

Vargas, J.F. & Toledo, M.J. (2024). Visualización de trabajo productivo con mapas de calor construidos usando fotografías tomadas con UAV y detecciones con machine learning. En Herrera, R.F., Salazar, L.A., (Editores), *Actas del IX Congreso Iberoamericano de Gestión y tecnología de la Construcción (IX ELAGEC2024)*.

VISUALIZACIÓN DE TRABAJO PRODUCTIVO CON MAPAS DE CALOR CONSTRUIDOS USANDO FOTOGRAFÍAS TOMADAS CON UAV Y DETECCIONES CON MACHINE LEARNING

José Francisco Vargas ¹ – j.vargashernandez@uandresbello.edu

Mauricio Javier Toledo ¹ – mauricio.toledo@unab.cl

¹Ingeniería Civil, Universidad Andres Bello, Santiago, Chile

RESUMEN

La gestión de movimientos de tierra es fundamental en el proceso constructivo, pues su correcta coordinación evita pérdidas de productividad y costos. Un problema común es la falta de consideración del factor espacial, lo que dificulta la ubicación precisa del trabajo y la gestión de maquinaria. Esto puede llevar a errores en la ubicación del trabajo debido a una mala comunicación o gestión. Este artículo propone una solución mediante la creación de mapas de calor que visualizan la concentración del trabajo realizado por los equipos. Esta herramienta incorpora el factor espacial en la planificación de maquinaria y espacios de trabajo, proporcionando a los profesionales de terreno información para gestionar de manera eficiente la flota de maquinaria. Para la investigación, utilizamos UAVs (vehículos aéreos no tripulados) para capturar imágenes en un proyecto de movimiento de tierras. Empleamos el algoritmo YOLO para detectar equipos que realizan actividades de movimiento de tierras y usamos QGIS (software de georreferenciación) para generar mapas de calor a partir de las detecciones y registrar el trabajo productivo. Estos mapas permiten georreferenciar y registrar de manera horaria dónde ocurre el trabajo productivo en el proyecto.

PALABRAS CLAVE

Mapa de calor; productividad; UAV; machine learning; YOLO; GIS.

INTRODUCCIÓN

En la mayoría de los proyectos de construcción es necesario hacer movimientos de tierra, ya sea para realizar excavaciones o simplemente para el escarpe o limpieza del terreno. La gestión y coordinación de los equipos de construcción que lo realizan es crucial, ya que pueden representar hasta el 30% del costo total del proyecto, dependiendo de la naturaleza y

envergadura del mismo (Shehadeh et al., 2022). Por lo tanto, los movimientos de tierra pueden llegar a tener un gran impacto tanto en la productividad, como en los costos de un proyecto de construcción. Actualmente, la medición de la productividad en los proyectos de construcción se realiza mediante registros visuales y la elaboración de informes y reportes que solamente señalan el rendimiento de los equipos de construcción en terreno. En el mejor de los casos, se construyen cartas de balance, basadas en elaborados procesos de registro, codificación y visualización del trabajo productivo, contributorio o no contributorio (Oglesby et al., 1989). Sin embargo, estos enfoques descuidan el factor espacial, pues no se visualiza dónde ocurre la actividad (Smith, 1999). Esto es problemático, ya que la actividad puede estar ocurriendo en un lugar inapropiado, lo que disminuye la eficiencia y aumenta el riesgo de daños, como la rotura de ductos o estructuras enterradas (Melchiorre et al., 2024), lo que pudiera generar retrasos y re-trabajos. Conocer la ubicación exacta de la actividad permite tomar medidas preventivas para evitar estos problemas.

Algunos autores ya sugieren el uso de estos registros visuales que incluyen la componente espacial con distintos enfoques. Por ejemplo, Zhao et al. (2020) utilizaron mapas de calor para definir el espacio de trabajo en proyectos de construcción a partir del monitoreo en tiempo real de los trabajadores de construcción. Pérez et al. (2024) aunque no realizan mapas de calor propiamente tal, discuten la utilidad de monitorear la ubicación de los trabajadores en tiempo real y graficar sus ubicaciones para entender la productividad de los trabajadores en los proyectos de construcción. Golovina et al. (2016) emplearon mapas de calor para mejorar la seguridad en obras, identificando las zonas más concurridas por los equipos de construcción y evitando el tránsito peatonal por ellas. Para resolver el problema espacial, esta investigación propone la elaboración de mapas de calor a partir de la detección del trabajo productivo de los equipos de construcción en fotografías capturadas usando UAVs (unmanned aerial vehicles).

El objetivo de esta investigación es desarrollar una metodología para elaborar mapas de calor, que son registros visuales donde se puede observar la concentración de actividad productiva de los equipos de construcción, similar a su uso en algunos deportes.

Para llevar a cabo la investigación, hicimos una revisión de la literatura para identificar registros similares y explorar cómo abordarlo. Abordamos 4 aspectos principales: (i) la productividad en proyectos de construcción; (ii) el uso de drones o UAV para la toma de fotografías; (iii) el uso de machine learning en aplicaciones de construcción; y (iv) la generación de mapas de calor en proyectos de construcción.

PRODUCTIVIDAD EN CONSTRUCCIÓN

La industria de la construcción es una de las más importantes no solo en Chile, sino a nivel global. Específicamente en Chile, esta industria aporta hasta un 7% del Producto Interno Bruto del país (León, 2023). Por ello, una disminución en la productividad de este sector puede tener un impacto directo en la economía nacional. Existen varias técnicas para mejorar la productividad, como capacitaciones, incentivos, entre otras (Martínez & Alarcón, 1988). También existen técnicas para medir la productividad, específicamente para los miembros de

una cuadrilla de trabajo que realizan distintas tareas. Una de las más comunes son las cartas de balance, que sirven para medir porcentualmente el trabajo productivo, contributivo y no contributivo (Oglesby et al., 1989; Vilca & Guzmán, 2014). En general, durante la revisión de la literatura sobre productividad, siempre se encontraron formas de medirla o de mejorarla, pero ninguna relacionada con el factor espacial, que es el objetivo final de esta investigación.

USO DE UAVS EN CONSTRUCCIÓN

Hoy en día, es cada vez más frecuente el uso de dispositivos UAV para capturar registros fotográficos dentro de las obras de construcción. La capacidad de obtener imágenes en zonas de difícil acceso que documenten todo el terreno proporciona una cantidad considerable de información (Anwar et al., 2018). Entre los usos destacados de estos drones se encuentran la creación de ortomosaicos, la generación de curvas de nivel, e incluso el cálculo preciso de movimientos de tierra (Hernández, 2021). Además, se ha observado que mejoran la logística y la productividad en los sitios de construcción, como lo muestra la investigación de Chica & Alarcón (2019). En resumen, el uso de drones en la construcción es muy versátil, y puede permitir la captura de fotografías aéreas que proporcionen información detallada sobre la operación de equipos en el sitio de construcción.

