

Universidad de Lima
Facultad de Ingeniería
Carrera de Ingeniería Civil



COMPARACIÓN DE METODOLOGÍAS DE PROCESOS AUTOMATIZADOS PARA EL RENDIMIENTO DE EXCAVADORAS EN UNA EDIFICACIÓN

Tesis para optar el Título Profesional de Ingeniero Civil

Adriana Camila Delgado Nalvarte

Código 20170474

Alejandro Martin Gomez Garcia

Código 20162079

Asesor

Ana Felicita Luna Torres

Co-Asesor

Mónica Alejandra Vergara Olivera

Lima – Perú

Mayo del 2023





**COMPARISON OF AUTOMATED PROCESS
METHODOLOGIES FOR EXCAVATOR
PERFORMANCE IN CONSTRUCTION**

TABLA DE CONTENIDO

RESUMEN	11
ABSTRACT	12
1.1 Planteamiento del Problema.....	13
1.2 Justificación.....	13
1.3 Objetivos	14
1.3.1 Objetivo General.....	14
1.3.2 Objetivos Específicos	14
1.4 Hipótesis.....	15
CAPÍTULO II: MARCO TEÓRICO-CONCEPTUAL	16
2.1 Conceptos Preliminares.....	16
2.1.1 Movimiento de Tierras	16
2.1.2 Excavadoras	18
2.1.3 Rendimiento de excavadoras	23
2.1.4 Cálculo de rendimiento de excavadoras.....	23
2.2 Inteligencia Artificial (IA)	27
2.2.1 Antecedentes	27
2.2.2 Definición.....	27
2.2.3 Ramas y Campos de la IA	28
2.2.4 Redes Neuronales Artificiales (RNA)	29
2.2.5 Redes Neuronales Convolucionales (CNN).....	30
2.3 Estado del arte.....	35

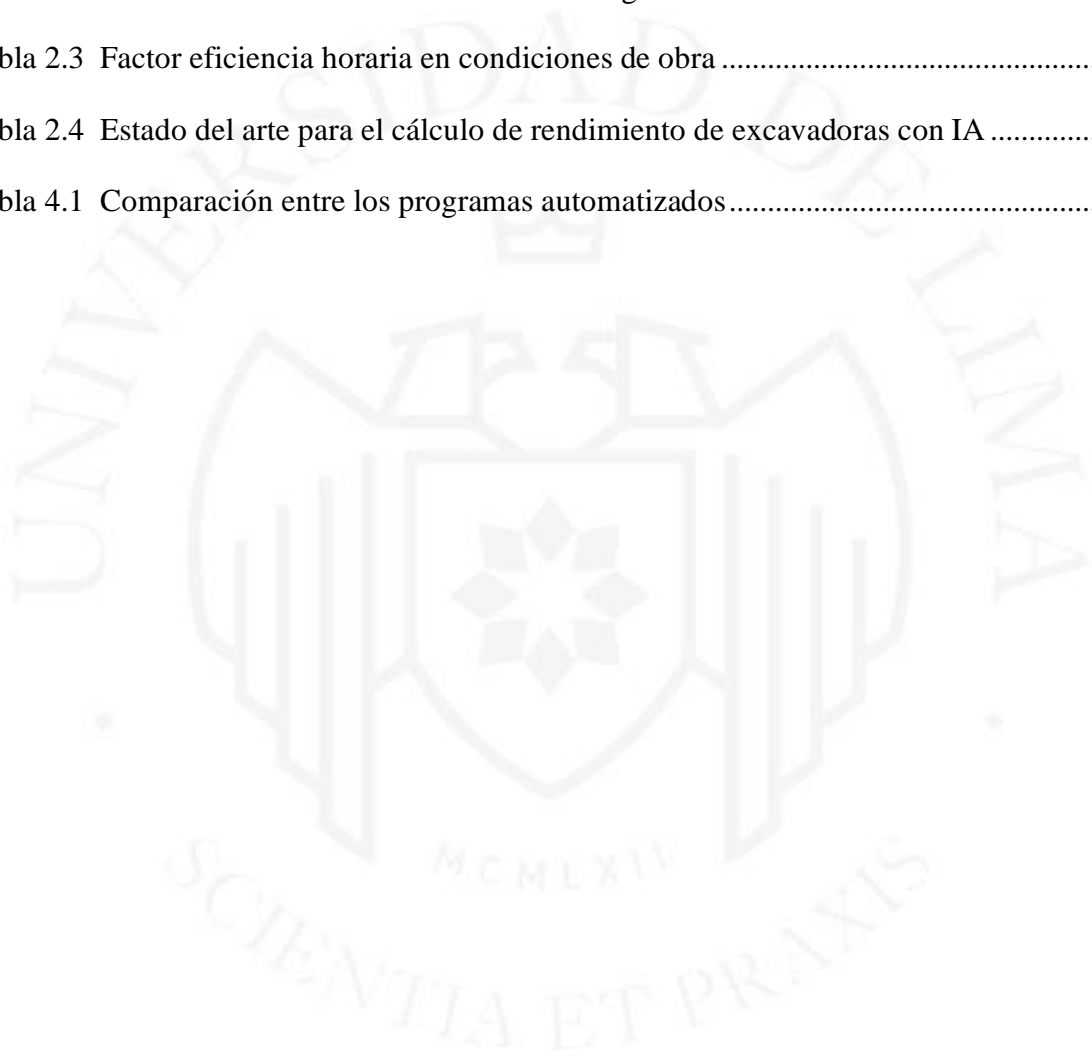
2.3.1	Análisis de la revisión literaria sistemática	36
CAPÍTULO III: MARCO METODOLÓGICO		42
3.1	Tipo de estudio.....	42
3.2	Sujeto de Estudio	43
3.2.1	Ubicación	43
3.2.2	Peculiaridades	44
3.2.3	Necesidades o flujo de los usuarios	44
3.3	Técnicas y procesos de recolección y procesamiento de datos.....	44
3.3.1	Metodología para el cálculo del rendimiento automatizado	44
3.3.2	Metodología para el análisis comparativo.....	45
3.3.3	Metodología para la obtención del <i>dataset</i>	46
3.4	Diseño de Recolección de Datos	47
3.5	Procesamiento y Análisis de Datos	49
3.5.1	Validación del cálculo Manual	49
3.5.2	Modelo para generación del <i>dataset</i>	51
CAPÍTULO IV: RESULTADOS.....		53
4.1	Rendimiento de excavadoras automatizado en Excel	53
4.2	Rendimiento de excavadoras automatizado en el programa RENDEXCA	54
4.3	<i>Dataset</i> generado para entrenar la CNN.....	56
4.4	Análisis Comparativo del rendimiento de excavadora con la forma automatizada en la hoja de Excel y el programa RENDEXCA	58
CAPÍTULO V: DISCUSIÓN		60
CONCLUSIONES.....		61
RECOMENDACIONES		62

