

## MEDICIÓN DEL FLUJO DE PERSONAS PARA CONTROLAR LA ILUMINACIÓN Y CLIMATIZACIÓN DE EDIFICIOS

*Isidro Robledo Vega, David A. Olivas Gutiérrez, Carmen L. García Mata, Pedro R. Márquez Gutiérrez, Rogelio E. Baray Arana*

Tecnológico Nacional de México / Instituto Tecnológico de Chihuahua  
División de Estudios de Posgrado e Investigación  
Ave. Tecnológico #2909, Col. 10 de mayo, Chihuahua, México  
Tel. +52(614)201-2014

[isidro.rv, carmen.gm, pedro.mg, rogelio.ba]@chihuahua.tecnm.mx, david.a.olivas.g@gmail.com

### RESUMEN.

Los edificios inteligentes proporcionan entornos confortables a las personas que los habitan y reducen el gasto energético. La medición del flujo de personas dentro de un edificio es importante para el diseño de sistemas eficientes que controlan la iluminación y climatización. Se desarrolló un sistema de visión embebido para la detección y ubicación de personas dentro de un área monitoreada por cámaras de seguridad. Se utilizó un modelo pre-entrenado de una red neuronal de aprendizaje profundo para la detección de personas presentes en las imágenes de las cámaras. Se creó un mapa de flujo de personas que contiene la información del número de individuos presentes en el área monitoreada. Esta información del mapa de flujo es utilizada para controlar la iluminación y climatización del área utilizando interruptores y termostatos comandados a distancia por el sistema embebido.

**Palabras Clave:** Detección de personas, redes neuronales de aprendizaje profundo, sistemas embebidos.

### ABSTRACT.

Smart buildings provide comfortable environments for the people who inhabit them, reducing energy consumption. The measurement of the flow of people inside a building is important for the design of efficient systems that control lighting and air conditioning. An embedded vision system was developed for the detection and location of people within an area monitored by surveillance cameras. We used a pre-trained model of a deep learning neural network for people detection. A people flow map was created which contains information of the number of individuals present in the monitored area. This information from the flow map is used to control the lighting and air conditioning of the area using switches and thermostats remotely controlled by the embedded system.

**Keywords:** People detection, deep learning neural networks, embedded systems.

### 1. INTRODUCCIÓN

Los edificios inteligentes tienen funciones que generalmente se enfocan en crear entornos confortables para las personas que los habitan. Muchas de las funciones de control de sistemas de los edificios inteligentes están basadas en el monitoreo de las actividades que realizan personas dentro de estos. Si se sabe con precisión la ubicación de los usuarios de un edificio inteligente será más eficiente la administración de los sistemas

para reducir costos energéticos [1]. Por esta razón, es muy importante contar con un sistema de detección y ubicación de personas confiable.

Los sistemas de visión por computadora para la detección y ubicación de personas no requieren que los individuos porten dispositivos y pueden ser implementados utilizando las cámaras de vigilancia instaladas en los edificios. Los algoritmos tradicionales de detección y seguimiento de personas están basados en técnicas genéricas como la substracción de fondo, el cambio medio adaptativo continuo y el flujo óptico [2]. La precisión de los métodos tradicionales se ve afectada cuando las imágenes son de baja resolución o si las personas presentan oclusiones severas [3]. Algunas de las técnicas de aprendizaje superficial utilizadas para la detección de personas son el histograma de gradientes orientados (HOG) [4] en combinación con las máquinas de vectores de soporte (SVM) [5] como clasificador para mejorar los resultados, como se sugiere en [6].

El creciente desarrollo de las redes neuronales de aprendizaje profundo y su aplicación en el procesamiento de imágenes a mejorado el rendimiento de los sistemas de detección y ubicación de personas. Un ejemplo de un sistema de detección de peatones se presenta en [7], donde se utiliza el modelo de red de aprendizaje profundo denominado *YOLO*, modificando su arquitectura para agregar capas intermedias que mejoran la detección de peatones. Se han realizado diferentes investigaciones [8][9][10][11] donde se comparan modelos de redes neuronales de aprendizaje profundo como *YOLO*, *YOLOv2*, *YOLOv3*, *SSD*, *R-CNN*, *Faster-RCNN*, *SSD* y *RetinaNet*, entre otros. El modelo *YOLOv3* ha demostrado ser uno de los más rápidos y precisos.

