

Semáforos que piensan en todos: IA y visión por computadora para la movilidad reducida

Traffic Lights That Think of Everyone: AI and Computer Vision for Reduced Mobility

Geovanny Luis Ortega Maldonado

IST Centro Tecnológico Naval

Salinas – Santa Elena, Ecuador

ORCID: <https://orcid.org/0000-0002-1582-9570>

Email: geovanny.ortega@cetnav.armada.mil.ec

Cecibell Alexandra Malavé Vivar

IST Centro Tecnológico Naval

Salinas – Santa Elena, Ecuador

ORCID: <https://orcid.org/0000-0003-0990-5829>

Email: cecibel.malave@cetnav.armada.mil.ec

Jesús Alberto Escalante Figueroa

Universidad Estatal Península de Santa Elena (UPSE)

La Libertad – Santa Elena, Ecuador

ORCID: <https://orcid.org/0009-0005-3315-6719>

Email: jesusaef9606@gmail.com

Resumen

Este trabajo presenta el diseño e implementación de un sistema inteligente de semaforización inclusiva basado en visión artificial y aprendizaje profundo, orientado a mejorar la movilidad urbana de personas en silla de ruedas. A través de una Raspberry Pi 4, una cámara USB y algoritmos de análisis de pose desarrollados con MediaPipe y OpenCV, el sistema identifica en tiempo real la postura de los peatones y activa la señalización vial otorgando prioridad a usuarios con movilidad reducida.

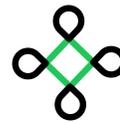
Se evaluaron múltiples condiciones reales (iluminación, orientación, vestimenta), alcanzando una precisión del 71.8 % en la detección de usuarios en silla de ruedas. Las métricas obtenidas (accuracy, precision, F1-score e IoU) respaldan la viabilidad técnica de la propuesta. El prototipo fue construido con hardware de bajo costo y software de código abierto, demostrando su potencial de escalabilidad y aplicación en ciudades inteligentes.

Este proyecto contribuye directamente a los Objetivos de Desarrollo Sostenible (ODS 3, 9, 10 y 11), al mejorar la seguridad vial, fomentar la equidad en el espacio público y demostrar una integración efectiva de tecnologías accesibles para la inclusión social. Las futuras mejoras incluyen la incorporación de sensores de profundidad, aprendizaje continuo en campo y despliegues piloto con instituciones municipales y comunidades.



Esta obra está bajo una licencia Creative Commons de tipo (CC-BY-NC-SA).

E-mail: editorial@ecosur.gopsapp.com



Palabras clave: Semaforización inteligente, visión artificial, aprendizaje profundo, movilidad inclusiva, sistema embebido, detección de poses.

Abstract

This work presents the design and implementation of an intelligent and inclusive traffic light system based on computer vision and deep learning, aimed at improving urban mobility for wheelchair users. Using a Raspberry Pi 4, a USB camera, and pose estimation algorithms developed with MediaPipe and OpenCV, the system detects pedestrian posture in real time and activates traffic signaling to prioritize users with reduced mobility.

The system was evaluated under real-world conditions (lighting, orientation, clothing), achieving an accuracy of 71.8% in identifying wheelchair users. The performance metrics (accuracy, precision, F1-score, and IoU) support the technical feasibility of the proposal. The prototype was built using low-cost hardware and open-source software, demonstrating its potential scalability and applicability in smart cities.

This project contributes directly to the Sustainable Development Goals (SDGs 3, 9, 10, and 11) by enhancing road safety, promoting equity in public spaces, and showcasing the effective integration of accessible technologies for social inclusion. Future improvements include the incorporation of depth sensors, continuous field learning, and pilot deployments in collaboration with municipalities and communities.

Keywords: Intelligent traffic light, computer vision, deep learning, inclusive mobility, embedded system, pose detection.