REFERENCIAS	63
BIBLIOGRAFÍA	67
ANEXOS.....	71



ÍNDICE DE TABLAS

Tabla 2.1 Propiedades representativas de tierras y rocas.....	18
Tabla 2.2 Cambio volumétrico de los materiales según su estado.....	24
Tabla 2.3 Factor eficiencia horaria en condiciones de obra	26
Tabla 2.4 Estado del arte para el cálculo de rendimiento de excavadoras con IA	35
Tabla 4.1 Comparación entre los programas automatizados.....	59



ÍNDICE DE FIGURAS

Figura 2.1 Secuencia de actividades	16
Figura 2.2 Partes de una excavadora sobre orugas	20
Figura 2.3 Excavadora sobre ruedas M322D2	20
Figura 2.4 Miniexcavadora sobre ruedas M322D2	21
Figura 2.5 Excavadora de largo alcance 352	21
Figura 2.6 Excavadora Hidráulica R9600	22
Figura 2.7 Draga retroexcavadora con cuchara de 1.9CBM	22
Figura 2.8 Clasificación de redes neuronales	31
Figura 2.9 Esquema del aspecto de una red neuronal	32
Figura 2.10 Valores de los pixeles de una imagen	33
Figura 2.11 Proceso de propagación hacia adelante	34
Figura 2.12 Proceso de propagación hacia atrás	34
Figura 3.1 Ubicación del pabellón I1	43
Figura 3.2 Metodología para el cálculo del rendimiento automatizado	45
Figura 3.3 Metodología para la obtención del dataset	47
Figura 3.4 Algoritmo de extracción de “frames”	48
Figura 3.5 Collage de las fotos extraídas	49
Figura 3.6 Capacidad del cucharón 04	50
Figura 3.7 Clasificación manual de fotogramas en LabelImg	51
Figura 3.8 Coordenadas de las excavadoras de un fotograma	52
Figura 4.1 Resultado del cálculo en la hoja de Excel	53

Figura 4.2 Resultado del cálculo en RENDEXCA55

Figura 4.3 Resultado del entrenamiento56

Figura 4.4 Resultado del entrenamiento para la identificación de excavadoras57



ÍNDICE DE ANEXOS

Anexo 1: Hoja de materialidad.....	72
Anexo 2: Variables de estudio.....	77
Anexo 3: Matriz ODS Objetivo #9	78



RESUMEN

En las edificaciones, el movimiento de tierras es una de las partidas más importantes dentro de los procesos constructivos, es primordial comprobar que el tiempo de ejecución de esta partida esté acorde al cronograma de actividades, y esto se relaciona directamente con el rendimiento de las maquinarias para el movimiento de tierras.

Por ello, la presente investigación de tipo cuantitativa se centra en estudiar diferentes metodologías para determinar los rendimientos de las maquinarias para el movimiento de tierras, las metodologías estudiadas son: Inteligencia artificial, automatización de conceptos convencionales mediante hojas de cálculo, y automatización usando un programa denominado RENDEXCA.

A través de esta investigación se estudiaron conceptos asociados a la inteligencia artificial, potente herramienta para la computación evolutiva, investigaciones han demostrado que hay varias maneras para automatizar procesos manuales; siendo un subcampo de esta, las redes neuronales convolucionales. Las mencionadas CNN (Convolutional Neural Networks) utilizan fotogramas como entradas y algoritmos para su procesamiento.

Sin embargo, dada la naturaleza de los datos se trabajó usando hojas de cálculo para el rendimiento de excavadoras, luego se organizó la información mediante la creación de hojas en Excel y software RENDEXCA.

Posteriormente, se procedió a realizar un análisis comparativo entre las distintas metodologías y se adoptó como mejor opción el uso del programa RENDEXCA en el cálculo del rendimiento de excavadoras.

Palabras clave: Basado en la Visión, Excavadoras, Monitoreo de la productividad, Movimiento de tierras, Fotogramas

ABSTRACT

In construction, earth moving is one of the most important items within the construction processes, it is essential to check that the execution time of this item is according to the schedule of activities, and this is directly related to the performance of earth moving machinery.

Therefore, the present research of quantitative type, focuses on studying different methodologies to determine the performance of earthmoving machinery, the methodologies studied are: Artificial intelligence, automation of conventional concepts using spreadsheets, and automation using a program called RENDEXCA.

Through this research we studied concepts associated with artificial intelligence, a powerful tool for evolutionary computation, research has shown that there are several ways to automate manual processes; being a subfield of this, the convolutional neural networks. The aforementioned CNNs (Convolutional Neural Networks) use frames as inputs and algorithms for their processing.

However, given the nature of the data, we worked using spreadsheets for excavator performance, then the information was organized by creating Excel sheets and RENDEXCA software.

Subsequently, a comparative analysis was carried out between the different methodologies and the use of the RENDEXCA program was adopted as the best option for calculating excavator performance.

Key words: Vision Based, Excavators, Productivity monitoring, Earthmoving, Photograms

CAPÍTULO I: INTRODUCCIÓN

1.1 Planteamiento del Problema

Al inicio de cualquier proyecto de construcción se desarrolla el movimiento de tierras. Esta etapa se define como el conjunto de actividades preliminares a realizar en el terreno, como tareas de desbroce y trabajos de excavación. Esta última, se puede realizar de dos maneras: de forma manual y/o mecánica mediante excavadoras (Ideconsa, 2018).

Actualmente, una de las causas de retrasos en la construcción recae en la pérdida de productividad, siendo el rendimiento de excavadoras un factor influyente de ésta, ya que, mide el avance de excavación en un tiempo determinado. Al no llegar al avance programado aumentan los costos, por lo que se debería implementar una metodología para disminuirlos usando como alternativa diferentes procesos automatizados, ya que el uso de procesos automatizados puede ayudar a reducir costes al disminuir la necesidad de recursos humanos para realizar manualmente estos procesos (Fisk & Reynolds, 2006).

Por otro lado, en la actualidad el desarrollo progresivo en el área de la Inteligencia Artificial influye fuertemente en los diferentes ámbitos y sectores de la ingeniería civil mejorando su implementación en tecnología. Por ejemplo, el impacto que podría generar en el Perú sería de un incremento del 7.3% del PBI para el año 2030 y consecuentemente podría aumentar los servicios empresariales con personal formado en inteligencia artificial según informó el Centro Nacional de Planeamiento Estratégico (Peru21, 2023).