En esta investigación se desarrolló un sistema de visión por computadora para medir el flujo de movimiento de personas de un área monitoreada por cámaras de seguridad. Este sistema proporciona la posición de los individuos detectados en las secuencias de imágenes adquiridas por las cámaras de seguridad utilizando un modelo pre-entrenado de una red neuronal de aprendizaje profundo. Se construyó un Mapa de

Flujo de Personas donde se almacenan las posiciones de las personas detectadas. La información del Mapa de Flujo de Personas es utilizada para el control de iluminación y climatización del área monitoreada. El sistema fue desarrollado en lenguaje Python sobre el sistema operativo Ubuntu. Esto incluye la adquisición y procesamiento de imágenes con la librería OpenCV y la implementación del modelo YOLOv3 utilizando las librerías PyTorch[12] y CUDA[13].

## 2. DETECCIÓN Y UBICACIÓN DE PERSONAS

El sistema visión por computadora para la detección y ubicación de personas realiza el análisis de secuencias de video adquiridas por una o más cámaras de seguridad. El primer paso para detectar y ubicar a una persona dentro de un espacio con cámaras de seguridad es delimitar el área que se va a monitorear. Las cámaras deben ser colocadas de forma que cubran toda el área, evitando puntos ciegos. Para el desarrollo y pruebas del sistema se utilizaron dos cámaras de seguridad con interfaz Ethernet, pueden adquirir 30 cuadros por segundo con una resolución de 1920x1080 píxeles, fueron ubicadas en las esquinas de una habitación rectangular denominada área de prueba, como se muestra en la figura 1.

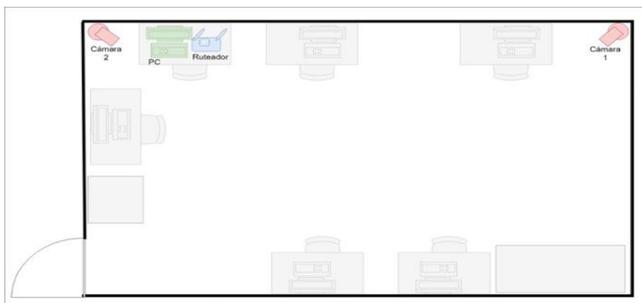


Figura 1.- Ubicación de las cámaras en el área de prueba.

Para el desarrollo del software de detección de personas se utiliza un modelo de redes neuronales de aprendizaje profundo pre-entrenado. Se hicieron las pruebas iniciales con el modelo denominado *MobileNet-SSD* [14], que es una combinación de [15] y [16], sobre la plataforma de desarrollo denominada *Caffe* [17]. El modelo fue entrenado utilizando las bases de datos *COCO* [18] y *Pascal VOC* [19]. *MobileNet-SSD* detecta y etiqueta diferentes tipos de objetos, se modificó la configuración para que solo detecte personas y regrese el rectángulo que encierra la persona detectada. Los resultados obtenidos con este modelo mostraron que detecta personas de pie, pero tiene problemas para detectar personas sentadas. Algunas veces produce recuadros que no encierran a la persona por completo y otras veces genera un doble recuadro sobre la misma persona.

Se cambió el modelo de red neuronal de aprendizaje profundo por el modelo pre-entrenado denominado *YOLOv3* [9], que trabaja sobre la plataforma de desarrollo denominada

*Darknet* [20], este modelo fue implementado utilizando funciones de la librería *CUDA* que hacen uso de procesadores gráficos o GPUs para acelerar el procesamiento. El modelo *YOLOv3* detecta personas en diferentes posturas y con menos errores que el modelo *MobileNet-SSD*. La figura 2 muestra una comparación de los resultados obtenidos los dos modelos.

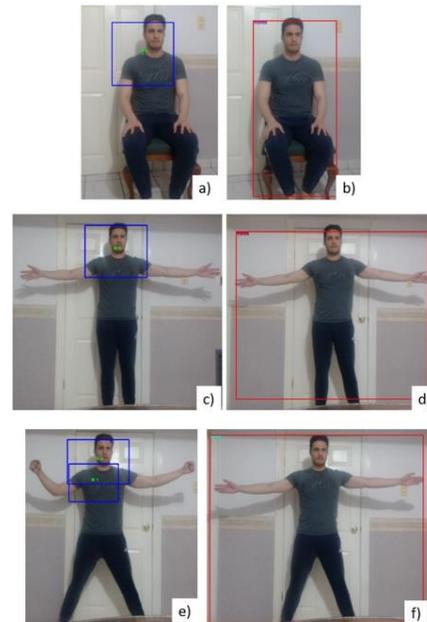


Figura 2.- Comparación de detección de personas entre *MobileNet-SSD* (a, c y e) y *YOLOv3* (b, d y f).