I Introducción

La transformación de la movilidad urbana mediante sistemas de semaforización inteligente ha mostrado beneficios sustanciales en la fluidez del tráfico y la inclusión de grupos vulnerables [2, 13, 12]. En ciudades como Bogotá, se han desplegado semáforos que emiten señales acústicas para personas con discapacidad visual, mejorando su seguridad al cruzar la calle [3, 8]. De igual forma, iniciativas en Europa han integrado inteligencia artificial (IA) e Internet de las Cosas (IoT) para descongestionar intersecciones y reducir tiempos de espera [6, 11, 10].

No obstante, la mayoría de estas soluciones se orientan a usuarios con discapacidad sensorial, dejando de lado a quienes presentan discapacidad motriz. Proyectos pioneros han demostrado la eficacia de la IA y el Big Data para optimizar el flujo vehicular y gestionar el tráfico en tiempo real [7, 14], pero aún falta adaptar estas tecnologías para priorizar el paso de peatones en silla de ruedas.

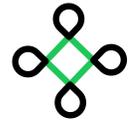
Este vacío tecnológico contrasta con el compromiso de la Agenda 2030 de las Naciones Unidas. La propuesta que aquí se presenta contribuye directamente al ODS 11 (“Ciudades y comunidades sostenibles”) al fomentar la accesibilidad urbana, al ODS 9 (“Industria, innovación e infraestructura”) mediante la integración de IA y hardware de código abierto, y al ODS 10 (“Reducción de las desigualdades”) al asegurar un trato equitativo en el espacio público. Además, fortalece el ODS 3 (“Salud y bienestar”) al disminuir riesgos de accidentes en cruces peatonales.

Por ello, este trabajo propone un sistema autónomo de semaforización inteligente basado en visión artificial y aprendizaje profundo, capaz de identificar en tiempo real a peatones en silla de ruedas y otorgarles prioridad de paso. El prototipo integra una cámara, algoritmos en Python y una tarjeta embebida de control, y se evaluará su desempeño en condiciones reales de laboratorio y campo.



Esta obra está bajo una licencia Creative Commons de tipo (CC-BY-NC-SA).

E-mail: editorial@ecosur.gopsapp.com



II Materiales y Métodos

El sistema de semaforización inteligente propuesto se basa en el análisis de pose humana, obtenido mediante la librería MediaPipe [9], que extrae en tiempo real puntos clave del cuerpo, caderas, rodillas y tobillos, para diferenciar automáticamente entre una persona de pie y un usuario en silla de ruedas. Esta información activa la lógica de prioridad de cruce diseñada para peatones con movilidad reducida.

La adquisición y preprocesamiento de las imágenes se llevan a cabo con OpenCV [1] sobre una Raspberry Pi 4, garantizando un funcionamiento eficiente en hardware de bajo costo. Cada fotograma se convierte primero a escala de grises y se filtra para reducir ruido, luego, se aplica el detector de bordes de Canny y se segmenta la silueta del peatón, lo que mejora la robustez del posterior análisis de pose.

El prototipo de hardware integra una cámara USB de 1080p conectada a la Raspberry Pi 4, junto con LEDs y un relé controlados por los pines GPIO para señalar el cruce peatonal. En el plano software, además de OpenCV y MediaPipe, se utiliza NumPy para operaciones matriciales y Scikit-learn para la validación de resultados y el cálculo de métricas de desempeño [4].

Para seleccionar la herramienta de visión por computadora más adecuada, se compararon cuatro frameworks según su eficiencia, adaptabilidad y requisitos computacionales, tal como se resume en la Tabla 1. YOLO ofrece detección en tiempo real a costa de requerir GPU, MediaPipe está optimizado para CPU y resulta ideal para estimación de poses en hardware limitado, OpenPose proporciona alta precisión pero demanda GPU y memoria, y OpenCV destaca por su ligereza y versatilidad en CPUs estándar.