USO DE MACHINE LEARNING EN LA INDUSTRIA DE LA CONSTRUCCIÓN

Con la introducción de la inteligencia artificial (IA), muchos ingenieros y profesionales de la construcción han encontrado formas de implementarla para facilitar tareas que a menudo requieren mucho tiempo y mano de obra. Por ejemplo, Obiuto et al. (2024) demostraron que, al utilizar IA para analizar grandes conjuntos de datos, es posible predecir desafíos que podrían causar retrasos en los proyectos, permitiendo así abordarlos de manera anticipada. Dentro del ámbito del machine learning, destaca el deep learning, que incluye los algoritmos detectores. Estos detectores, son capaces de evaluar patrones como trabajadores y maquinarias y reconocerlos en las fotografías (Son & Kim, 2021; Bochkovskiy et al., 2020). En los últimos años, estos detectores se han implementado en la industria de la construcción. Por ejemplo, una investigación utilizó detectores para verificar si los trabajadores en una obra estaban usando cascos de seguridad (Zhou et al., 2021), demostrando cómo la IA puede mejorar la seguridad en la construcción. Rebolledo & Toledo (2023) utilizaron detectores para identificar cuándo los equipos de construcción estaban operando. Esta metodología permitió crear informes de productividad y proporcionó una nueva forma de aplicar la IA en la gestión de obras. Esta implementación de la inteligencia artificial no sólo mejora la eficiencia y la seguridad, sino que también ofrece herramientas avanzadas para la planificación y coordinación de actividades en sitios de construcción.

USO DE MAPAS DE CALOR

Un mapa de calor es una representación visual que utiliza un gradiente de colores para diferenciar entre distintas concentraciones de puntos en un mapa (García, 2022). Este tipo de mapa muestra dónde se concentra más intensamente una actividad específica. Para la creación de estos mapas, se han consultado diversos artículos que los han utilizado tanto en el ámbito de la construcción como en otras disciplinas. Por ejemplo, en ingeniería ambiental,

se han creado mapas de calor utilizando QGIS para estimar las zonas más propensas a incendios (Polo et al., 2022). En medicina, se han empleado estos mapas para estimar la ubicación de tumores pancreáticos usando el entorno de programación Matlab (Pedanekar et al., 2019). Asimismo, es posible generar mapas de calor a partir de coordenadas, como se demostró en una investigación que estimaba las zonas con mayor incidencia de accidentes (Netek et al., 2018). En general, estas investigaciones comparten el uso de software GIS (como QGIS) y la aplicación de coordenadas geoespaciales.

Esta investigación adoptará una metodología similar para crear mapas de calor, pero con un enfoque específico en el ámbito de la construcción. El objetivo es visualizar la concentración de actividades de movimiento de tierras, permitiendo una mejor planificación y coordinación de los recursos en el sitio de construcción. Para ello usaremos drones o UAV para la toma de imágenes del sitio. Luego usaremos algoritmos de detección de imágenes para identificar cuándo y dónde los equipos están realizando trabajo productivo. Finalmente, usaremos software GIS (QGIS) para generar mapas de calor a partir de las detecciones que proporcionen información sobre la concentración de actividad de los equipos durante tareas de movimiento de tierras, como la excavación en un sitio de construcción. Buscamos abordar los siguientes objetivos: ¿Cómo capturo videos o fotos con UAV?, ¿Cómo entreno algoritmos de ML para detectar maquinarias en construcción? ¿Cómo usar tales detecciones para construir un mapa de calor? y ¿Cómo puedo visualizar el trabajo productivo de los equipos de construcción en obra?

METODOLOGÍA

Para esta investigación seguimos los siguientes pasos: selección de un caso de estudio y recolección de los datos necesarios (UAV DJI Mavic Air 2), preparación de dichos datos (etiquetado y entrenamiento realizado en entorno Matlab), entrenamiento del algoritmo de detección YOLO, determinación de los centros de las detecciones, georreferenciación de las imágenes y creación del mapa de calor usando QGIS. Estos pasos fueron fundamentales para llevar a cabo la investigación y generar un análisis detallado sobre la actividad y la distribución espacial de los equipos en el sitio de construcción. La Figura 1 muestra de forma esquemática la metodología seguida.

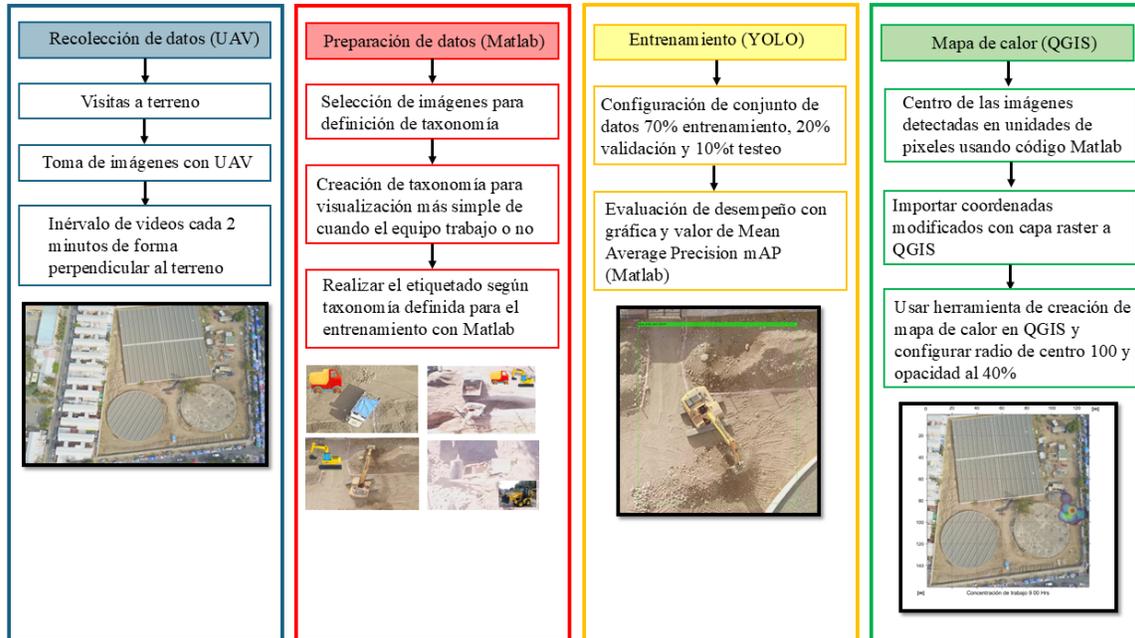


Figura 1. Esquema de metodología seguida.

CASO DE ESTUDIO

El proyecto seleccionado para el estudio se ubica en Domingo Tocornal 1367, comuna de Puente Alto y pertenece a la empresa sanitaria Aguas Andinas. Corresponde a un conjunto de estanques de agua potable en un terreno de aproximadamente 20,800 m². El proyecto contemplaba la excavación para la instalación de tuberías, el transporte de material y el nivelado del terreno. Para la realización de trabajos en este sitio, fue necesario el empleo de maquinaria pesada que incluyó excavadoras, camiones tolva y mini-retroexcavadoras. La imagen aérea referencial del proyecto se muestra en la Figura 2.