Para determinar la ubicación de cada persona detectada dentro del área monitoreada se establece como punto de referencia las coordenadas del pixel del centro de la base del recuadro que encierra a la persona, como se muestra en figura 3.

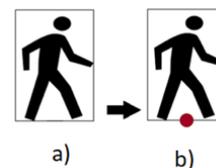


Figura 3.- a) Recuadro que encierra a la persona detectada. b) Pixel de referencia para la ubicación de la persona detectada.

## 3. MAPA DE FLUJO DE PERSONAS

La ubicación de cada persona detectada en las imágenes del área monitoreada está definida en coordenadas en píxeles. A continuación, se describe el proceso para convertir las coordenadas en píxeles a coordenadas en metros que serán utilizadas para la construcción del Mapa de Flujo de Personas.

Se desarrolló un programa de calibración del área monitoreada que permite definir los vértices de una región dentro de una imagen de cada cámara. Debido al ángulo de visión de las

cámaras de seguridad, es posible que alguno de los vértices quede fuera de la imagen; el programa de calibración permite alargar artificialmente la imagen para definir los vértices faltantes. Los vértices definidos son utilizados en el cálculo de una transformación de perspectiva [21] para convertir las coordenadas en píxeles de la ubicación de las personas a coordenadas en metros, como se muestra en la figura 4.

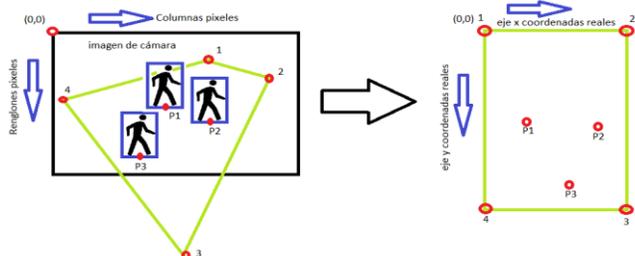


Figura 4.- Transformación de perspectiva del área de prueba.

Para el cálculo de la transformación de perspectiva se define un arreglo denominado *polígono origen* con las coordenadas de los vértices marcados en una imagen. También se define un arreglo denominado *polígono destino* con las coordenadas en metros de los vértices del área monitoreada. Estos arreglos deben contener el mismo número de vértices y debe haber una correspondencia geométrica entre ellos, debiendo coincidir el primer vértice u origen en las coordenadas (0,0) de los dos arreglos y continuar en el sentido horario, como se muestra en la figura 4. Con los arreglos de vértices se procede al cálculo de la matriz de transformación  $M$  a partir de:

$$\begin{bmatrix} t_i x'_i \\ t_i y'_i \\ t_i \end{bmatrix} = M \begin{bmatrix} x_i \\ y_i \\ 1 \end{bmatrix} \quad (1)$$

Donde  $(x_i, y_i)$  son los vértices del *polígono origen* en coordenadas homogéneas y  $(x'_i, y'_i)$  son los vértices del *polígono destino*. Para calcular la matriz de transformación  $M$  se requieren 4 vértices correspondientes en los polígonos origen y destino. La matriz de proyección  $M$  puede ser utilizada para convertir coordenadas en píxeles a coordenadas en metros por medio de:

$$\begin{bmatrix} x'/w \\ y'/w \\ w \end{bmatrix} = M \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (2)$$

Donde  $(x, y)$  son las coordenadas en píxeles de la ubicación de la persona detectada y  $(x', y')$  son sus correspondientes coordenadas en metros.

El Mapa de Flujo de Personas es un arreglo de datos donde se almacenan las coordenadas en metros de las personas detectadas. Este mapa se divide en zonas determinadas por la

ubicación y cobertura de las luminarias y termostatos a controlar. Para esta investigación se dividió el área de prueba en seis zonas, como se muestra en la figura 5. El sistema de detección y ubicación de personas mantiene actualizada la información del Mapa de Flujo de Personas determinando el número de individuos ubicados en cada zona del mapa.

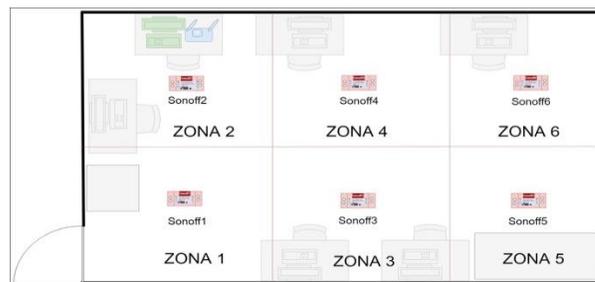


Figura 5.- Mapa de Flujo de Personas del área de prueba dividida en seis zonas.