1.2 Justificación

El problema de los proyectos de construcción es que presentan pérdidas económicas por una diferencia en el cálculo del rendimiento teórico de las excavadoras con el rendimiento real. Esta diferencia se presenta porque en obra existen factores determinantes como el clima, ambiente de trabajo o fallas mecánicas que limitan el rendimiento esperado de la maquinaria (Fisk & Reynolds, 2006).

Es por eso que mediante el desarrollo de las investigaciones de metodologías que automaticen estos procesos se ha logrado encontrar que es posible implementar diferentes métodos para calcular el rendimiento de las maquinarias. Por lo tanto, es necesario realizar esta investigación porque debemos comprobar si la creación de una hoja de Excel automatizada y el programa RENDEXCA en el cálculo del rendimiento de excavadoras es imprescindible para esta problemática, comprobando así, si la utilización de programas automatizados ahorra significativamente tiempos.

Por otro lado, se busca aportar una base de datos (*dataset*) de imágenes clasificadas de actividades realizadas por excavadoras a partir de videos obtenidos de campo con la ayuda de las redes neuronales convolucionales (CNN, por sus siglas en inglés).

Asimismo, nuestra investigación se alinea al objetivo número 9 de los ODS (Industria, innovación e infraestructuras) porque se enfoca en países en desarrollo como Perú para mejorar su capacidad tecnológica e investigación científica. Apoyando así el desarrollo de las mismas e incentivando las innovaciones (ONU, 2015).

1.3 Objetivos

1.3.1 Objetivo General

- Comparar los resultados del rendimiento de excavadoras obtenido mediante la automatización en una hoja de Excel y en el programa RENDEXCA.

1.3.2 Objetivos Específicos

- Desarrollar un programa para automatizar los cálculos de rendimiento de excavadoras.
- Generar el manual de usuario para el programa RENDEXCA
- Calcular el rendimiento de los equipos de manera convencional
- Calcular el rendimiento de los equipos de manera automatizada
- Explorar nuevas opciones de generación de información a utilizar en automatización (*datasets*, redes neuronales)

1.4 Hipótesis

El cálculo del rendimiento de las excavadoras podría ser optimizado mediante el programa RENDEXCA, el cual, generará resultados más inmediatos. Así mismo, esta metodología a largo plazo propondrá una base de datos acumulable y permitirá una mayor eficiencia ya que automatizará dicho proceso.



CAPÍTULO II: MARCO TEÓRICO-CONCEPTUAL

Este capítulo aborda temas relevantes para la línea de investigación “Innovación: tecnologías y productos” de la Universidad de Lima y del área académica de la Carrera de Ingeniería Civil, a partir de la construcción del Marco Teórico sobre conceptos teóricos, metodologías como los programas de cómputo y las CNN. Posteriormente, se presenta el estado del arte destacando los estudios de caso y revisiones con aplicabilidad de técnicas para obtener el rendimiento de excavadoras.

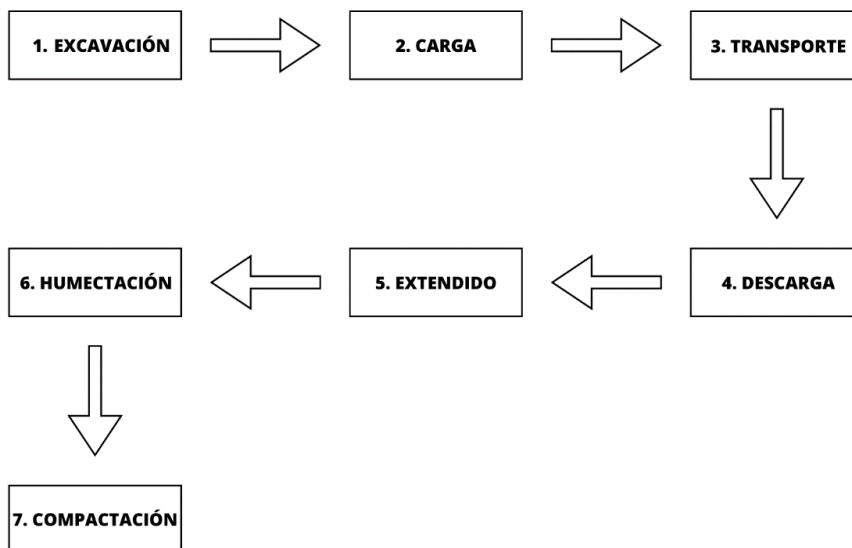
2.1 Conceptos Preliminares

2.1.1 Movimiento de Tierras

Esta etapa se define como el conjunto de actividades preliminares a realizar en el terreno de forma localizada y masiva mediante trabajos manuales y con maquinarias respectivamente (Ideconsa, 2018). El movimiento de tierras, incluye actividades como las mostradas en la figura 2.1.

Figura 2.1

Secuencia de actividades



Con respecto al conjunto de actividades mencionado, se puede realizar en forma manual (mano de obra) o en forma mecánica (uso de maquinarias pesadas). De esta secuencia de actividades, nos vamos a enfocar en la de excavación.

Cabe resaltar que previo al inicio de operaciones del movimiento de tierras, se debe definir el tipo de proyecto a ejecutar ya sea edificación, paisajística o minera para de esta forma, poder realizar una intervención al terreno como la limpieza de arbustos, plantas, maleza y basura que pueda encontrarse in situ. A toda esta operación se le denomina despeje y desmonte (Bello & Álvarez, 2015).

Por otro lado, las tierras excavadas presentan un porcentaje de esponjamiento que depende del tipo de suelo, por ejemplo, en terrenos sueltos existe una variación del 10%, mientras que en terrenos duros y rocosos de 20% o 40% aproximadamente. Lo que debe tomarse en cuenta a la hora de calcular el volumen de material excavado (conocido como “metrado”) y de presupuestar el proyecto (Peurifoy et al., 2006).