RECOLECCIÓN DE DATOS

Durante la recolección de datos, se realizaron 8 visitas a terreno. Las primeras 7 fueron para recolectar imágenes para entrenar el algoritmo detector, y la última, para testear la metodología y crear el mapa de calor a partir de las detecciones de trabajo productivo de los equipos de construcción. Obtuvimos las imágenes a partir de videos capturados con el UAV DJI Mavic Air 2, en calidad 4K y a 24 FPS (UAV con cámara cenital o perpendicular al terreno). En las primeras 7 visitas, grabamos videos de aprox. 5 min a 60 m de altura, con foco en equipos de construcción específicos. En la última visita, grabamos videos de 2 min para muestrear cada intervalo de 10 min en 1 hora, es decir, 6 videos de 2 min cada uno para cada hora de trabajo muestreada. Hicimos esto para no exceder la autonomía de vuelo del UAV (aprox. 30 min por batería) y cubrir una jornada matutina de trabajo de 9:00 a 13:00 hrs. con las 3 baterías disponibles. Las grabaciones de la última visita las hicimos a 150 m para capturar en simultáneo todo el trabajo en el terreno. El procedimiento seguido nos permitió recolectar videos y fotos detallados y variados en diferentes emplazamientos y

condiciones de luminosidad, aspectos cruciales para entrenar adecuadamente el algoritmo detector.



Figura 2. Caso de Estudio: Proyecto de excavación estanques Aguas Andinas, Puente Alto.

PREPARACIÓN DE DATOS

En esta parte de la investigación, revisamos las imágenes aéreas recolectadas para identificar las diferentes actividades realizadas por los equipos de construcción con el fin de determinar cuándo están realizando Trabajo Productivo y cuándo están realizando Trabajo No Contributorio. Una vez identificadas las distintas actividades, definimos diferentes posturas que pueden adoptar los equipos para evaluar cuándo están trabajando o no. La Tabla 1 muestra las clases que definimos/observamos en nuestras fotos. Hicimos esto con el objetivo de desarrollar una Taxonomía que ayudara a resumir las Clases asociadas a todas las posturas de los equipos fotografiadas mientras trabajaban. Una vez realizada la Taxonomía, etiquetamos las imágenes, que consiste en marcar la zona de interés dentro de las mismas. Como recomendación, se opta siempre por incluir al equipo de construcción en el centro y extender la zona de interés con el fin de recoger información adicional del entorno.

Tabla 1. Resumen de Clases.

Clase	Equipos	Tipo de Trabajo
EXCAMTP	Excavadora y Camión	Trabajo Productivo
EXCATP	Excavadora	Trabajo Productivo
EXCATNC	Excavadora	Trabajo No Contributorio
CAMTP	Camión	Trabajo Productivo
CAMTNC	Camión	Trabajo No Contributorio
MIRTP	Mini Retroexcavadora	Trabajo Productivo

ENTRENAMIENTO

Una vez etiquetadas las imágenes, entrenamos el algoritmo detector YOLOv4 en un entorno de MATLAB. Con el algoritmo detector buscábamos clasificar automáticamente cuándo el equipo estaba trabajando o agregando valor al proyecto. Usamos una configuración común para entrenar algoritmos de inteligencia artificial: 70% de las imágenes para entrenamiento, 20% para validación y 10% para prueba. Realizamos los entrenamientos para cada clase por separado hasta alcanzar resultados aceptables para nuestra prueba de concepto (buscamos una precisión promedio del 70% para cada clase). Completamos 28 entrenamientos entre todas las clases, etiquetando más de 5000 imágenes en total.

MAPA DE CALOR

Una vez realizados los entrenamientos necesarios, debemos procesar un conjunto de imágenes para hacer las detecciones. Para generar los mapas de calor, necesitamos obtener el centro de dichas detecciones que representa la posición (x,y) de dónde ocurre el trabajo en el sitio de construcción. Desarrollamos un código en MATLAB que facilita este trabajo y entrega una matriz con tres columnas: la primera indica el nombre de la clase detectada, mientras que las otras dos entregan las coordenadas (x,y) del centro del rectángulo de detección expresadas en unidades de píxeles. Usaremos estas coordenadas para la creación del mapa de calor en QGIS, un software de información geográfica que cuenta con herramientas para crear mapas de calor con solo cargar una capa ráster y las coordenadas previamente modificadas. Finalmente, testeamos la representación más apropiada del mapa de calor y experimentamos con dos variables: la opacidad y el radio de los centros. El objetivo de estas pruebas fue identificar la combinación que proporcionara los mejores resultados visuales y analíticos.

RESULTADOS

En esta sección presentamos los resultados de la recolección y preparación de datos; entrenamientos y sus desempeños; y finalmente los mapas de calor generados a partir de las detecciones de los equipos de construcción.

RECOLECCIÓN DE DATOS

En las 8 visitas a terreno capturamos más de 7.000 imágenes de los distintos equipos de construcción y el detalle se muestra en la Tabla 2. En el período en que visitamos el proyecto, pudimos observar menos trabajo de la mini retroexcavadora lo que explica que contamos con menos imágenes. Estas imágenes las usamos tanto para los entrenamientos de cada clase de equipos (primeras 7 visitas), como para la etapa de monitoreo de trabajo productivo (visita 8) y la generación de los mapas de calor asociados. Las imágenes fueron extraídas de cada segundo de video, lo que explica el total observado.

Tabla 2. Detalle Recolección de Datos.

Equipo Observado	Grabación/videos [minutos]	Imágenes #
Excavadora	31	1.860
Camión	37	2.220
Excavadora y Camión	48	2.820
Mini Retroexcavadora	14	840
TOTALES	130 min @ 24 FPS	7.740

PREPARACIÓN DE DATOS

En la Figura 3 mostramos una taxonomía que ayuda a clasificar las posturas típicas que asumen los equipos cuando realizan trabajo productivo (verde) o cuando realizan trabajo no contributivo (rojo). La función de la Taxonomía es mostrar las posturas que podían adoptar los equipos y asegurar una cantidad consistente de información durante el proceso de etiquetado. En cada caso, distinguimos entre 6 y 8 posturas. Cada clase se nombró con un código, como 'CAMTP' para el camión en trabajo productivo.

Hicimos el etiquetado de clases en MATLAB, utilizando etiquetas de colores distintos para equipos en trabajo productivo y una etiqueta roja para clases no contributivas (ver Figura 4). Esta elección destacó mejor cada equipo. Etiquetamos más de 3.000 imágenes e incluimos el entorno del equipo de construcción en la zona de interés (suelos, estructuras adyacentes, acopios, etc.).

N°	TAREAS	EQUIPOS	POSTURA EQUIPOS					
			EXCAMTP01	EXCAMTP02	EXCAMTP03	EXCAMTP04	EXCAMTP05	EXCAMTP06
1	Carga de Camión	Camión y Excavadora	TRABAJO PRODUCTIVO					
2	Excavación	Excavadora	EXCATP01	EXCATP02	EXCATP03	EXCATP04	EXCATP05	EXCATNC
			TRABAJO PRODUCTIVO	TRABAJO NO CONTRO				
3	Trasporte áridos y vuelta a posición de carga	Camión	CAMTP01	CAMTP02	CAMTP03	CAMTP04	CAMTP05	CAMTP06
			TRABAJO PRODUCTIVO					
			CAMTP07	CAMTNC				
			TRABAJO PRODUCTIVO	TRABAJO NO CONTRO				
4	Desplazamiento de material y vuelta a zona de carga	Mini Retro	MIRTP01	MIRTP02	MIRTP03	MIRTP04	MIRTP05	MIRTP06
			TRABAJO PRODUCTIVO					

Figura 2. Taxonomía de Clases: (1) Excavadora y Camión; (2) Excavadora; (3) Camión; y (4) Mini Retroexcavadora.