Cuando se requiere más de una cámara para cubrir el área a monitorear, el video adquirido por cada cámara es procesado por una instancia diferente del sistema de detección y ubicación de personas, por lo que se genera un Mapa de Flujo de Personas por cada cámara del área monitoreada. Entonces se debe llevar a cabo un proceso de fusión de datos que consiste en unir los datos de los mapas generados para cada cámara siguiendo determinadas reglas para la obtención de un solo Mapa de Flujo de Personas. En este proceso se comparan las zonas correspondientes del mapa de cada cámara para determinar el número de personas que fueron detectadas en ellas. Se definieron 3 reglas para la actualización del Mapa de Flujo de Personas resultante de la fusión de datos:

1. Si el número de personas en todas las cámaras es igual, el Mapa de Flujo de Personas resultante se queda con ese número.
2. Si el número de personas detectadas es distinto entre las cámaras, el Mapa de Flujo de Personas resultante se queda con el mayor número detectado en cada área.
3. Si no se detectaron personas en ninguna de las cámaras, se asigna un cero a la zona correspondiente del Mapa de Flujo de Personas resultante.

#### 4. CONTROL DE ILUMINACIÓN Y CLIMATIZACIÓN

Se desarrolló el sistema de control de iluminación y climatización para el área monitoreada. El objetivo es reducir el consumo de energía eléctrica basado en la información del Mapa de Flujo de Personas.

##### 4.1. Control de Iluminación

Con los avances del Internet de las cosas (IoT), cada vez existe mayor diversidad y disponibilidad de dispositivos que pueden ser utilizados para controlar la iluminación de forma remota. Es

importante que el fabricante de los dispositivos inteligentes proporcione una interfaz para desarrollo de aplicaciones de control (API). En cuanto al protocolo de comunicación se decidió utilizar dispositivos que puedan ser controlados por medio de WiFi, así se pueden implementar redes privadas para el intercambio de información. El aspecto más importante a considerar, para la selección de los dispositivos de control de iluminación adecuados, es evitar la modificación de la infraestructura de iluminación presente en el área a controlar, es decir, se pretende utilizar dispositivos IoT que puedan controlar el encendido/apagado de las luminarias con que se cuenta actualmente. Se evaluaron las características de diferentes dispositivos, la mayoría de ellos eran relevadores de las marcas Wingoneer, Relay pros y MHCOZY, pero todos requieren de fuentes de alimentación DC externas. Se eligió el interruptor Sonoff Basic ya que se alimenta con el voltaje de la línea de AC y aunque el firmware de fábrica solo permite el control por medio de una aplicación que no permite su manipulación directa, fue sencillo manipular el hardware para instalar un firmware de código libre que permite manipular el interruptor por medio del protocolo TCP/IP. La figura 6 muestra el diagrama de conexión eléctrica del interruptor seleccionado.



Figura 6.-Diagrama de conexión eléctrica del interruptor Sonoff Basic.

El interruptor Sonoff Basic se instala fácilmente cortando los cables de la alimentación actual y conectándolo de acuerdo al diagrama, sujetando su carcasa de plástico al gabinete de la luminaria. Otra ventaja es que su costo es menor al de los otros dispositivos evaluados.

Se desarrolló el código para el control de iluminación que utiliza la información del Mapa de Flujo de Personas para encender o apagar de forma individual cada una de las luminarias del área monitoreada que corresponden a una zona definida en el Mapa de Flujo de Personas. El algoritmo de control enciende o apaga los interruptores de las zonas de acuerdo a las siguientes reglas lógicas:

1. Si P y L entonces L
2. Si NP y NL entonces NL
3. Si P y NL entonces L
4. Si NP y L entonces NL

Donde P significa personas detectadas en la zona, NP significa que no se detectan personas en la zona, L significa que la luminaria de la zona está encendida y NL significa que la luminaria está apagada. Las dos primeras reglas no realizan

ningún cambio en la iluminación. La regla 3 enciende la luminaria de forma inmediata. La regla 4 apaga la luminaria después de un tiempo predeterminado en el cual no se detectan personas para evitar dejar sin iluminación a alguna persona por errores de detección.

#### 4.2. Control de Climatización

Los sistemas de climatización de edificios, por lo general, utilizan unidades paquete del tipo HVAC (Heating, Ventilation and Air Conditioning) que actúan como calefacción en invierno y como refrigeración en verano. Su finalidad es la de proporcionar al usuario un ambiente interior cuya temperatura, tasa de humedad relativa y purificación del aire sean confortables. Los sistemas de climatización instalados en edificios incluyen termostatos para controlar la temperatura de determinadas áreas, por lo general, el diseño de un sistema de climatización se realiza por áreas, de acuerdo a la potencia frigorífica de las unidades paquete. Los termostatos tradicionales para el control de la temperatura son dispositivos montados sobre la pared que funcionan de forma independiente, es decir, no interactúan con otros dispositivos y se manipulan manualmente.

