: Detección de objetos en una sola pasada

1.2. Redes neuronales convolucionales

Las Redes Neuronales Convolucionales [4] son un tipo especializado de red neuronal artificial diseñada principalmente a fin de procesar datos que tienen una estructura de cuadrícula, como imágenes y videos. Las CNN son en extremo efectivas en tareas relacionadas con la visión por computadora, como la clasificación de imágenes o la detección de objetos.

La característica principal de una CNN es su capacidad para realizar convoluciones en los datos de entrada. Las convoluciones son operaciones matemáticas que permiten extraer características relevantes de una imagen al aplicar filtros o núcleos convolucionales en diferentes regiones de la imagen.

La arquitectura de una CNN suele seguir un patrón en el que las primeras capas aprenden características simples (como bordes), y las capas posteriores combinan estas características simples para identificar características más complejas y abstractas en las imágenes.




Figura 2: Arquitectura de una CNN

2. Desarrollo

A fin de garantizar un enfoque eficiente y efectivo en este contexto, se ha seleccionado la metodología evolutiva de prototipado.

La relevancia de aplicar esta metodología radica en la necesidad de contar con un enfoque

dinámico y flexible que permita enfrentar los desafíos inherentes a la combinación de disciplinas especializadas como el aprendizaje automático, el procesamiento de imágenes y el diseño de algoritmos de coordinación. Dado que rara vez es posible poseer un dominio absoluto en todas estas áreas, el enfoque por prototipado es un enfoque prudente que involucra iteraciones continuas, al permitir la incorporación progresiva de nuevos conocimientos, herramientas y técnicas a medida que se descubren.

La metodología del desarrollo evolutivo mediante prototipos posibilitará el abordaje gradual y sistemático de los desafíos planteados. A medida que se desarrollen soluciones funcionales de los algoritmos de detección y coordinación, estos podrán someterse a pruebas en un entorno controlado. Además, esta metodología facilita la transformación evolutiva de los prototipos a medida que se descubren y desarrollan nuevas capacidades y enfoques.

Es fundamental destacar que, al considerar que el objetivo central es la mejora de la eficiencia del tráfico y reducción de los accidentes viales, la capacidad de probar y validar conceptos clave antes de una implementación completa resulta esencial. El enfoque de prototipado y evaluación a lo largo del proceso contribuye a la reducción de la probabilidad de errores costosos y garantiza que el sistema final cumpla de manera efectiva con sus objetivos.

En el contexto del desarrollo del proyecto, se han identificado varios incrementos esenciales. Cada uno desempeña un papel crítico en la consecución de los objetivos del sistema de semaforización inteligente. Estos incrementos se presentan como etapas cruciales que se han diseñado para abordar los desafíos técnicos y conceptuales clave.

2.1. Incremento 1

En la fase inicial, se realizaron los análisis pertinentes para la gestión y planificación del proyecto. Se definieron el alcance y los objetivos fundamentales del sistema. Se llevaron a cabo investigaciones sobre tecnologías relevantes para la detección de vehículos mediante visión por computadora, así como la selección del lenguaje de programación adecuado a las necesidades del proyecto y la identificación de servicios y bibliotecas útiles.

Además, se establecieron las necesidades del sistema, como contar con una cámara disponible, un modelo de detección vehicular y un algoritmo de coordinación basado en demanda.

2.2. Incremento 2

En esta fase se llevó a cabo la obtención de imágenes que representan vehículos típicamente presentes en las calles de la ciudad de Salta. Este paso resulta esencial para la creación de modelos de detección de estas entidades, permitiendo la construcción de un sistema experto capaz de identificar estos objetos mediante el procesamiento de imágenes. Además, se efectuó un análisis exhaustivo de las imágenes adquiridas para garantizar el aprendizaje efectivo del modelo.

Una vez obtenidas las imágenes de entrenamiento, se realizaron las notaciones correspondientes para que el modelo aprenda los patrones relevantes, al registrar cinco atributos por cada detección realizada:

- » *class*: entero que representa la clase del objeto;
- » *x-center*: la coordenada en x de la caja de detección normalizada por el ancho de la imagen;
- » *y-center*: la coordenada en y de la caja de detección normalizada por el alto de la imagen;
- » *width*: ancho de la caja de detección;
- » *height*: alto de la caja de detección.