Tabla 2.1*Propiedades representativas de tierras y rocas*

Material	Peso en Banco (kg/m³)	Peso Suelto (kg/m³)	Porcentaje de Esponjamiento	Factor de Esponjamiento
Arcilla seca	1.6	1.185	36	0.74
Arcilla húmeda	1.78	1.305	35	0.74
Tierra seca	1.66	1.325	25	0.8
Tierra Húmeda	1.895	1.528	25	0.8
Tierra y grava	1.895	1.575	20	0.83
Grava seca	1.66	1.475	12	0.89
Grava húmeda	2.02	1.765	14	0.88
Caliza	2.61	1.63	60	0.63
Roca, bien explotada	2.49	1.586	60	0.63
Arena seca	1.542	1.34	15	0.87
Arena húmeda	1.6	1.4	15	0.87
Esquisito	2.075	1.47	40	0.71

Nota. De “*Construction Planning. Equipment and Methods*” Por R. L. Peurifoy, C. Schenayder y A. Shapira, 2011. (<https://n9.cl/aq26h>)

2.1.2 Excavadoras

En el sector construcción existen diferentes maquinarias pesadas para facilitar las operaciones de movimiento de tierras masivo, entre ellas la más utilizada es la excavadora. Esta se diferencia de las demás debido a que es un vehículo autopropulsado capaz de desplazarse de un lugar a otro y que, para sus operaciones principales de excavación y carga, se fija en el terreno dándole así una mejor estabilidad. Asimismo, las excavadoras están diseñadas principalmente para excavar utilizando cucharones, por el cual eliminan grandes cantidades de tierra o material particulado (MOTORGIGA, 2023).

Por otro lado, las excavadoras realizan seis tipos de operaciones, a saber, “excavación”, “acarreo”, “vertido”, “balanceo”, “desplazamiento” y “parada”, y tienen dos

tipos principales de patrones secuenciales, es decir, características visuales y ciclos de operación (Kim & Chi, 2019).

Se menciona seis tipos de excavadoras con sus beneficios y limitaciones.

- Excavadoras de orugas. También conocidas como excavadoras compactas, son óptimas para trabajos de construcción y minería pesada. Su sistema de ruedas de cadena les permite deslizarse y escalar colinas con menos riesgo, aunque son más lentas que otras excavadoras, proporcionan mayor equilibrio, flexibilidad y estabilidad en general en terrenos desiguales.
- Excavadoras de ruedas. Este vehículo realiza esencialmente la misma función que la alternativa anterior, pero con importantes cambios de rendimiento debido al movimiento de las ruedas. Ofrece velocidad y maniobrabilidad en superficies planas y de concreto, pero no funciona mejor en terrenos accidentados y empinados.
- Miniexcavadoras. Las miniexcavadoras se adaptan fácilmente a espacios reducidos y se puede utilizar en interiores. Sin embargo, solo pueden manejar cargas pequeñas.
- Excavadoras de largo alcance. Como su nombre sugiere, una excavadora de largo alcance cuenta con una sección de brazo y pluma más larga. El diseño permite una mejor operación en ubicaciones de difícil acceso.
- Excavadoras hidráulicas. Es el más utilizado en la industria minera y también puede funcionar eficazmente en otras áreas. Tiene un motor muy potente y el cucharón tiene mayor capacidad, pero es demasiado pesado para algunos proyectos (Ipesa, 2020).
- Draga excavadora. Es una excavadora grande que utiliza un sistema único de cuerda de izaje y línea de arrastre, y se utiliza en proyectos de ingeniería civil a gran escala debido a su peso y tamaño (Ipesa, 2020).

Figura 2.2

Partes de una excavadora sobre orugas



Nota. De Creixer, 2021. (<https://creixer.mx>)

Figura 2.3

Excavadora sobre ruedas M322D2



Nota. De "Excavadora sobre ruedas CAT". Por UNIMAQ, 2023. (<https://n9.cl/6zbw1>)

Figura 2.4

Miniexcavadora sobre ruedas M322D2



Nota. De “Miniexcavadora modelo PC26MR-3”. Por KOMATSU, 2023. (<https://n9.cl/t5m58>)

Figura 2.5

Excavadora de largo alcance 352



Nota. De “Excavadora de largo alcance CAT 352 de hasta 19.6m y profundidad de excavación de 13.04m”. Por CAT, 2023. (<https://n9.cl/u5c6b>)

Figura 2.6

Excavadora Hidráulica R9600



Nota. De “Excavadora hidráulica R9600 con tecnología de última generación para minería”. Por Tiempo Minero, 2021. (<https://n9.cl/mz5oo>)

Figura 2.7

Draga retroexcavadora con cuchara de 1.9CBM



Nota. De “Excavadora con cangilones giratoria se instala en el cuerpo flotante en forma de caja de acero de la draga de cangilones”. Por Dredger, 2023. (<https://n9.cl/meiqa>)

2.1.3 Rendimiento de excavadoras

El rendimiento de las excavadoras es un factor que influye en la productividad del movimiento de tierras.

Este se define como la cantidad de material movido, transportado, compactado o instalado por maquinaria pesada operada por trabajadores calificados y, dependiendo de la maquinaria que se esté operando, el rendimiento suele ser expresado mediante unidades de volumen por unidad de tiempo (Carranza & Combata, 2015).

Cuando calculamos el rendimiento de excavadoras podemos planificar de una manera más acertada la estimación de costos y el cronograma de actividades, es por eso que los resultados calculados deben ser precisos ya que estos están involucrados en el juicio de decisiones a nivel directivo. Asimismo, la supervisión de la productividad de los equipos pesados, que es un proceso de medición, análisis y mejora de la eficiencia operativa y el rendimiento de los equipos, es una tarea importante para gestionar y completar con éxito los proyectos de movimiento de tierras (Kim & Chi, 2019).

2.1.4 Cálculo de rendimiento de excavadoras

Para el cálculo del rendimiento de excavadoras de construcción, primero se ha analizado los estados de los materiales durante el proceso de movimiento de tierras. A continuación, se presentan dichos estados:

- En banco. Se define así a aquel material que no ha sido manipulado o perturbado por acción humana es decir tal cual se encuentra en la naturaleza.
- Suelto. Se define así a aquel material que ha sido manipulado o perturbado por cualquiera de las actividades inherentes del proceso de movimiento de tierras.
- Compacto. Es aquel material que ha sido manipulado o perturbado durante la fase de compactación como por ejemplo durante la etapa de construcción de terraplenes.

Se ha explicado cada uno de estos procesos para poder entender mejor el cambio volumétrico de los materiales que se presenta en la tabla 2.2.

Tabla 2.2*Cambio volumétrico de los materiales según su estado*

Material	Estado Actual	Volumen en banco (E.B.) en m ³	Volumen suelto (E.S.) en m ³	Volumen compactado (E.C.) en m ³
Arena	E.B.	1	1.01	0.95
	E.S.	0.9	1	0.86
	E.C.	1.06	1.17	1
Grava	E.B.	1	1.25	0.9
	E.S.	0.8	1	0.72
	E.C.	1.11	1.39	1
Arcilla	E.B.	1	1.43	0.9
	E.S.	0.7	1	0.63
	E.C.	-	-	1
Tierra Común	E.B.	1	1.25	0.9
	E.S.	0.8	1	0.72
	E.C.	1.11	1.39	1

Nota. De “La maquinaria pesada en movimientos de tierras” Por R. Vargas, 1999.