El Internet de las cosas (IoT) y las tecnologías para edificios inteligentes a propiciado el avance tecnológico de los dispositivos para el control de climatización. Actualmente existen termostatos inteligentes que pueden ser operados en forma remota, pueden ser programados por periodos de tiempo y aprenden las preferencias de los usuarios para adaptar las condiciones climáticas, además de poder ser manipulados a distancia por medio de aplicaciones para dispositivos móviles. En este proyecto se incorpora un termostato inteligente que puede ser manipulado por el sistema de control de climatización para hacer más eficiente el consumo energético ajustando la temperatura de acuerdo al número de personas presentes.

Existen diferentes tipos de termostatos inteligentes disponibles en el mercado, la mayoría de ellos son controlados por aplicaciones desarrolladas por su fabricante. El requerimiento más importante para el desarrollo del control de climatización es que el termostato inteligente proporcione una interfaz de programación de aplicaciones (API) abierta, que permita tener una interacción vía WiFi para el control de sus todas sus capacidades. Otro requisito importante es que se pueda adaptar a los sistemas de climatización ya instalados en el edificio.

Se evaluaron diferentes dispositivos como los termostatos *Ecobee4*, *Lux/Kono* y *Honeywell Lyric T5* que proporcionan conectividad por WiFi pero no proporcionan un API abierto. Se seleccionó el *Nest Learning Thermostat*, ya que es el único dispositivo que proporciona un API con funciones que permiten manipular su configuración. Se instaló en el área de prueba sustituyendo al termostato manual en operación. La especificación de las conexiones eléctricas del termostato Nest

son compatibles con los estándares tradicionales, por lo que no se requirió ninguna modificación al cableado actual. La figura 7 muestra el diagrama de conexión y el termostato ya instalado.



Figura 7.- Termostato Nest. a) Diagrama de conexión y b) Dispositivo instalado en el área de prueba.

Se instaló la librería python-nest 4.1.0 para el desarrollo del código del control de climatización. Las funciones de la librería permiten: 1) encender o apagar el dispositivo, 2) cambiar el modo de operación entre calor o frío y 3) cambiar el valor de la temperatura deseada en el área.

Se selecciona el modo de operación del termostato de acuerdo a la temporada, el sistema se fija en modo frío a partir de que inicia la primavera y en modo calor al iniciar el otoño. Las temperaturas ideales según [22] son fijadas en 24.5°C para modo frío y 22°C en modo calor. Debido a que la respuesta de los equipos de climatización no es tan rápida, se deben considerar tiempos de espera en el orden de minutos para realizar cambios en el modo de operación y ajuste de temperatura. El control de climatización toma en cuenta la información del número total de personas presentes en todas las zonas del Mapa de Flujo de Personas. Se especifican las siguientes reglas lógicas para el control de climatización:

1. Si NT y P entonces T
2. Si T y NP entonces NT
3. Si T y P entonces Ajustar Temperatura

Donde T significa termostato encendido, NT significa termostato apagado, P significa que hay personas presentes en el área y NP significa que no hay personas presentes en el área. La Regla 1 solo se aplica si sus condiciones se cumplen por más de tres minutos, la Regla 2 solo se aplica si sus condiciones se cumplen por más de tres minutos y la Regla 3 solo se aplica si sus condiciones se cumplen por más de 15 minutos. El Ajuste de Temperatura de la Regla 3 se aplica de acuerdo al número de personas presentes en el área, si hay más de 4 personas se reduce la temperatura 1.5°C para mantenerla dentro del rango de confort definido en [22]. Se utilizaron los parámetros físicos del área de prueba para determinar que se requieren 4 personas para incrementar la temperatura 1.5°C en un tiempo de 15 minutos, de acuerdo a la ecuación de capacidad calorífica:

$$Q = mC\Delta T \quad (3)$$

Donde  $Q$  es el calor necesario para provocar el cambio de temperatura  $\Delta T$  en una masa  $m$  de un compuesto, en este caso es aire, con su respectivo calor específico  $C$ . Se establece un intervalo de tiempo de 15 minutos para que el control de climatización haga la revisión del Mapa de Flujo de Personas y la actualización del valor de temperatura en el termostato Nest.