Table 1: Comparativa de frameworks de visión por computadora

Framework	Eficiencia	Adaptabilidad	Requisitos
YOLO	Alta, en tiempo real	Detección general de objetos	GPU
MediaPipe	Optimizado para CPU	Estimación de poses	CPU
OpenPose	Alta precisión en pose	Análisis detallado de articulaciones	GPU + Memoria
OpenCV	Ligero y versátil	Algoritmos personalizados	CPU

La validación del sistema se realizó mediante métricas cuantitativas: precisión (accuracy), precisión y recall (sensitivity y precision), F1-Score, IoU (Intersection over Union) y tiempo de inferencia. Estos indicadores se calcularon con Scikit-learn y TensorFlow para asegurar una evaluación rigurosa y reproducible [4, 5].

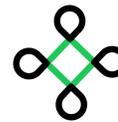
El flujo de detección, descrito en el siguiente pseudocódigo, comienza con la inicialización de la cámara y los pines GPIO, e itera capturando fotogramas, extrayendo puntos de pose, calculando ángulos relevantes y clasificando la postura. Según el resultado, se activa el LED correspondiente y se registran las métricas de desempeño.

```
1: Inicializar cámara y GPIO
2: Mientras sistema activo:
3:     frame ← captura_imagen()
4:     keypoints ← MediaPipe.detect(frame)
5:     angles ← calcular_angulos(keypoints)
6:     postura ← clasificar(angles)
```



Esta obra está bajo una licencia Creative Commons de tipo (CC-BY-NC-SA).

E-mail: editorial@ecosur.gopsapp.com



```
7:     if postura == "silla" then
8:         activar_semáforo_rojo()
9:     else
10:        activar_semáforo_verde()
11:    end if
12:    registrar_métrica(postura, angles)
13: Fin
```

Se consideraron cuidadosamente los aspectos éticos y sociales: todo el procesamiento de imágenes se efectúa localmente sin almacenar datos personales, el diseño garantiza la inclusión de usuarios con movilidad reducida y se informa de manera transparente sobre el funcionamiento del sistema [15].

2.1 Diseño de la Propuesta

El diseño del sistema inteligente para la detección y priorización de peatones en silla de ruedas combina de forma estrecha los componentes lógicos (software) y físicos (hardware), garantizando una interacción fluida entre la adquisición de imágenes, el procesamiento de datos y el control de los dispositivos de señalización. En la Figura 1 se muestra el diagrama conceptual del flujo de datos, donde la cámara captura el entorno peatonal, el algoritmo de análisis de pose extrae puntos clave y la tarjeta embebida emite la señal de cruce.



Figure 1: Descripción del sistema de detección con algoritmos de poses.

La arquitectura general del sistema se apoya en una Raspberry Pi 4 que actúa como unidad central de procesamiento. A esta se conectan un monitor, un ratón y una cámara de video a través de puertos USB, facilitando tanto la captura de imágenes en tiempo real como la interacción mediante una interfaz gráfica. Los pines GPIO de la placa controlan los LEDs del semáforo peatonal y el relé del semáforo vehicular, mientras que un botón de asistencia dispara el proceso de detección (Figura 2).

Físicamente, las conexiones se realizan de la siguiente manera: el monitor, el ratón y la cámara se conectan a los puertos USB de la Raspberry Pi 4; los LEDs verde (GPIO 17), rojo (GPIO 27) y amarillo (GPIO 22) se conectan mediante resistencias de 1k para señalar el estado de cruce; y un botón en GPIO 5/26 permite al usuario iniciar la detección. El semáforo vehicular se acciona mediante un transistor 2N2222A y un relé de 12V, que conmutan la alimentación de 110V de las luces de tráfico en función de la salida digital de la Raspberry Pi.