Como se observa en la tabla 2.2, se ha podido obtener los volúmenes suelto y compactado en m³ a partir de un volumen en banco de prueba y fijo de 1 m³ mediante los factores de expansibilidad y comprensibilidad que se detallan a continuación:

- **Expansibilidad.** También denominado factor de abundamiento o hinchamiento. Este coeficiente representa el incremento porcentual de volumen que relaciona directamente los estados de materiales tanto en *banco* como *suelto*. Este concepto presenta una fórmula de la siguiente manera:

$$\text{Expansibilidad (\%)} = \frac{\text{Volumen suelto} - \text{Volumen en banco}}{\text{Volumen en banco}} \times 100$$

Como se puede observar, el *volumen suelto* se puede despejar de esta fórmula obteniéndose lo siguiente:

$$\text{Volumen suelto} = \text{Volumen en banco} \times \left(1 + \frac{\text{expansibilidad (\%)}}{100} \right)$$

- Compresibilidad. También denominado factor de reducción, este coeficiente representa la reducción porcentual de volumen entre los estados de en *banco* y *compacto* con respecto al estado en *banco*. Este concepto presenta una fórmula de la siguiente manera:

$$\text{Compresibilidad (\%)} = \frac{\text{Volumen en banco} - \text{Volumen compactado}}{\text{Volumen en banco}} \times 100$$

Como se puede observar, el *volumen compactado* se puede despejar de esta fórmula obteniéndose lo siguiente:

$$V_{\text{compactado}} = V_{\text{banco}} \times \left(1 - \frac{\text{compresibilidad (\%)}}{100} \right)$$

Asimismo, se ha empleado la siguiente fórmula para el cálculo del rendimiento de excavadoras de construcción:

Rendimiento:

$$R = \frac{3600 \times Q \times F \times E \times K}{C_m}$$

Donde:

3600: Número de segundos en una hora

Q: Capacidad del cucharón de la pala en m³

F: Factor de conversión de los suelos sin unidades

E: Eficiencia de la máquina en fracción unitaria

K: Factor de eficiencia del cucharón sin unidades

C_m: Tiempo que dura el ciclo de trabajo en segundos

R: Rendimiento de excavadoras de construcción en m³ por hora

A continuación, se va a explicar en mayor detalle cada una de las variables de la fórmula anterior.

- Capacidad del cucharón de la pala (Q). Se define como la cantidad de material a cargar y remover de la zona de trabajo por parte del sujeto de estudio que son las excavadoras empleadas en el proyecto, las cuales responden a los modelos de Hyundai Robex 220LC-9SB y Doosan DX225LCA, importantes en el cálculo ya que, de sus fichas técnicas, se obtuvo la variable de capacidad del cucharón de la pala (Q) en m^3 .
- Factor de conversión volumétrica de los suelos (F). Se ha obtenido mediante los valores de la tabla 2.2 anteriormente mencionada.
- Eficiencia de la máquina (E). También denominado factor de rendimiento de trabajo o eficiencia. Este factor vendría a ser el tiempo real o efectivo de trabajo ya sea durante el día o cada hora que se asigna para una actividad en específico según condiciones de obra.

Tabla 2.3

Factor eficiencia horaria en condiciones de obra

Equipo	Excelente (min/h)	Promedio (min/h)	Desfavorable (min/h)*
Cargador frontal	50	45	40
Retroexcavadora	50	45	40
Excavadora	55	50	45

Nota: *Trabajos nocturnos, min/h = minutos por hora. De “Manual de construcción de carreteras” Por A. Villalba Sánchez, 2010.

- Factor de eficiencia del cucharón (K). Este factor se relaciona con la cantidad de material que existe en el área de trabajo y la capacidad real que puede operar o levantar el mismo.
- Tiempo que dura el ciclo de trabajo en segundos (C_m). Se refiere a las distintas tareas que realiza la maquinaria pesada como son las actividades de carga, balanceo y excavación para completar correctamente un trabajo en un tiempo determinado. La duración o tiempo de ciclo se puede calcular de forma visual u observacional ya que se tiene los videos del movimiento de tierras. Para el caso mencionado se analizó las

tres actividades principales que son la excavación, carga y balanceo de la excavadora a partir de cinco videos y se sacó un promedio de los tiempos obtenidos.

2.2 Inteligencia Artificial (IA)

2.2.1 Antecedentes

En las últimas dos décadas, la inteligencia artificial (IA) ha mejorado enormemente el rendimiento de los sistemas de fabricación y de servicio. Ha tenido gran influencia en el campo popular de la informática, ya que ha mejorado y facilitado la vida humana. Las áreas de aplicación de la IA están teniendo un gran impacto en varios campos de la vida diaria, ya que se están empezando a utilizar ampliamente para resolver problemas complejos en los proyectos de construcción y que ha demostrado tener una eficacia adecuada según lo requerido. Entre los beneficios que nos puede otorgar, la IA nos permitirá resolver los desafíos de cuidar a una población que envejece, reducir significativamente, incluso a cero, los accidentes de tráfico y las muertes, entre otras cosas (VijiPriya et al., 2016).

2.2.2 Definición

Se puede describir la inteligencia artificial como el intento de crear una simulación ingeniosa que imite o reproduzca el pensamiento inteligente, para que las máquinas puedan tener una mente en el sentido completo y literal de la palabra (Haugeland, 1985).

Boden (2016) sostiene que no es una dimensión única, sino un espacio profundamente estructurado de capacidades diversas para procesar la información. Además, tiene muchas técnicas diferentes para resolver una gran variedad de tareas y tiene por objetivo que los ordenadores hagan la misma clase de cosas que puede hacer la mente.

Asimismo, las metodologías populares actualmente incluyen métodos numéricos e inteligencia computacional pero también se utiliza una gran cantidad de herramientas que incluye muchas versiones de búsqueda y optimización matemática, lógica, métodos probabilísticos, economía y más. En consecuencia, diferentes innovaciones han reducido el esfuerzo humano y, por otro lado, también han dejado a la gente inactiva. Las sociedades desean que un operario impulsado por una máquina haga cosas diseñadas para ti en lugar de

involucrar sus propios medios. Esta motivación logró que los científicos de hoy en día inventaran nuevos dispositivos que podrían "facilitar" la vida humana. Con el objetivo de mecanizar los procesos, la IA surgió como la única respuesta a todas las preguntas. (VijiPriya et al., 2016)

2.2.3 Ramas y Campos de la IA

- **Aprendizaje Automático o *Machine Learning* (ML)**

Según El Naqa & Murphy (2015), el aprendizaje automático es una categoría de algoritmos de computación que intentan emular la inteligencia humana mediante la observación y el aprendizaje del entorno en el que operan. Estas técnicas han demostrado ser efectivas en una variedad de campos, incluyendo la identificación de patrones, la visión por computadora, las finanzas, la biología computacional y aplicaciones biomédicas.