CLASES					
EXCAMTP	EXCATP	EXCATNC	CAMTP	CAMTNC	MIRTP

Figura 4. Ejemplos de etiquetado de clases.

ENTRENAMIENTOS

Para realizar los entrenamientos usamos YOLOv4 en MATLAB. Realizamos más de 25 entrenamientos para todos los equipos, conforme completábamos las 8 visitas a terreno. Las grabaciones las hicimos a dos alturas de vuelo distintas: 60 m y 150 m. Los detalles de tales entrenamientos se muestran en la Tabla 3.

Los primeros entrenamientos corresponden a fotos capturadas en vuelos a 60 m para entrenar el algoritmo en detecciones generales. Se logró un rendimiento satisfactorio con un mAP superior al 70% en las clases EXCATP, CAMTP y EXCAMTP, excepto para la mini retroexcavadora (MIRTP) debido a que las grabaciones logradas tienen deficientes condiciones de luminosidad que dificultan el reconocimiento del equipo (más pequeño) y si realiza trabajo productivo o no. Seleccionamos los entrenamientos en negrita (con *) que son aquellos de mejor desempeño, con mayor número de fotos y varias grabaciones/videos. Escogimos los entrenamientos 9 y 10 con mAP del 89% y 93% porque detectaban mayor variedad de posturas y superan el 70%.

Los entrenamientos con grabaciones a 150 m (15 al 28), se realizaron para abarcar más terreno y mejorar las detecciones a mayor altura y poder diagnosticar el trabajo productivo (visita 8). Estos entrenamientos alcanzaron buenos resultados, con un mAP del 87% para las clases de EXCAMTP y 100% para EXCATP, a excepción del camión (CAMTP). En este caso, el mAP máximo alcanzado fue solo del 41%, muy por debajo del umbral deseado del 70%. Por ende, la idea sería mejorar dichos entrenamientos para lograr una mejor precisión en futuras detecciones y, por ende, obtener un mapa de calor más preciso. Con los vuelos a 150 m no pudimos capturar a la mini retroexcavadora en terreno.

Los gráficos de precisión promedio (mAP) y de pérdida (Training Loss) ubicados en el extremo derecho de la Figura 5, muestran los desempeños de los entrenamientos. Además, la pérdida de validación (curva naranja) fue alta en todos los casos debido a la limitación de datos variados, lo que sugiere que el algoritmo entrenado podría no funcionar bien con diferentes tipos de equipos, aunque tenga un mAP alto. La solución es entrenar el algoritmo con datos variados de diferentes proyectos, condiciones de luminosidad variadas, etc. para mejorar su capacidad de generalización.

Tabla 3. Listado y detalle de Entrenamientos.

Equipo	Clase	Altura Vuelo [m]	Entrenamiento	# Imágenes	mAP
EXCAVADORA	EXCATP	60	1	162	0,31
EXCAVADORA	EXCATP	60	2	324	0,97
EXCAVADORA	EXCATP	60	3	280	0,99
EXCAVADORA *	EXCATP	60	4	184	1,00
CAMIÓN	CAMTP	60	5	84	1,00
CAMIÓN	CAMTP	60	6	153	0,56
CAMIÓN	CAMTP	60	7	153	0,36
CAMIÓN	CAMTP	60	8	152	0,67
CAMIÓN *	CAMTP	60	9	101	0,89
EXCAVADORA Y CAMIÓN *	EXCAMTP	60	10	267	0,93
MINIRETRO	MIRTP	60	11	143	0,026
MINIRETRO	MIRTP	60	12	170	0,54
MINIRETRO	MIRTP	60	13	255	0,66
MINIRETRO *	MIRTP	60	14	330	0,67

EXCAVADORA	EXCATP	150	15	110	0,104
EXCAVADORA	EXCATP	150	16	90	0,847
EXCAVADORA	EXCATP	150	17	190	0,220
EXCAVADORA	EXCATP	150	18	270	0,347
EXCAVADORA *	EXCATP	150	19	90	1,00
CAMIÓN	CAMTP	150	20	150	0,00
CAMIÓN	CAMTP	150	21	180	0,018
CAMIÓN	CAMTP	150	22	100	0,033
CAMIÓN	CAMTP	150	23	90	0,037
CAMIÓN *	CAMTP	150	24	160	0,41
EXCAVADORA Y CAMIÓN	EXCAMTP	150	25	150	0,760
EXCAVADORA Y CAMIÓN	EXCAMTP	150	26	360	0,047
EXCAVADORA Y CAMIÓN	EXCAMTP	150	27	360	0,167
EXCAVADORA Y CAMIÓN *	EXCAMTP	150	28	150	0,87