## 5. INTEGRACIÓN E IMPLANTACIÓN DEL SISTEMA

El diseño de un sistema de visión embebido para la detección y ubicación de personas basado en modelos pre-entrenados de redes neuronales de aprendizaje profundo demanda recursos computacionales que difícilmente están presentes en una tarjeta embebida de uso general. La compañía Nvidia ofrece las tarjetas Jetson [23] en los modelos Nano, TX1, TX2/TX2i y AGX Xavier. Estas tarjetas embebidas fueron diseñadas para eficientar el diseño de sistemas embebidos para aplicaciones de Inteligencia Artificial, incluyendo la ejecución de redes neuronales de aprendizaje profundo y el procesamiento digital de imágenes. Se ponen a disposición de los desarrolladores características especiales como la disponibilidad de procesadores gráficos (GPU) con un gran número de núcleos. En este proyecto se consideró el uso de la tarjeta Nvidia Jetson TX2 que tiene un consumo de potencia de 7.5 watts, cuenta con 8 Gb de memoria RAM, tiene CPU con 4 núcleos ARM Cortex A57@2GHz y 2 núcleos Denver2@2GHz, un GPU con 256 núcleos Maxwell@1.3GHz, un disco duro de estado sólido de 32 Gb, además tiene incorporado un puerto de red Gigaethernet y cuenta con un módulo para conexión a redes WiFi. La tarjeta tiene precargada una versión adaptada del sistema operativo Ubuntu 16.04. La figura 8 muestra la vista superior de la tarjeta Nvidia Jetson TX2.



Figura 8.- Tarjeta Nvidia Jetson TX2.

Nvidia ofrece algunas opciones recomendadas para la configuración de la tarjeta Jetson TX2. Estas opciones están orientadas a sacar el máximo provecho de la misma y utilizar todos sus recursos de manera óptima. Se utilizó el conjunto de herramientas de desarrollo de software (SDK) denominado Jetpack [24], que provee varias opciones de configuración para el desarrollo de diferentes tipos de sistemas. Se instaló el Jetpack SDK en su versión 4.3 que incluye las librerías CUDA

versión 10 y OpenCV versión 4.1.1, también incluye Python 3.6. Además se instalaron manualmente las librerías pytorch, numpy, numba, pygame, pandas, imutils, matplotlib y python-nest. El diseño, desarrollo y pruebas iniciales del sistema fueron realizadas en una computadora de escritorio con procesador Intel Core i7 de 8va. generación con 16Gb de memoria RAM y tarjeta de gráficos Nvidia GeForce GTX 1060, considerando que debería ser finalmente implementado en la tarjeta Nvidia Jetson TX2, por lo que se tomaron en cuenta las condiciones necesarias para su correcto funcionamiento.

### 5.1. Implantación del Sistema

La implantación del sistema completo consiste en que la tarjeta Jetson TX2 integre el sistema para detección y ubicación de personas con el sistema de control de iluminación y climatización. El sistema de detección y ubicación de persona utiliza dos cámaras de video de la marca Hikvision, modelo HiLook IPC-B620-Z, conectadas por medio de cable de red Ethernet a un ruteador de la marca Linksys, modelo WRT54G. La tarjeta Jetson TX2 también se comunica por medio de cable de red Ethernet al ruteador Linksys con la finalidad de que esta pueda adquirir y procesar el video de las cámaras que cubren el área de prueba. Los dispositivos del sistema de control de iluminación y climatización se conectan al ruteador Linksys por medio de la red WiFi. El esquema de conexiones de red del sistema se muestra en figura 9.



Figura 9.- Conexión en red de los dispositivos del sistema.

### 5.2. Pruebas de Funcionamiento y Resultados

El software desarrollado puede ser iniciado desde una terminal en la sistema embebido conectando un teclado y un monitor a la tarjeta Jetson TX2 o por medio de una terminal remota en una computadora conectada en la misma red. En la implantación final del sistema se configuró el autoinicio del software al arranque del sistema embebido. La figura 10 muestra la captura de las cámaras en tiempo real visualizadas en un monitor conectado al sistema embebido.

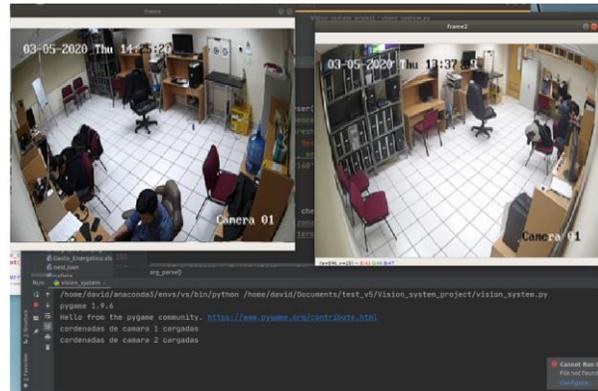


Figura 10.- Visualización en tiempo real de las cámara conectadas al sistema embebido.