Según VijiPriya et al. (2016), existen diversas aplicaciones de ML, entre ellas tenemos:

- Detección de rostros en la cámara móvil. Por lo general, las cámaras pueden tomar una foto automáticamente cuando alguien sonríe de manera más perfecta ahora más que nunca debido a los desarrollos en los métodos de aprendizaje automático.
- Reconocimiento facial. Un programa eficiente puede identificar a una persona a partir de una imagen. Un avance en el aprendizaje automático es el software de grupo automático de rostro preciso adicional.
- Reconocimiento de voz. Las optimizaciones de los sistemas de reconocimiento de voz han sido posible gracias al aprendizaje automático explícitamente el aprendizaje profundo.
- Google. Se considera a sí mismo como una agrupación de aprendizaje automático ahora. También es un pionero en esta área porque el aprendizaje automático es un componente importante y preciso para sus principales negocios de publicidad y búsqueda.

- **Aprendizaje Profundo o *Deep Learning* (DL)**

Según LeCun et al. (2015), el aprendizaje profundo, es una estructura compleja en grandes conjuntos de datos que mediante el uso de un algoritmo de retro propagación nos indica cómo una máquina debe cambiar sus parámetros internos para mejorar técnicas como el reconocimiento de voz, el reconocimiento de objetos visuales, el reconocimiento de objetos, etc. Además, el desarrollo de redes convolucionales profundas ha conllevado avances en el procesamiento de imágenes, video, voz y audio.

Liu et al. (2015), sostienen que el DL se refiere a un área del aprendizaje automático que se basa en el aprendizaje de un nivel de representaciones, correspondiente a una jerarquía de características, factores o conceptos, en la que los conceptos de palanca superior se definen a partir de los de palanca inferior, y los conceptos de palanca inferior pueden definir muchos conceptos de palanca superior. El aprendizaje profundo alcanza múltiples niveles de representación y abstracción, lo que ayuda a comprender datos como imágenes, audio y texto. El concepto de aprendizaje profundo procede del estudio de la red neuronal artificial, el perceptrón multicapa, que contiene más capas ocultas que la estructura de aprendizaje profundo.

2.2.4 Redes Neuronales Artificiales (RNA)

Dentro del aprendizaje automático tenemos a las redes neuronales artificiales, estas son modelos matemáticos que intentan reproducir el comportamiento del cerebro humano al simplificar el sistema real que simulan y obtener las características principales de esta para desarrollar correctamente una tarea determinada.

En base a esto, se pueden reducir a tres conceptos las características principales que reproducen las redes neuronales artificiales: procesamiento paralelo, distribuido y adaptativo.

El procesamiento en paralelo realizado por las neuronas artificiales radica en un elemento de procesamiento simple y constituye el elemento principal de un sistema neuronal artificial.

Por otro lado, las neuronas artificiales están compuestas por un conjunto de capas las cuales hacen que la información se encuentre distribuida a lo largo de la sinapsis de la red, dando así cierta tolerancia a fallos.

Por último, las redes neuronales artificiales tienen la capacidad de adaptar su funcionamiento a distintos entornos modificando las conexiones existentes entre neuronas. Es así como logra aprender de la experiencia y generalizar conceptos.

Las neuronas suelen agruparse en unidades funcionales denominadas capas. Se denomina capa de entrada a aquella que está compuesta por neuronas de entradas y por lo tanto recibe información procedente desde el exterior. Análogamente, se denomina capa oculta y capa de salida a aquellas capas que están compuestas por neuronas ocultas y de salida respectivamente. Una red neuronal artificial está compuesta por una o más capas, las cuales se encuentran interconectadas entre sí (Mitacc, 2006).

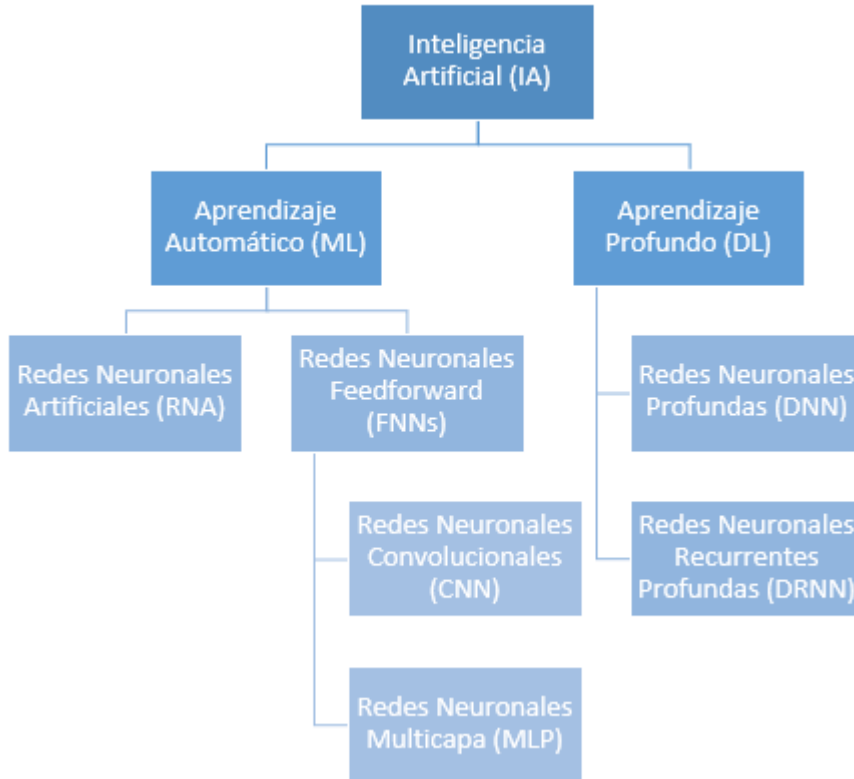
2.2.5 Redes Neuronales Convolucionales (CNN)

Las CNN también se encuentran dentro del Aprendizaje Automático, que a su vez se encuentra dentro de las redes neuronales “*Feedforward*”, estas se caracterizan por ser una red de neuronas artificiales que no tiene ningún tipo de retroalimentación y las conexiones entre las distintas neuronas de la red siguen un único sentido, desde la entrada de la red hacia la salida de esta (Thamm, 2023).