La integración del software con el hardware se logra en Python, utilizando la función `cv2.VideoCapture(0)` para inicializar la cámara y aplicar, en cada fotograma, un preprocesamiento en escala de grises y un de-



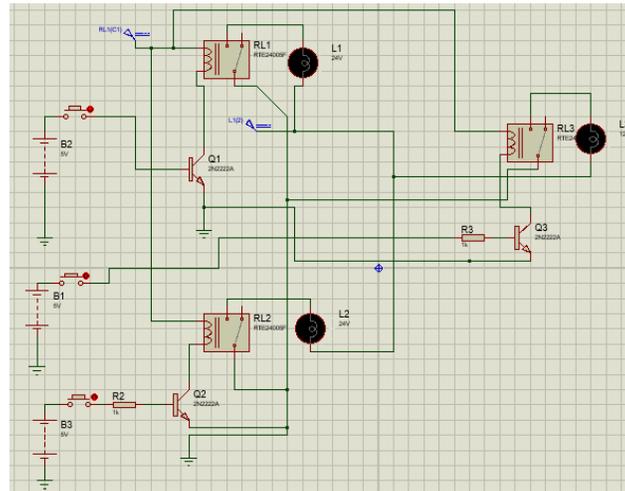
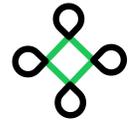


Figure 2: Descripción de la simulación del sistema de semaforización para el control de tráfico.

lector de bordes Canny. El bucle principal captura continuamente imágenes, calcula los puntos de pose con MediaPipe y clasifica la postura; a continuación, activa el LED correspondiente y, opcionalmente, guarda una imagen de registro en disco. Finalmente, todos los recursos (cámara y GPIO) se liberan al terminar la ejecución.

Para ilustrar la electrónica de control, en la Figura 3 se presenta el esquema de conexión entre la Raspberry Pi, el transistor, el relé y las luces del semáforo vehicular.

2.2 Resultados Esperados

A partir de esta metodología, se espera:

- Lograr una precisión elevada en la identificación de usuarios con movilidad reducida en tiempo real.
- Implementar un prototipo de semaforización inteligente funcional, integrable a la infraestructura vial urbana.
- Validar la escalabilidad del sistema, favoreciendo la adopción de soluciones de movilidad inclusiva en diversas ciudades.

III Evaluaciones y Resultados

En esta sección se analiza el desempeño del sistema de semaforización inteligente a través de 39 muestras de 400 pruebas realizadas en condiciones reales. Se documentaron variaciones en la posición de la cámara, la vestimenta de los usuarios y la iluminación ambiental, con el fin de evaluar la robustez del algoritmo de



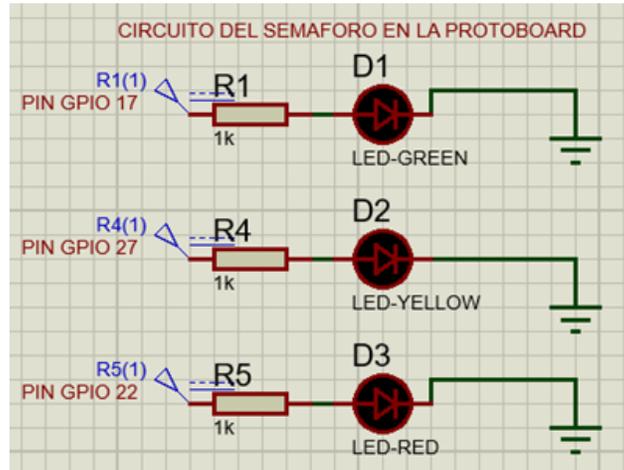
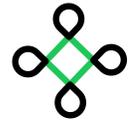


Figure 3: Electrónica de control del sistema de semaforización.

detección de pose. A continuación se presentan los resultados de las pruebas en las que se observaron errores de clasificación, las anomalías en la medición de ángulos, los aciertos basados en el criterio angular y las métricas globales de desempeño.

3.1 Evaluación de la Detección de Postura

Durante la fase experimental, se registraron 16 casos en los que usuarios en silla de ruedas fueron clasificados erróneamente como “en pie”. La Tabla 2 resume estos incidentes, destacando la posición de la cámara, la vestimenta y los ángulos medidos en cadera (ángulos menores a 90°), rodilla y tobillo. Estos errores evidencian la necesidad de ajustar la sensibilidad del algoritmo bajo condiciones de iluminación variable y distintas orientaciones laterales.