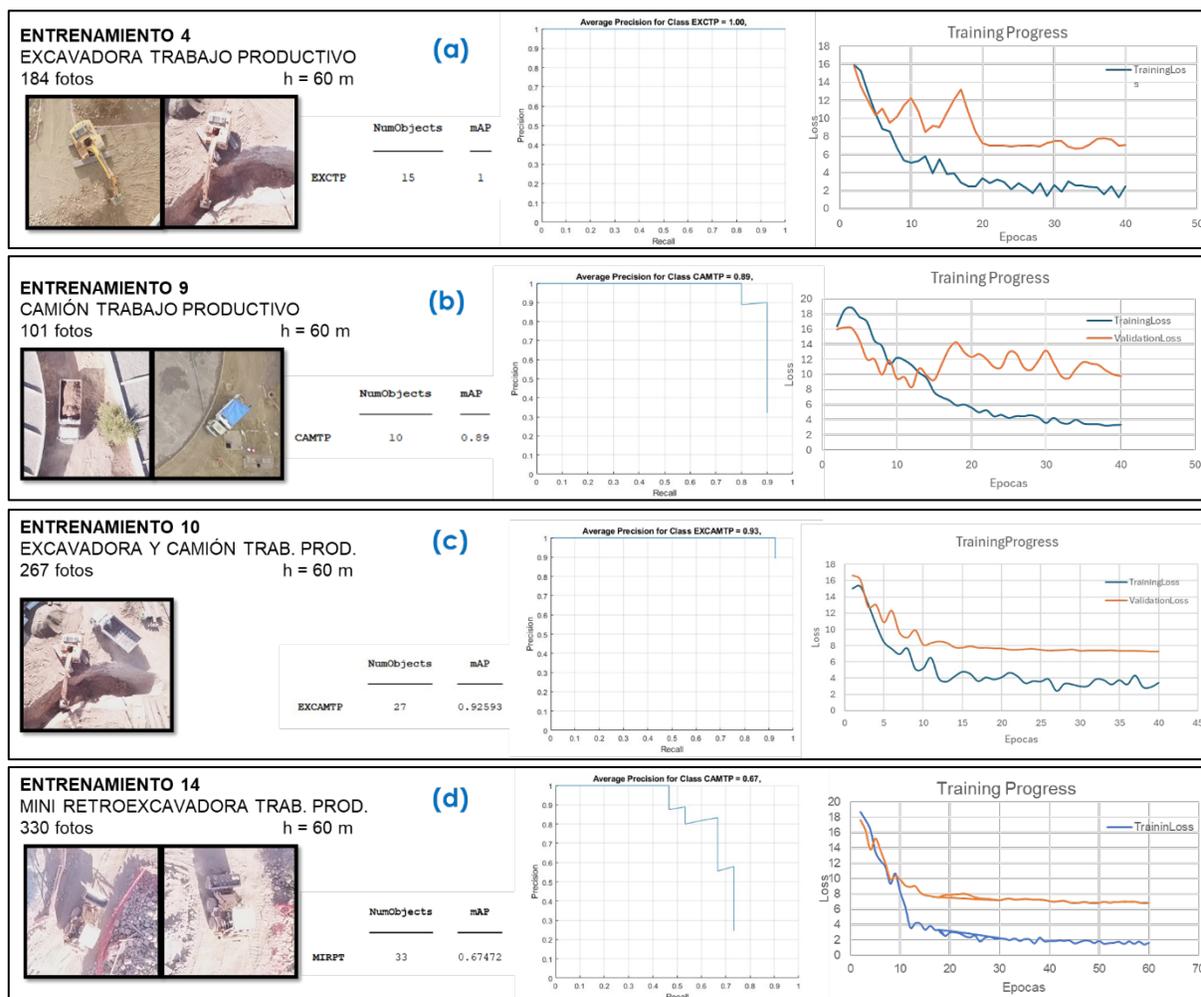


Figura 5. Resumen Entrenamientos (60 m): (a) Excavadora; (b) Camión; (c) Excavadora y Camión; y (d) Mini Retroexcavadora.

OBTENCIÓN DE CENTROS DE DETECCIONES

Como se mencionó en la metodología, para la creación del mapa de calor es necesario obtener los centros de las detecciones. Para esto, desarrollamos un código que automatiza este proceso de manera más eficiente. La Figura 6, muestra la visualización de las detecciones, con un recuadro del color correspondiente a la clase detectada y el centro marcado con una “x”, aunque en ocasiones las “x” no quedan perfectamente centrados en el equipo. Como hicimos entrenamientos para clases por separado, debimos agrupar todos los resultados en una sola matriz con 3 columnas: clase, coord. X, coord. Y. Cada fila corresponde a una detección (centro).



Figura 6. Ejemplo Centro Detecciones.

MAPAS DE CALOR

Usamos QGIS para construir los mapas de calor a partir de la matriz de las detecciones. Primero cargamos la fotografía del terreno completo como capa ráster y luego la matriz con los centros de las detecciones y las clases correspondientes. Usamos la función/herramienta de mapa de calor. Testeamos distintos niveles de opacidad y radios y optamos por usar un 40% de opacidad y un radio de 100 píxeles para el mapa de calor.

En la Figura 7 podemos observar el mapa de calor de todas las detecciones de trabajo productivo ocurridas entre las 9:00 y 9:59 hrs. Para un mejor análisis y referencia visual usamos una cuadrícula de 20 x 20 m. La imagen más grande (izquierda) representa la concentración de trabajo de todos los equipos (flota). En particular, esta se concentra cerca de los 120 m en la dirección X y entre los 80 y 100 m en la dirección Y. Mientras más rojo

mayor concentración de detecciones y mientras más azul, menor concentración. El punto rojo, por tanto, denota el centro del trabajo productivo en esa hora. Las zonas verdes indican que hubo trabajo debido a la movilidad de la excavadora, la cual debía reposicionarse para la carga del camión, y desplazarse en la excavación. Las imágenes más pequeñas de la Figura 7 (derecha) representan la concentración de trabajo de los equipos por separado. Vemos una gran concentración de la excavadora en varias partes del mapa, mientras que la concentración de la excavadora y el camión se encuentra en una zona más acotada. Esto ocurre porque las cargas se realizaban siempre en el mismo lugar, mientras que la excavadora se desplazaba un poco para ubicarse mejor. Las Figuras 8, 9 y 10 representan los mapas de calor del proyecto a las 10:00, 11:00 y 12:00 hrs. respectivamente.

En la Figura 8 la concentración de trabajo es prácticamente la misma, pero observamos un área roja más grande y amplia. Esto nos indica que, probablemente, a las 10:00 hrs. hubo más trabajo (más detecciones) que a las 9:00 hrs., aunque casi siempre en el mismo lugar.

Por último, la Figura 9 (mapa de calor de las 11:00 hrs.) muestra una situación similar a las de las 9:00 y 10:00 hrs., donde el trabajo se concentra casi en el mismo lugar, pero más desplazado hacia la izquierda y con una menor intensidad que a las 10:00 hrs. En la Figura 10 (mapa de calor de las 12:00 hrs.), se observa una concentración más desplazada hacia la derecha.

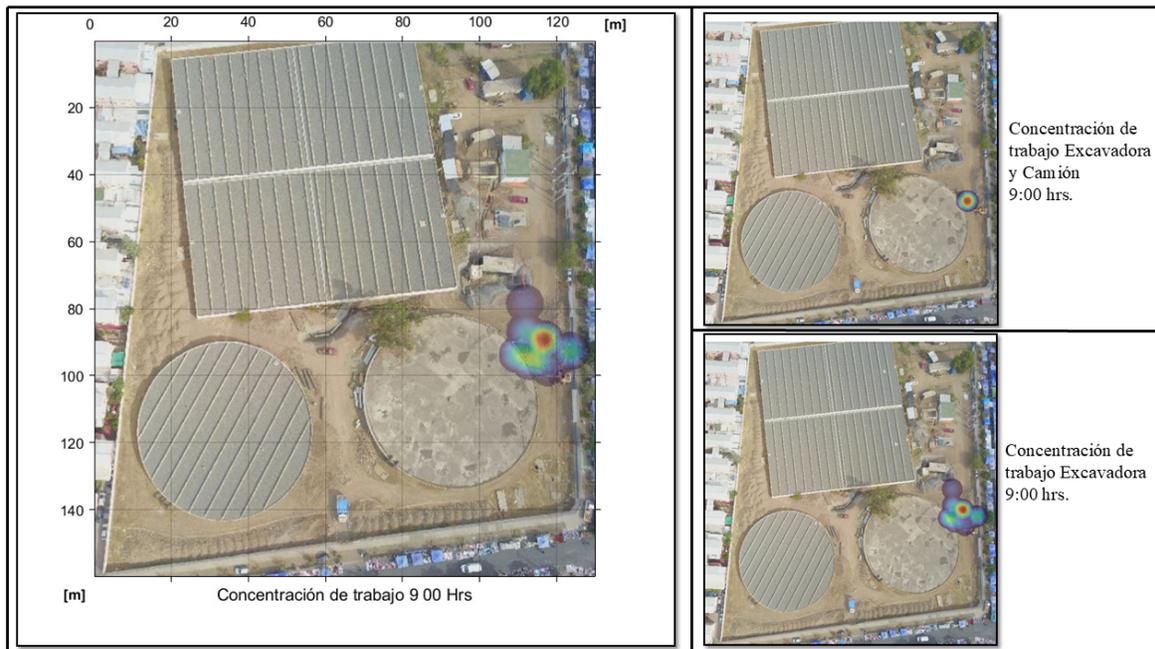


Figura 7. Mapa de Calor 9:00 hrs. Flota equipos (izquierda) y equipos por separado (derecha).