Como se observa en la figura 2.8 dentro de esta categoría encontramos otras redes neuronales como las redes neuronales multicapa (MLP, por sus siglas en inglés) y las redes neuronales recurrentes (RNN, por sus siglas en inglés). Siendo estos algunos de los tipos de redes neuronales más comunes, nos centraremos en explicar las CNN.

Figura 2.8

Clasificación de redes neuronales

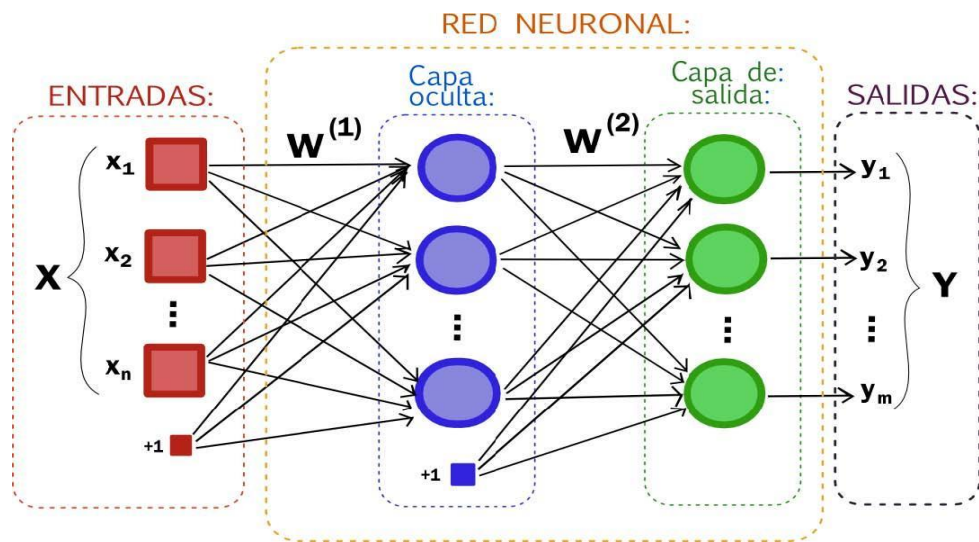


Según Luo et al. (2018), la CNN es un potente algoritmo que se emplea para el análisis de imágenes y para realizar tareas como detección de objetos, segmentación de imágenes o reconocimiento facial, entre otras. Además, los modelos CNN pueden reconocer de forma efectiva y automática características de imágenes estáticas apilando distintas capas convolucionales y de agrupación.

Estas redes neuronales intentan imitar el cerebro humano y su proceso de aprendizaje. Al igual que un cerebro toma la entrada, la procesa y genera una salida, lo mismo hace la red neuronal. Estas tres acciones se representan en forma de capas: entrada, oculta y salida (Singh, 2020).

Figura 2.9

Esquema del aspecto de una red neuronal



Nota. De “Red Neuronal En Python” Por Art From Code, 2021.
(<https://artfromcode.wordpress.com/2017/04/18/red-neuronal-en-python-con-numpy-parte-1/>)

Estas unidades individuales en las capas se llaman neuronas las cuales cumplen un papel importante en recibir señales de entradas de las neuronas vecinas y calcular un valor de salida para ser proporcionada a las demás. Sus conexiones entre cada una de ellas tienen asociado a un peso que tiene como función hacer que la red se potencie más de conocimiento de la información transmitida. Además, se habla de red neuronal a un conjunto de neuronas que en lo posible la podemos encontrar en dos estados: reposo y excitado, es decir en un estado de activación de los cuales a cada uno se le asigna un valor que puede ser continuo o discreto. Asimismo, se conocen cuatro funciones de transferencia típicas que determinan los distintos tipos de neuronas: función escalón, función lineal y mixta, sigmoideal y función Gaussiana (Villanueva, 2002).

Por ejemplo, la función sigmoideal tiene una función importante en la activación de conformación de redes neuronales artificiales. Consiste en tener un rango de valores de salida de 0 a 1 siendo interpretada como una probabilidad y donde los resultados altos tienden a acercarse a 1, a comparación de los resultados bajos que tienden acercarse a 0 (Caballero et al., 2014).

Por otro lado, el proceso completo de entrenamiento de una red neuronal implica dos pasos:

- **Propagación hacia adelante (*forward propagation*)**

La capa de entrada recibe imágenes en formato numérico, donde cada número representa la intensidad de los píxeles de la imagen. Las neuronas de las capas ocultas aplican algunas operaciones matemáticas sobre estos valores. Para realizar estas operaciones matemáticas, hay ciertos valores de parámetros que se inicializan aleatoriamente. Después de estas operaciones matemáticas en la capa oculta, el resultado se envía a la capa de salida que genera la predicción final. La convolución suele representarse matemáticamente con un signo de asterisco (Singh, 2020).

Figura 2.10

Valores de los píxeles de una imagen




Nota. De “Introducción a las redes neuronales”, 2016. (<https://www.analyticsvidhya.com>)

En resumen, primero se cargan las imágenes de entrada en una variable (digamos X), luego se define (inicializar aleatoriamente) una matriz de filtro. Después se aplica la función de activación sigmoide en el resultado. A continuación, se define (inicializar aleatoriamente) la matriz de pesos y de sesgo, se debe aplicar una transformación lineal a los valores. Finalmente, se aplica la función sigmoide sobre los datos. Este será el resultado final.

Figura 2.11

Proceso de propagación hacia adelante



Nota. De “Introducción a las redes neuronales”, 2016. (<https://www.analyticsvidhya.com>)

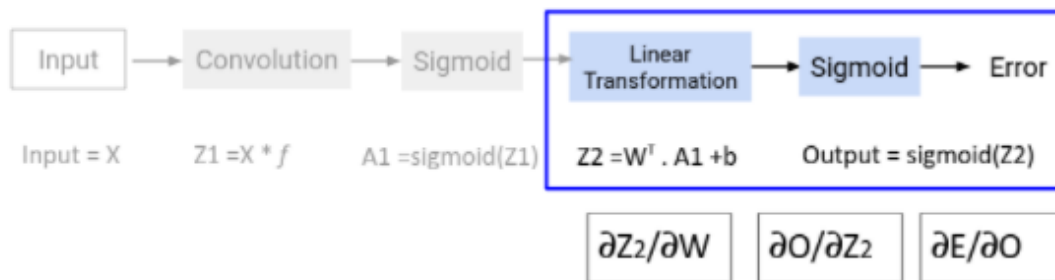
- **Propagación hacia atrás (*back propagation*)**

En el proceso de propagación hacia atrás, el modelo intenta actualizar los parámetros de forma que las predicciones globales sean más precisas.