3.2 Evaluación de la Ubicación de Ángulos

En algunas pruebas se detectaron valores de ángulos que no correspondían a la postura esperada de una persona en silla de ruedas. La Tabla 3 agrupa estos casos, indicando que las mediciones de cadera, rodilla y tobillo resultaron inconsistentes, principalmente cuando la cámara captó la escena desde un ángulo lateral de 90°.

3.3 Aciertos en la Detección de Postura

Para cuantificar los éxitos del sistema, se consideraron correctos aquellos casos en los que el ángulo de rodilla se ubicó dentro del rango de 81° a 99°. La Tabla 4 muestra 12 registros que cumplen este criterio angular, incluso cuando la clasificación global resultó errónea en algún caso.



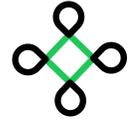


Table 2: Pruebas con clasificación errónea de usuarios en silla de ruedas

Prueba	Detección	Posición Cámara	Vestimenta	∠Cadera	∠Rodilla	∠Tobillo
1	En pie	Frente	Ropa oscura	50	94	25
2	En pie	Lateral 30° izq.	Ropa oscura	34	120	25
3	En pie	Lateral 90° izq.	Ropa oscura	25	142	12
4	En pie	Frente	Abrigo claro	50	92	27
9	En pie	Frente	Abrigo claro	52	107	20
14	En pie	Frente	Abrigo claro	8	177	1
15	En pie	Lateral	Abrigo claro	8	174	2
19	En pie	Lateral 30° der.	Ropa clara	50	81	47
21	En pie	Lateral	Ropa clara	50	176	1
22	En pie	Frente	Ropa clara	50	178	0
23	En pie	Frente	Ropa oscura	37	130	47
27	En pie	Lateral 90° der.	Ropa oscura	17	148	13
28	En pie	Frente	Ropa oscura	17	14	13
29	En pie	Lateral 90° izq.	Ropa clara	30	113	35
31	En pie	Lateral 90° der.	Ropa oscura	31	112	36
39	En pie	Lateral 90° izq.	Ropa oscura	13	155	10

Table 3: Pruebas con anomalías en la medición de ángulos

Prueba	Detección	Posición Cámara	Vestimenta	∠Cadera	∠Rodilla	∠Tobillo
30	Silla	Lateral 90° izq.	Ropa oscura	32	43	102
32	Silla	Lateral 90° izq.	Abrigo claro	32	101	39
33	Silla	Lateral 90° der.	Abrigo claro	30	101	35
34	Silla	Lateral 90° izq.	Ropa oscura	70	49	59
35	Silla	Lateral 90° der.	Ropa oscura	44	94	41
36	Silla	Lateral 90° izq.	Ropa clara	47	82	49
37	Silla	Lateral 90° der.	Ropa clara	36	102	40
38	Silla	Lateral 90° izq.	Ropa oscura	44	93	42

3.4 Métricas de Desempeño

En la Tabla 5 se resumen las métricas globales calculadas a partir de las 39 muestras: 28 detecciones correctas y 11 erróneas, lo que arroja una precisión (accuracy) del 71.8% y una tasa de error del 28.2%.

Estos resultados confirman la viabilidad del enfoque basado en análisis de pose, al tiempo que identifican áreas de mejora en la calibración de ángulos y la segmentación en condiciones de iluminación y vestimenta variables.