Durante las pruebas de funcionamiento en el área monitoreada por las cámaras se determinó que dos de la seis zonas del Mapa de Flujo de Personas no tienen presencia de personas en la mayor parte del día, también se detectó que durante la hora de comida los usuarios dejan encendidas las lámparas y el sistema de climatización. De esta manera, el sistema embebido logra una reducción del consumo eléctrico de un 40% diario con el control de iluminación y 8.3% de ahorro por cada hora que no haya personas en el área de prueba para el control de climatización. Con los resultados obtenidos en las pruebas de funcionamiento realizadas se demostró que es posible el desarrollo de sistemas de control para edificios que pueden ser integrados sin grandes modificaciones a las instalaciones que se cuenta. Esto es posible si se seleccionan los dispositivos adecuados para ser controlados a distancia y una plataforma embebida con las capacidades adecuadas de acuerdo a los sistemas que se desee controlar. Con respecto a la detección de persona se encontró que las cámaras de video de los sistemas de seguridad, como las utilizadas en el sistema desarrollado, pueden proporcionar imágenes en condiciones de baja iluminación, por lo que es posible seguir detectando a las personas con el software desarrollado. Las pruebas realizadas permitieron comprobar que la resolución de las cámaras fue suficiente para que el software pudiera detectar personas en los puntos más alejados.

## 6. CONCLUSIONES

Se desarrolló el prototipo de un sistema de visión embebido que mide el flujo de personas en un área monitoreada por cámaras de seguridad dentro de un edificio y que utiliza esta información para el control de la iluminación y climatización. Se creó un Mapa de Flujo de Personas dividido en zonas que contiene la información de las personas detectadas y ubicadas en cada zona. La información del Mapa de Flujo de Personas es procesada para controlar la iluminación y climatización del área monitoreada. Para el control de iluminación se instaló un interruptor inteligente controlado a distancia en cada luminaria del área monitoreada que corresponde a cada zona del Mapa de

Flujo de Personas. Se definió un conjunto de reglas lógicas para el control de encendido/apagado de los interruptores basado en la información de la presencia de personas en cada zona. Para el control de climatización se sustituyó el termostato manual que controla el sistema HVAC por un termostato inteligente controlado a distancia. Se creó un conjunto de reglas lógicas para control de la temperatura del termostato basadas en la información del Mapa de Flujo de Personas, tomando como base temperaturas de confort definidas en la literatura para las temporadas de invierno y verano. La temperatura puede ser ajustadas de acuerdo al número de personas detectadas en el área. El diseño del sistema tomó en cuenta que los dispositivos para el control de la iluminación y climatización se puedan integrar a la infraestructura del edificio actual sin la necesidad de realizar demasiadas modificaciones en los sistemas existentes y que además pueda hacer uso del video de las cámaras de seguridad ya instaladas.

Se realizaron pruebas dentro de un laboratorio de superficie rectangular monitoreado por dos cámaras de seguridad. El área monitoreada es iluminada por seis lámparas y tiene instalado un sistema de climatización controlado por un termostato. El Mapa de Flujo de personas se dividió en seis zonas de acuerdo al posición de las luminarias. Después de una semana de pruebas se determinó que dos de las zonas del área monitoreada tiene un flujo de personas casi nulo y que en algunas ocasiones (ej. a la hora de comida) las personas dejan las luminarias y el termostato encendidos al abandonar el área, por lo que se observó una reducción en el consumo de energía de 40% en iluminación y 8.3% por cada hora que no se detecten personas con el control de climatización. Se pueden realizar mejoras en la medición del flujo de personas cuando se tienen varias cámaras utilizando un método de fusión de datos que revise la ubicación de las personas registradas por cada cámara para determinar el número de personas en cada zona y actualizar el Mapa de Flujo de Personas final.