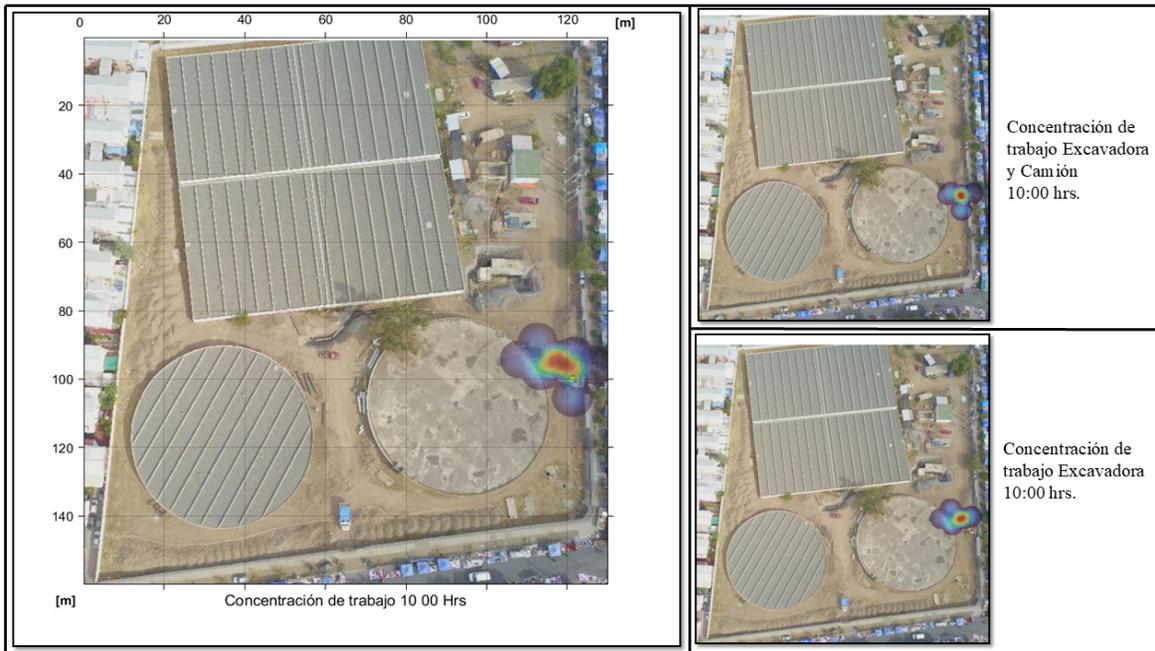


Figura 8. Mapa de Calor 10:00 hrs.

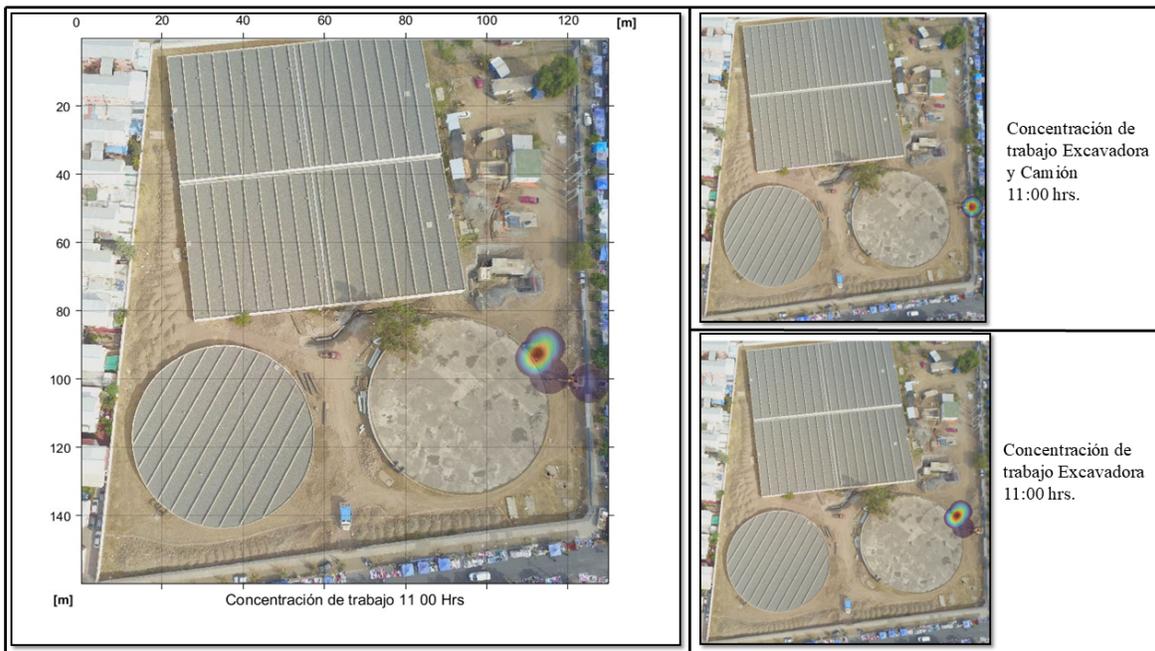


Figura 9. Mapa de Calor 11:00 hrs.

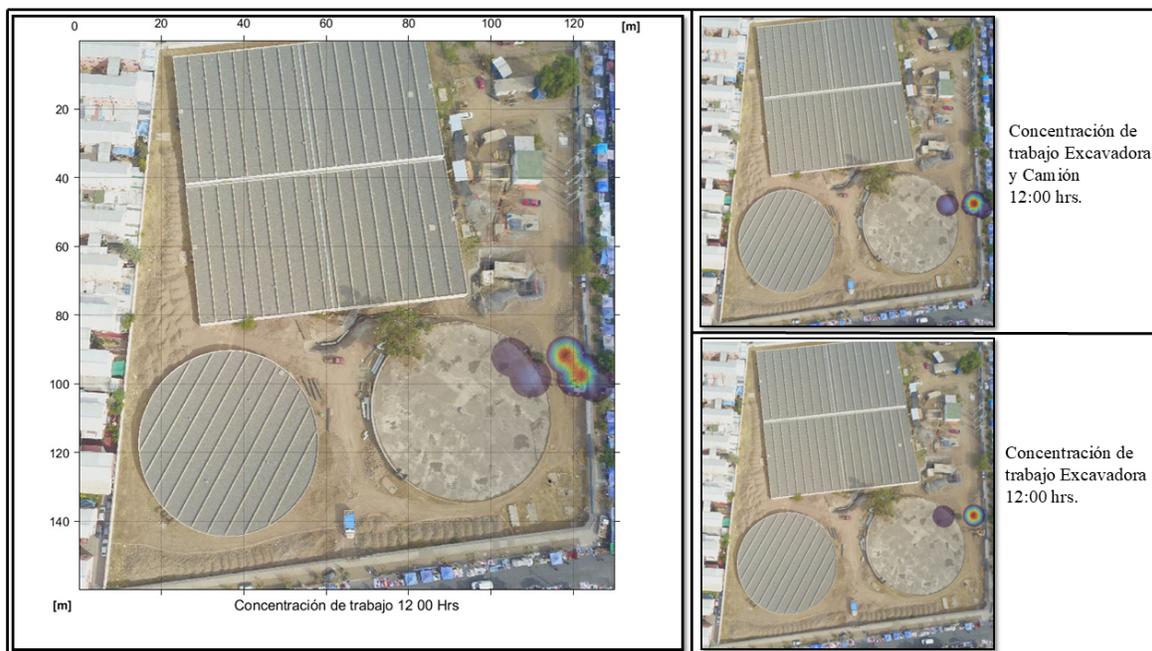


Figura 10. Mapa de Calor 12:00 hrs.