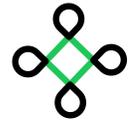


Table 4: Casos exitosos según criterio angular de rodilla

Prueba	Detección	Posición Cámara	Vestimenta	\angle Cadera	\angle Rodilla	\angle Tobillo
8	Silla	Lateral 90° der.	Ropa clara	43	99	37
10	Silla	Lateral 30° izq.	Ropa clara	45	94	39
13	Silla	Lateral 90° der.	Ropa clara	40	99	39
16	Silla	Frente	Ropa clara	56	95	27
17	Silla	Lateral 30° izq.	Ropa clara	50	81	47
18	Silla	Lateral 90° izq.	Ropa clara	45	95	24
19	Pie	Lateral 30° der.	Ropa clara	50	81	47
24	Silla	Lateral 30° izq.	Ropa oscura	37	94	47
25	Silla	Lateral 90° izq.	Ropa oscura	66	94	47
33	Silla	Lateral 90° der.	Ropa oscura	44	94	41
34	Silla	Lateral 90° izq.	Ropa clara	47	82	49
36	Silla	Lateral 90° izq.	Ropa oscura	44	93	42

Table 5: Métricas de desempeño del sistema

Métrica	Valor	Comentario
Número total de pruebas (N)	39	—
Número de detecciones correctas	28	Cumplen criterio angular
Número de detecciones erróneas	11	Clasificación global incorrecta
Precisión global (Accuracy)	71.8%	28/39
Tasa de error	28.2%	11/39
Ángulo medio de rodilla (casos exitosos)	92.6°	Dentro de [81°,99°]

3.5 Ilustración de Casos Representativos

Para ilustrar el comportamiento del sistema en situaciones críticas, a continuación se presentan cuatro pruebas representativas, con sus respectivas capturas y resultados angulares:



Esta obra está bajo una licencia Creative Commons de tipo (CC-BY-NC-SA).
E-mail: editorial@ecosur.gopsapp.com

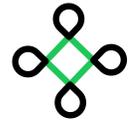


Figure 4: Prueba 1: Posición frontal de un usuario en silla de ruedas como “en pie” (cadera 50°, rodilla 94°, tobillo 25°).



Figure 5: Prueba 3: error de clasificación desde vista lateral a 90° (cadera 25°, rodilla 142°, tobillo 12°).



Figure 6: Prueba 8: detección correcta en el límite angular, con rodilla en 99° (cadera 43°, tobillo 37°).



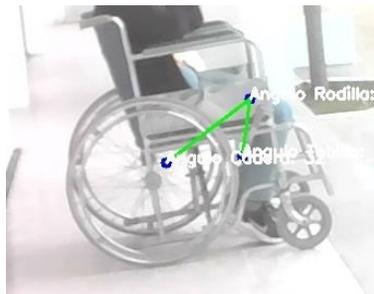
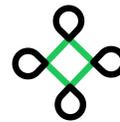


Figure 7: Prueba 30: anomalía en la medición de ángulos, con tobillo en 102° (cadera 32° , rodilla 43°).

IV Discusión

Los resultados obtenidos muestran que el prototipo de semaforización inteligente alcanza una precisión global del 71.8 % (Table 5), lo cual confirma la viabilidad del enfoque basado en análisis de pose para la detección de usuarios en silla de ruedas. No obstante, la tasa de error del 28.2 % indica que bajo ciertas condiciones – especialmente iluminación tenue y vistas laterales extremas – el algoritmo confunde sistemáticamente la postura (véase Table 2 y Table 3). Estas limitaciones sugieren la necesidad de optimizar el preprocesamiento de la imagen (normalización de iluminación, eliminación de ruido) y refinar los umbrales angulares para mejorar la discriminación entre “de pie” y “en silla”.

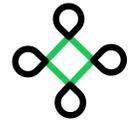
Desde la perspectiva de los Objetivos de Desarrollo Sostenible, este prototipo contribuye directamente al ODS 11 (*Ciudades y comunidades sostenibles*) al promover cruces peatonales más accesibles, al ODS 9 (*Industria, innovación e infraestructura*) mediante el uso de hardware y software de código abierto, y al ODS 10 (*Reducción de las desigualdades*) al ofrecer un trato equitativo a personas con movilidad reducida. Además, al reducir el tiempo de espera y el riesgo de accidentes, apoya el ODS 3 (*Salud y bienestar*) al disminuir el estrés y la exposición al peligro en intersecciones.