## 7. BIBLIOGRAFÍA

- [1] Song, H., Srinivasan, R., Sookoor, T., Jeschke, S., Smart Cities: Foundations, Principles, and Applications. John Wiley & Sons, 2017.
- [2] Karasulu, B., Korukoglu, S., "A software for performance evaluation and comparison of people detection and tracking methods in video processing", *Multimed Tools Appl*, 55, 677–723, 2011.
- [3] D. Kang, Z. Ma and A. B. Chan, "Beyond Counting: Comparisons of Density Maps for Crowd Analysis Tasks—Counting, Detection, and Tracking", In *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 29, no. 5, pp. 1408–1422, May 2019.
- [4] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection", In 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), San Diego, CA, USA, 2005, vol. 1, pp. 886–893.
- [5] C. Cortes and V. Vapnik, "Support-Vector Networks", *Machine Learning*, vol. 20, no. 3, pp. 273–297, Sep. 1995.
- [6] M. Olejniczak and M. Kraft, "Taming the HoG: The Influence of Classifier Choice on Histogram of Oriented Gradients Person Detector Performance", *Artificial Intelligence and Soft Computing, ICAISC 2017, Lecture Notes in Computer Science*, vol 10245, Springer, 2017.
- [7] W. Lan, J. Dang, Y. Wang, and S. Wang, "Pedestrian Detection Based on YOLO Network Model", In 2018 IEEE Intl. Conf. on Mechatronics and Automation (ICMA), 2018, pp. 1547–1551.
- [8] A. Khan, A. Sohail, U. Zahoora, and A. S. Qureshi, "A Survey of the Recent Architectures of Deep Convolutional Neural Networks", *Artif Intell Rev*, 53, 5455–5516, 2020.
- [9] J. Redmon and A. Farhadi, "YOLOv3: An Incremental Improvement," arXiv preprint arXiv:1804.02767, 2018.
- [10] A. Ulhaq, A. Khan, and R. Robinson, "Evaluating Faster-RCNN and YOLOv3 for Target Detection in Multi-sensor Data", In *Statistics for Data Science and Policy Analysis*, pp. 185–193, Singapore, 2020.
- [11] T. Shi, Y. Niu, M. Liu, Y. Yang, C. Wang, and Y. Huang, "Underwater Dense Targets Detection and Classification based on YOLOv3", In *IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pp. 2595–2600, 2019.
- [12] "CUDA Zone", NVIDIA Developer [En línea]. Disponible en: <https://developer.nvidia.com/cuda-zone>. [Consultado: mayo 17, 2022].
- [13] PyTorch for Jetson Nano, NVIDIA Developer Forums. [En línea]. Disponible en: <https://devtalk.nvidia.com/default/topic/1049071/jetson-nano/pytorch-for-jetson-nano-version-1-3-0-now-available/>. [Consultado: mayo 17, 2022].
- [14] "GitHub - chuanqi305/MobileNet-SSD: Caffe Implementation of Google MobileNet SSD detection network, with pretrained weights on VOC0712 and mAP=0.727." [En línea]. Disponible en: <https://github.com/chuanqi305/MobileNet-SSD>. [Consultado: mayo 17, 2022].
- [15] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications", arXiv:1704.04861, 2017.
- [16] W. Liu et al., "SSD: Single Shot MultiBox Detector", In *Computer Vision – ECCV 2016, Lecture Notes in Computer Science*, vol 9905. Springer, 2016.
- [17] "Caffe | Deep Learning Framework". [En línea]. Disponible en: <https://caffe.berkeleyvision.org/> [Consultado: mayo 17, 2022].
- [18] "COCO - Common Objects in Context". [En línea]. Disponible en: <https://cocodataset.org/#home> [Consultado: mayo 17, 2022].
- [19] "The PASCAL Visual Object Classes Homepage". [En línea]. Disponible en: <http://host.robots.ox.ac.uk/pascal/VOC/index.html>. [Consultado: mayo 17, 2022].
- [20] J. Redmon, "Darknet: Open Source Neural Networks in C", 2016. [En línea]. Disponible en: <https://pjreddie.com/darknet/>. [Consultado: mayo 17, 2022].
- [21] "OpenCV: Geometric Image Transformations", OpenCV. [En línea]. Disponible en: [https://docs.opencv.org/3.4/da/d54/group\\_imgproc\\_transform.html](https://docs.opencv.org/3.4/da/d54/group_imgproc_transform.html). [Consultado: mayo 17, 2022].
- [22] S. Wang, *Handbook of Air Conditioning and Refrigeration*, 2nd. Ed., New York: McGraw-Hill, 2001.
- [23] "Sistemas Integrados Avanzados", NVIDIA. [En línea]. Disponible en: <https://www.nvidia.com/es-la/autonomous-machines/embedded-systems/>. [Consultado: mayo 17, 2022].
- [24] "JetPack", NVIDIA Developer, [En línea]. Disponible en: <https://developer.nvidia.com/embedded/jetpack> [Consultado: mayo 17, 2022].