Figura 3: Clasificación por color de autos (azul) y camionetas (naranja)

A partir de este análisis, se obtuvieron las siguientes notaciones:

```
0 0.251415 0.265886 0.412736 0.430006
0 0.756722 0.238413 0.392689 0.413284
0 0.741391 0.768754 0.463443 0.456284
1 0.260259 0.773532 0.442217 0.441951
```

Figura 4: Notaciones obtenidas

2.3. Incremento 3

Durante esta etapa, se alimentó el sistema con las imágenes recopiladas en el segundo incremento. La creación de este modelo de detección se basó en el empleo del algoritmo *You Only*

Look Once. Este algoritmo se especializa en la detección de objetos en tiempo real, al emplear una única red neuronal convolucional con el fin de identificar objetos en imágenes. La implementación de este modelo constituye un pilar fundamental para el reconocimiento efectivo de vehículos en tiempo real.



Figura 5: Vehículos estáticos detectados por el modelo



Figura 6: Vehículos en movimiento detectados por el modelo

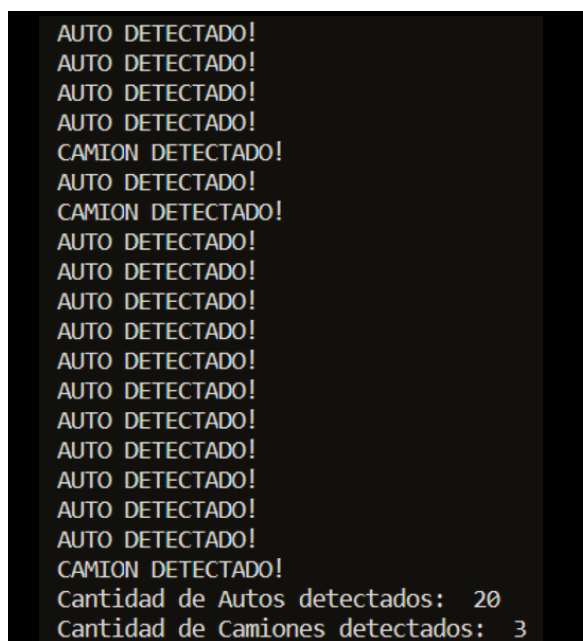


Figura 7: Resultados obtenidos de la detección

2.4. Incremento 4

En esta etapa se utilizó el modelo de detección en una situación vial real para detectar posibles falencias del modelo y hacer los ajustes necesarios.



Figura 8: Ejemplo del video analizado




Figura 9: Video procesado

En el video procesado observamos que el modelo detecta camiones y otras entidades como autos o tapa de alcantarilla. Esto puede deberse a la falta de instancias de otras clases y la falta de un filtro de confianza, es decir, que solo detecte los objetos que cumplan con cierto nivel de *accuracy*, por ejemplo, del 70 %. Además, es necesario que el modelo no detecte solo a autos, ya que puede ser información valiosa saber si hay otros tipos de vehículos, como camiones.

Luego de ajustar el filtro de confianza y agregar más instancias del tipo “camión”:




Figura 10: Ajuste del filtro

En esta detección se puede ver que el modelo ya no detecta la tapa de alcantarilla como entidad. Además, detecta a los camiones como tales en lugar de “autos”.

2.5. Incremento 5

En el quinto incremento, se abordó el desarrollo de un sistema que permitiera la generación aleatoria de entidades en dos instancias independientes. Este proceso simula la llegada de vehículos a una intersección, al considerar que la llegada de vehículos en dos calles es un proceso independiente y paralelo. Se diseñó un algoritmo específico para coordinar estas entidades con el propósito de maximizar el flujo vehicular y minimizar el tiempo de espera promedio. Con base en la cantidad de vehículos detectados en ambos sistemas, se calcula el tiempo necesario en cada intersección.

El algoritmo consta de dos procesos paralelos. Ambos procesos generan una cantidad aleatoria de entidades (entre una y cinco) cada un tiempo aleatorio (entre un y quince minutos). Según la cantidad de entidades generadas por cada proceso se otorgan las prioridades y se calcula el tiempo estimado necesario para que cada sentido se vacíe.

A partir de las detecciones obtenidas por el modelo, se utilizan como datos de entrada para el algoritmo de coordinación, suministrando datos sobre la presencia de vehículos en tiempo real. El algoritmo realiza la asignación óptima de prioridad en un semáforo específico, al indicar el tiempo ideal en el que el semáforo debe permanecer en estado “verde”.

Cada uno de estos incrementos se presenta como un paso crítico en el proceso de desarrollo del sistema de semaforización inteligente, juega un papel esencial en el logro de los objetivos de reducción de la congestión vehicular y mejora de la seguridad vial en la provincia de Salta.

4. Resultados

4.1. Modelo de detección

El modelo obtenido se puso en prueba mediante el análisis de un video obtenido desde el punto de vista de un semáforo a fin de comprobar la correcta detección de entidades viales por parte del modelo, a continuación, se muestran los reconocimientos hechos a lo largo del video.