En las Figuras 11 y 12 podemos ver la concentración de trabajo de la flota y de cada equipo en cada hora. En particular, podemos notar que la concentración del trabajo a las 9:00 y 10:00 hrs. para ambos equipos es casi en el mismo lugar, mientras que, para las dos horas siguientes, tiende a desplazarse un poco hacia la derecha. Esto mismo se aprecia si analizamos todo el trabajo en conjunto (Figura 11). El periodo más productivo fue a las 10:00 hrs. Esto probablemente se debe a que como la jornada comienza a las 9:00 hrs, se emplea un poco más de tiempo en preparar los equipos, lo que provoca que estén paralizados durante más tiempo. Mientras que, cerca de la hora de almuerzo (13:00 hrs), se puede concluir que el ritmo de trabajo tiende a bajar un poco, por lo que los equipos también trabajan menos. En general, se observa una buena producción en casi todos los horarios.

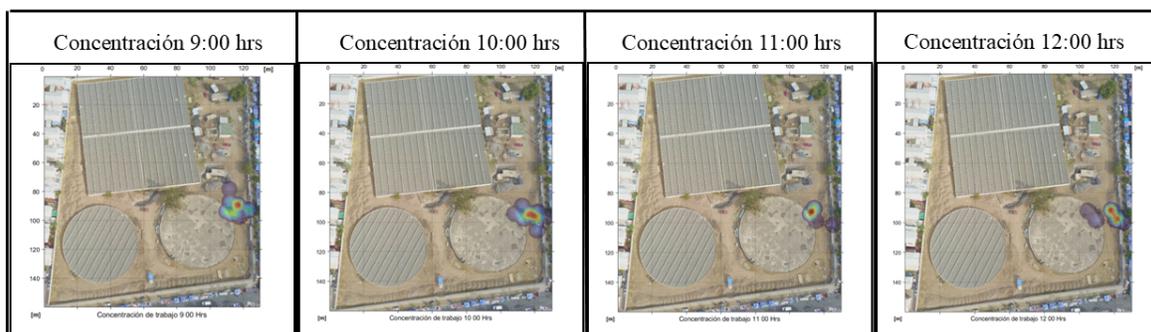


Figura 11. Mapas de Calor Jornada de la mañana para todos los equipos (flota).

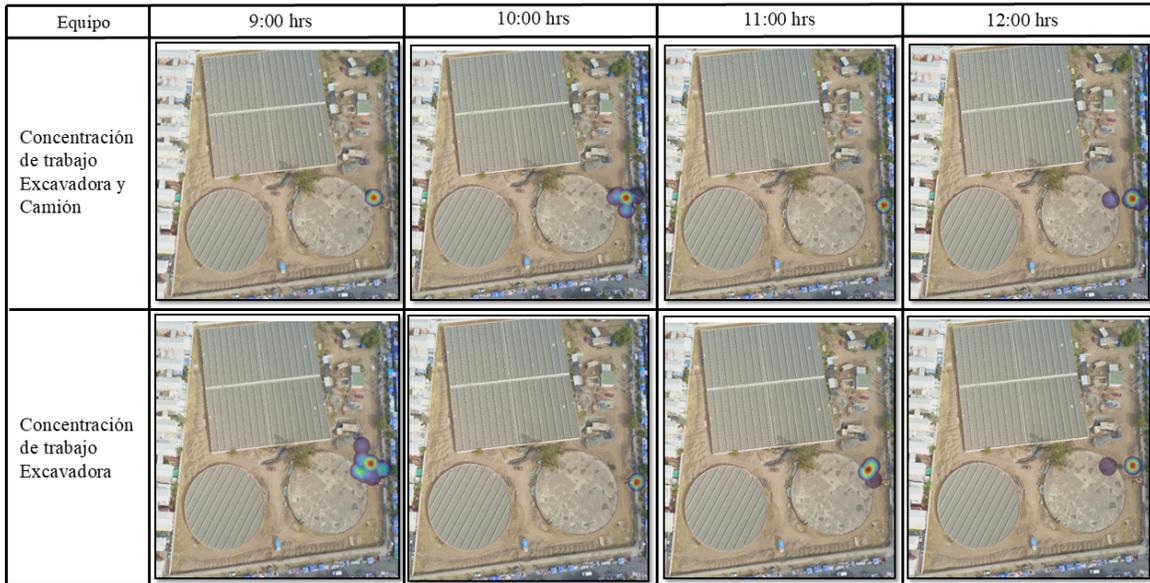


Figura 12. Mapas de Calor Jornada de la Mañana para cada equipo.

ANÁLISIS Y CONCLUSIONES

Esta investigación ha ilustrado un caso donde se implementa el uso de mapas de calor para identificar las zonas donde ocurre más trabajo productivo o donde se concentra el trabajo realizado por equipos de construcción. Nuestro caso de estudio corresponde a un proyecto de movimientos de tierra que emplea excavadoras, camiones y mini retroexcavadoras. La investigación implementa el uso de UAVs para la captura de imágenes, inteligencia artificial (YOLOv4) para la detección de equipos trabajando, y la generación de mapas de calor a partir de las detecciones utilizando un software de tipo GIS (QGIS).

Testeamos varias alturas de vuelo y volamos el UAV a 60 m para capturas focalizadas en un equipo específico lo que nos permitió entrenar el algoritmo detector. Para el diagnóstico del trabajo productivo en un período de tiempo (1 hora o 1 mañana de trabajo) volamos el UAV a 150 m para capturar la totalidad del sitio de trabajo en simultáneo. Usamos los vuelos focalizados (60 m) para entrenar el algoritmo con las diferentes clases definidas. Generamos una taxonomía de posturas de trabajo de los equipos para facilitar el proceso de etiquetado y entrenamiento y garantizar desempeños adecuados. Muestreamos el trabajo productivo volando el UAV (150 m) aproximadamente 2 minutos por cada intervalo de 10 minutos. Repetimos esto 6 veces para construir el mapa de 1 hora de observación. A su vez, repetimos este procedimiento 4 veces para diagnosticar media jornada de trabajo. Presentamos los mapas de calor en un formato horario que resume el trabajo de la flota de equipos y de cada equipo por separado. La generación de estos mapas de calor nos proporciona información sobre la densidad de trabajo de los equipos en el sitio de construcción o espacio de trabajo. Los mapas de calor en construcción pueden ofrecer una alternativa innovadora para visualizar dónde se concentra el trabajo de maquinarias y a partir de esto, tomar medidas tendientes a la mejora productiva del proceso constructivo.