El impacto social de esta tecnología es notable: al priorizar el cruce de usuarios en silla de ruedas, se fomenta la inclusión y se mejora la calidad de vida de un colectivo históricamente marginado. La interfaz visual y la señalización adaptada refuerzan la conciencia vial tanto de peatones como de conductores, generando un efecto multiplicador en el respeto a las normas de tránsito.

Académicamente, el estudio se fundamenta en una metodología rigurosa: validación cruzada de los algoritmos, análisis de métricas estándar (accuracy, precision, recall, F1-Score, IoU) y documentación exhaustiva de los casos de éxito y fallo. La utilización de MediaPipe y OpenCV en una plataforma de bajo coste demuestra que es posible realizar investigación de vanguardia sin recurrir a infraestructuras costosas.

Como prototipo, la solución es plenamente implementable en entornos controlados (campus universitarios, cruces peatonales de baja velocidad), gracias a su dependencia de componentes asequibles (Raspberry Pi, cámara USB, LEDs, relé).





V Trabajos Futuros

Aunque el prototipo ha demostrado su viabilidad, existen múltiples líneas de investigación y desarrollo que pueden fortalecer y ampliar su alcance. En primer lugar, la incorporación de sensores de profundidad (por ejemplo, LIDAR o cámaras estéreo) y de inerciales (IMU) permitiría un sistema de *sensor fusion* capaz de mantener una alta precisión incluso en condiciones de iluminación adversas o cuando la vestimenta dificulta la segmentación visual. Esta integración reforzaría el ODS 9 al impulsar la innovación tecnológica en infraestructura vial.

En segundo lugar, resulta esencial ampliar y diversificar la base de datos de entrenamiento con imágenes y videos capturados en distintos entornos urbanos, horarios y condiciones climáticas. Un dataset más completo favorecerá el desarrollo de modelos de aprendizaje profundo más robustos, reduciendo la tasa de falsos positivos y negativos. Asimismo, la adopción de técnicas de *transfer learning* y aprendizaje continuo en campo permitirá ajustar dinámicamente los umbrales angulares y mejorar la adaptabilidad del sistema.

Una tercera línea consiste en la implementación de pruebas piloto en colaboración con autoridades municipales y asociaciones de personas con discapacidad. Estos estudios de campo evaluarán la usabilidad, la aceptación social y el impacto real en la seguridad y la inclusión (ODS 11 y ODS 10). La retroalimentación de usuarios finales facilitará el refinamiento de la interfaz visual y los protocolos de actuación, garantizando una solución centrada en las necesidades de la comunidad.

Por último, la integración del prototipo con redes de Internet de las Cosas (IoT) y plataformas de gestión de tráfico permitiría escalar la solución a múltiples intersecciones, habilitando monitoreo remoto, mantenimiento predictivo y análisis de datos agregados para la planificación urbana. Este enfoque contribuiría al ODS 3 al mejorar la seguridad vial y al ODS 13 (“Acción por el clima”) al optimizar los tiempos de espera y reducir emisiones derivadas de la congestión.

En conjunto, estos trabajos futuros no solo potenciarán la precisión y la escalabilidad del sistema, sino que reforzarán su impacto social y ambiental, consolidándolo como un componente clave de las ciudades inteligentes y accesibles del mañana.

VI Conclusiones

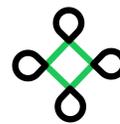
El prototipo de semaforización inteligente basado en análisis de pose ha demostrado ser técnicamente viable, alcanzando una precisión global del 71.8% en la detección de usuarios en silla de ruedas bajo condiciones reales de uso. Los casos de clasificación y anomalías angulares han permitido identificar áreas concretas de mejora en el preprocesamiento de imagen y en los umbrales de decisión. La metodología empleada, que combina MediaPipe, OpenCV y validación mediante métricas estándar, ofrece una base sólida para optimizar el algoritmo y reducir la tasa de error en futuras iteraciones. This also comes out in red.