Figura 11: Análisis del video desde el punto de vista de un semáforo

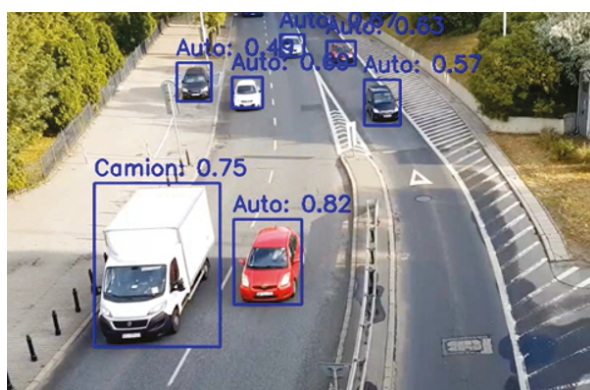


Figura 12: Análisis del video desde el punto de vista de un semáforo




Figura 13: Detección correcta de autos y camiones

Se puede observar que el modelo detecta de forma correcta cada tipo de entidad (auto y camión) con buenos niveles de confianza y, además, no detecta entidades de manera errónea, como previamente lo hacía.

4.2. Algoritmo de coordinación

En cuanto a los datos obtenidos por el algoritmo de coordinación:

```

Autos en A: 5
Autos en B: 0
Semaforo en verde: A
Tiempo semáforo: 15 segundos
La hora actual es: 31:48
=====
Autos en A: 0
Autos en B: 3
Semaforo en verde: B
Tiempo semáforo: 9 segundos
La hora actual es: 32:03
=====
Autos en A: 2
Autos en B: 0
Semaforo en verde: A
Tiempo semáforo: 6 segundos
La hora actual es: 32:12
=====
Autos en A: 1
Autos en B: 0
Semaforo en verde: A
Tiempo semáforo: 3 segundos
La hora actual es: 32:29
=====
Autos en A: 0
Autos en B: 5
Semaforo en verde: B
Tiempo semáforo: 15 segundos
La hora actual es: 32:32
=====

```

Figura 14: Resultados obtenidos

En la Figura 14 se puede apreciar la demanda del semáforo. Se ve que este asigna prioridades de manera alternada durante las tres primeras iteraciones, pero en la cuarta vuelve a asignarle la prioridad a "A", ya que no hay autos en la dirección "B".

Además, se puede ver la se da en la asignación de tiempos variables sobre los semáforos por tiempos fijos, el algoritmo calcula el tiempo necesario para vaciar de autos un sentido y le asigna ese tiempo en verde. Una vez que finaliza este tiempo vuelve a verificar cuál es la necesidad de cada sentido y a calcular las prioridades.

5. Conclusión

El uso del modelo YOLOv5, junto con OpenCV, ha demostrado ser altamente eficaz en la detección precisa de vehículos en tiempo real, lo que permite una coordinación dinámica de los semáforos según la demanda actual del tráfico y, en consecuencia, una reducción significativa de la congestión vehicular. Los resultados obtenidos en entornos controlados muestran un gran potencial para su implementación en escenarios urbanos reales, donde estos sistemas pueden adaptarse y escalarse a fin de ofrecer soluciones efectivas y sostenibles en la gestión del tráfico en ciudades en crecimiento. Además, la evolución continua de la tecnología y los algoritmos de detección sugieren que estos sistemas no solo mejorarán la eficiencia del tráfico a corto plazo, sino que también contribuirán al desarrollo de futuras soluciones avanzadas para la gestión del tráfico urbano.

Referencias

- [1] A. M. Monterrey Cañas, C. A. Sosa Ramírez, y M. A. Jinete Gómez, "Diseño de un sistema de semaforización inteligente para controlar flujo vehicular a partir de procesamiento de imágenes," 2020.
- [2] W. Hu y J. B. Cicchino, "Effects of Turning on and off Red-light Cameras on Fatal Crashes in Large U.S. Cities," *Journal of Safety Research*, vol. 61, pp. 141–148, 2017.
- [3] J. Redmon, S. Divvala, R. Girshick, y A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," en *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2016-December, pp. 779–788, 2015. Disponible en: <https://doi.org/10.1109/CVPR.2016.91>.
- [4] K. O'Shea y R. Nash, "An Introduction to Convolutional Neural Networks," *International Journal for Research in Applied Science and Engineering Technology*, vol. 10, no. 12, pp. 943–947, 2015. Disponible en: <https://doi.org/10.22214/ijraset.2022.47789>.