Una limitación de este trabajo fue contar con grabaciones muy similares y focalizadas en zonas próximas. Esto se debió a la naturaleza del proyecto (caso de estudio) que involucraba al subcontrato de movimiento de tierras en un período de tiempo muy acotado. En el futuro, sería recomendable contar con más grabaciones para obtener un conjunto de imágenes más variado de los equipos observados. Por ejemplo, en el caso de la mini retroexcavadora, cuando la capturamos trabajando, las condiciones climáticas (ventoso) y de luminosidad (muy soleado) no nos permitieron contar con un registro adecuado para entrenar el algoritmo clasificador y obtuvimos un mal desempeño (bajo 70% de precisión). Como se trata de un movimiento de tierras, el viento hizo que se levantara polvo y la excesiva luminosidad se tradujo en imágenes saturadas y, por tanto, difíciles de usar. Otras limitaciones incluyen la transformación de coordenadas o la autonomía de vuelo del UAV para registrar un día completo de trabajo.

En futuras investigaciones, se recomienda testear el uso de cámaras fijas ubicadas a gran altura para evitar problemas de autonomía y simplificar el proceso de georreferenciación de la información visual capturada por el UAV. Incluso sería interesante explorar el uso de una flota de drones que puedan grabar varios lugares en simultáneo, para subdividir sitios de construcción más extensos.

REFERENCIAS

- Anwar, N., Izhar, M. A., & Najam, F. A. (2018). Construction monitoring and reporting using drones and unmanned aerial vehicles (UAVs). In *The Tenth International Conference on Construction in the 21st Century (CITC-10)* 8(3), 2-4.
- Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). Yolov4: Optimal speed and accuracy of object detection. arXiv preprint arXiv:2004.10934.
- Chica, J. & Alarcón, L.F. (2019). Metodología de Análisis y Mejoramiento de la Logística y Productividad en la Industria de la Construcción Mediante el Uso de Drones. Tesis MSc., Pontificia Universidad Católica de Chile, Chile.
- García, C. (2022). Generación de mapas de calor mediante un sistema de geoposicionamiento. Tesis Doctoral, Universitat Politècnica de València, España.
- Golovina, O., Teizer, J., & Pradhananga, N. (2016). Heat map generation for predictive safety planning: Preventing struck-by and near miss interactions between workers-on-foot and construction equipment. *Automation in Construction*, 71, 99–115. <https://doi.org/10.1016/j.autcon.2016.03.008>
- Hernández, J. B. (2021). Aplicación de los drones en la industria de la construcción. *Nextia*, (6), 5-16.
- León, N. (2023). Proyecciones para la construcción. *Cámara Chilena de la Construcción*. Retrieved from: <https://www.ccs.cl/wp-content/uploads/2023/11/231123-CChC.pdf>

- Martínez C., L. F., & Alarcón C., L. F. (1988). Programas de mejoramiento de la productividad para obras de construcción. *Revista Ingeniería De Construcción*, (5), 53–79. Retrieved from:
<https://revistaingenieriaconstruccion.uc.cl/index.php/ric/article/view/18075>
- Melchiorre, M., Bacchi, L., Palmieri, P., Ruggeri, A., Salamina, L., & Mauro, S. (2024). A model-based framework to prevent excavator induced damage in operations on natural gas pipelines. *Engineering Failure Analysis*, *164*, 108659.
- Netek, R., Pour, T., & Slezakova, R. (2018). Implementation of Heat Maps in Geographical Information System - Exploratory Study on Traffic Accident Data. *Open Geosciences*, *10*(1), 367–384. <https://doi.org/10.1515/geo-2018-0029>
- Obiuto, N. C., Adebayo, R. A., Olajiga, O. K., & Festus-Ikhuoria, I. C. (2024). Integrating artificial intelligence in construction management: Improving project efficiency and cost-effectiveness. *Int. J. Adv. Multidisc. Res. Stud*, *4*(2), 639-647.
- Oglesby, C. H., Parker, H. W., & Howell, G. A. (1989). *Productivity improvement in construction*. McGraw-Hill.
- Pedaneekar, T., Kedare, R., & Sengupta, A. (2019). Monitoring tumor progression by mapping skin microcirculation with laser Doppler flowmetry. *Lasers in Medical Science*, *34*(1), 61–77. <https://doi.org/10.1007/s10103-018-2600-z>
- Pérez, C.T., Wandahl, S. & Arildsen, M.R. (2024). Relationship between time spent in value-adding work categories and workspaces. In D. B. Costa, F. Drevland, & L. Florez-Perez (Eds.), *Proceedings of the 32nd Annual Conference of the International Group for Lean Construction (IGLC32)*, 454–465. <https://doi.org/10.24928/2024/0189>
- Polo, E., Llaque, G., & Luján, J. (2022). *Aplicación de Sistemas de Información Geográfica al Estudio del Riesgo y Prevención de Incendios Forestales en Áreas Naturales Protegidas de Cuzco*. Tesis Ingeniería Ambiental. Universidad Privada del Norte. Trujillo, Perú.
- Rebolledo, F., & Toledo, M. (2023). *Detección y Medición de Trabajo en Equipos de Construcción Mediante Machine Learning*. Tesis de Ingeniería Civil. Universidad Andrés Bello. Santiago, Chile.
- Shehadeh, A., Alshboul, O., Tatari, O., Alzubaidi, M. A., & Hamed El-Sayed Salama, A. (2022). Selection of heavy machinery for earthwork activities: A multi-objective optimization approach using a genetic algorithm. *Alexandria Engineering Journal*, *61*(10), 7555–7569. <https://doi.org/10.1016/j.aej.2022.01.010>
- Smith, S. (1999). Earthmoving productivity estimation using linear regression techniques. *Journal of Construction Engineering and Management*. *125*(3), 131-141.
[https://ascelibrary.org/doi/abs/10.1061/\(ASCE\)0733-9364\(1999\)125:3\(133\)](https://ascelibrary.org/doi/abs/10.1061/(ASCE)0733-9364(1999)125:3(133))

- Son, H. & Kim, C. (2021). Integrated worker detection and tracking for the safe operation of construction machinery. *Automation in Construction*. Volume 126. 103670. <https://doi.org/10.1016/j.autcon.2021.103670>.
- Vilca, M. P. & Guzmán, C. (2014). Mejora de la productividad por medio de las cartas de balance en las partidas de solaqueo y tarrajeo de un edificio multifamiliar. Tesis de Ingeniería Civil. Universidad Peruana de Ciencias Aplicadas, Perú.
- Zhao, J., Seppänen, O., & Peltokorpi, A. (2020). Applying heat maps to define workspace in construction based on real-time tracking system with coordinate positioning information. *IGLC 28 - 28th Annual Conference of the International Group for Lean Construction 2020*, 841–852. <https://doi.org/10.24928/2020/0014>
- Zhou, Q., Qin, J., Xiang, X., Tan, Y., & Xiong, N. N. (2021). Algorithm of helmet wearing detection based on AT-YOLO deep mode. *Computers, Materials and Continua*, 69(1), 159–174. <https://doi.org/10.32604/cmc.2021.017480>