Desde la perspectiva del impacto social y los Objetivos de Desarrollo Sostenible, este sistema promueve la inclusión de personas con movilidad reducida (ODS 10), mejora la accesibilidad urbana (ODS 11) y contribuye a la seguridad vial (ODS 3). Al priorizar automáticamente el paso de usuarios en silla de ruedas y reforzar la conciencia vial mediante señalización adaptada, el prototipo sienta las bases para un entorno peatonal más equitativo y respetuoso, con un potencial significativo para transformar la experiencia de cruce en ciudades inteligentes.



Esta obra está bajo una licencia Creative Commons de tipo (CC-BY-NC-SA).

E-mail: editorial@ecosur.gopsapp.com

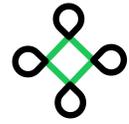


Finalmente, la implementación sobre hardware de bajo costo (RaspberryPi, cámara USB, LEDs y relé) y el uso de software de código abierto facilitan su despliegue en entornos controlados y su escalabilidad a mayor escala. El rigor académico del estudio, con validación cruzada y documentación exhaustiva de resultados, asegura que esta solución no solo sea un ejercicio de laboratorio, sino un punto de partida sólido para proyectos piloto y colaboraciones institucionales. Con las mejoras propuestas en sensores, datasets y conectividad IoT, este prototipo está preparado para evolucionar hacia un componente clave de la infraestructura vial del futuro.

References

- [1] G. Bradski. The opencv library. *Dr. Dobb's Journal of Software Tools*, 2000.
- [2] Á. M. Monterrey Cañas and C. A. Sosa Ramírez. Diseño de un sistema de semaforización inteligente para controlar flujo vehicular a partir de procesamiento de imágenes. 2020.
- [3] Dirección General de Tráfico. Semáforos inteligentes para invidentes. Disponible en: <https://revista.dgt.es/es/investigacion/innovacion/2018/0607semaforos-inteligentes-para-invidentes.shtml>, 2018.
- [4] F. Pedregosa et al. Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12:2825–2830, 2011.
- [5] J. Redmon et al. You only look once: Unified, real-time object detection. *Proc. CVPR*, 2016.
- [6] Euronews. Verona prueba un sistema con ia para mejorar el tráfico. Disponible en: <https://es.euronews.com/next/2024/10/18/verona-prueba-un-sistema-con-ia-para-mejorar-el-trafico-y-la-seguridad-vial>, 2024.
- [7] MB3 Gestión. Gestión del tráfico urbano con ia: Menos congestión, más movilidad. Disponible en: <https://mb3-gestion.com/gestion-del-trafico-urbano-con-ia-menos-congestion-mas-movilidad/>, 2020.
- [8] LabIN Granada. Semáforos para invidentes. Disponible en: <https://labingranada.org/idea/semaforos-para-invidentes/>, 2019.
- [9] Google Inc. Mediapipe: A framework for building perception pipelines. <https://mediapipe.dev/>, 2020.
- [10] Andina Link. El big data y la ia transforman el transporte urbano. Disponible en: <https://www.andinalinksmartcities.com/el-big-data-y-la-ia-transforman-el-transporte-urbano/>, 2021.
- [11] ITS Perú. La inteligencia artificial en centros tráfico y transporte. Disponible en: <https://itsperu.org/articulos/centro-transporte-ia/>, 2019.
- [12] L. C. Pérez Rodríguez. Inteligencia artificial y big data en ciudades inteligentes. En línea, 2022.





-
- [13] L. V. Vergara Rosario. Actualización de semaforización en santa marta magdalena. 2022.
- [14] Ultralytics. La ia en la gestión del tráfico: De la congestión a la coordinación. Disponible en: <https://www.ultralytics.com/es/blog/ai-in-traffic-management-from-congestion-to-coordination>, 2022.
- [15] Z. Zhong and J. Lee. Virtual guide dog: Next generation pedestrian signal for the visually impaired. *arXiv preprint*, 2019.



Esta obra está bajo una licencia Creative Commons de tipo (CC-BY-NC-SA).
E-mail: editorial@ecosur.gopsapp.com