Una vez generada la salida, el siguiente paso es comparar la salida con el valor real. En función de la salida final, y de lo cerca o lejos que esté del valor real (error), se renuevan los valores de los parámetros. El proceso de propagación hacia adelante se repite utilizando los valores actualizados de los parámetros y se generan nuevas salidas. Esta es la base de cualquier algoritmo de red neuronal.

Figura 2.12

Proceso de propagación hacia atrás



Nota. De “Introducción a las redes neuronales”, 2016. (<https://www.analyticsvidhya.com>)

2.3 Estado del arte

Actualmente existen diversas publicaciones que han examinado el uso de las redes neuronales convolucionales en el cálculo del rendimiento de excavadoras. Entre los principales trabajos científicos identificados que aportan a la investigación en curso se destacan los estudios más relevantes además de agregar trabajos de movimiento de tierras masivo que están a continuación en orden cronológico en la tabla 2.4.

Tabla 2.4

Estado del arte para el cálculo de rendimiento de excavadoras con IA

ID	Título	Autores	Tipo de estudio	Año	Palabras clave
1	Cálculo de rendimiento de retroexcavadora, excavadora y cargador frontal en movimiento de tierras	Aguilar Azañero,A; Ysla Oyarce,L.	Tesis	2016	Rendimiento, maquinaria pesada, movimiento de tierras
2	Análisis y Ejecución de movimiento de tierras en una obra empleando el diagrama de Curva masa	Guevara Martinez, F.	Tesis	2015	Movimiento de tierras, rendimiento, vías terrestres
3	Evaluación de rendimientos de equipos en las operaciones de movimiento de tierras en el Minado Cerro Negro Yanacocha-Cajamarca	Malpica Quijada, C.	Tesis	2014	Movimiento de tierras, maquinaria pesada, rendimiento
4	Automated Excavators Activity Recognition and Productivity Analysis from Construction Site Surveillance Videos	Chen Chena, Zhenhua Zhub, Aming Hammade	Artículo	2020	Earthmoving excavators, workers activities, equipment, features
5	Estimation of the excavator actual productivity at the construction site using video analysis	Sopie, Martina; Vukomanovic, Mladen;Car-Pusic, Diana; Zavrski, Ivica	Artículo	2021	Earthmoving excavators, Action recognition, equipment, features
6	Multi-camera vision-based productivity monitoring of earthmoving operations	Jinwoo Kim; Seokho Chi	Artículo	2020	Action recognition, Tracking, Simulation, Equipment, Identification, Workers, Excavators, Networks, Features, Systems (continúa)

(continuación)

ID	Título	Autores	Tipo de estudio	Año	Palabras clave
7	Convolutional neural networks: Computer vision-based workforce activity assessment in construction	Jinwoo Kim; Seokho Chi	Artículo	2018	Action recognition, Workers, Productivity, Equipment, Framework, Design, Images
8	An object recognition, tracking, and contextual reasoning-based video	Jie Gong, Carlos H.Caldas	Artículo	2011	Visualization, Simulation
9	Deep Convolutional Neural Networks for efficient vision-based tunnel inspection	Makatansis K., Protopapadakis E., Doulamis A., Doulamis N., Loupos C.	Proceeding Paper	2015	Machine vision, concrete, system, cracks, model
10	A review on Significance of Sub Fields in Artificial Intelligence	Dr J. VijiPriya, Dr. Jammi Ashok, Dr S.Suppiah	Artículo	2016	Artificial Intelligence, Robotics, Expert, Systems, Machine Learning and Neural Networks

2.3.1 Análisis de la revisión literaria sistemática

- Estimación de la productividad real de la excavadora en la obra mediante análisis de video (Sopie et al., 2021)

En el artículo se resalta el cálculo de la productividad real de maquinaria pesada de construcción mediante uso de tecnologías basadas en la visión. Para ello se apoyan en cámaras de video y análisis de videos grabados mediante un avanzando programa informático denominado SRF, el cual puede aplicarse al comienzo del movimiento de tierras y después de cualquier cambio significativo en el rendimiento del movimiento de tierras. Con un adecuado conocimiento de la productividad es posible estimar el tiempo y costo de la actividad. Asimismo, la aplicación continua de SRF permite mejorar la supervisión de los trabajos al lograr la detección de forma temprana de un rendimiento de trabajo inusual y ante esto, ofrece la posibilidad de aplicar medidas apropiadas y correctivas a tiempo. Por lo tanto, con una visión continua de la productividad y de los puntos muertos, es posible seguir la dinámica del rendimiento y detectar a tiempo las acciones desfavorables e inaceptables.

- Reconocimiento de la actividad de las excavadoras automatizadas y análisis de la productividad a partir de videos de vigilancia de obras (Chen et al., 2019)

En el artículo se destaca como papel importante a la hora de completar los proyectos de construcción, la productividad de los equipos de construcción. Sin embargo, resalta que el control actual de la productividad en las obras depende en gran medida de la observación y el registro manual de las actividades de los equipos, lo que requiere mucho trabajo y tiempo. Para abordar este problema, un número creciente de estudios de investigación se centró en la identificación automática de las actividades de los equipos a partir de los vídeos de vigilancia de la obra. Sin embargo, estos estudios no lograron realizar con precisión el reconocimiento de la actividad y el análisis de la productividad, cuando varios equipos están trabajando juntos. Por ello, esta investigación propone un marco novedoso para analizar automáticamente la actividad y la productividad de múltiples excavadoras en función del diseño de tres redes neuronales convolucionales para detectar, seguir y reconocer las actividades de excavadoras. Los resultados de esta investigación arrojaron análisis del tiempo de actividad, ciclo de trabajo de carguío y productividad de las excavadoras con una precisión del 87,6%. Lo que indica la viabilidad del marco propuesto para automatizar el seguimiento de la productividad de las excavadoras.

- Supervisión de la productividad de las operaciones de movimiento de tierras basada en la visión multicámara (Kim & Chi, 2019)

El artículo presenta metodologías para el seguimiento de equipos. Esta investigación emplea uno de los algoritmos de seguimiento visual más utilizados: el Seguimiento-Aprendizaje-Detección (TLD). Los estudios existentes en los dominios de la construcción han demostrado su alta aplicabilidad para el seguimiento de objetos en entornos dinámicos. Esta capacidad se origina en dos componentes vitales del algoritmo TLD: la integración funcional y el aprendizaje en línea. La integración funcional es un proceso de activación de un detector y un rastreador al mismo tiempo, y este enfoque híbrido permite rastrear equipos de movimiento de tierras a largo plazo, aunque dichos equipos se mueven dinámicamente y tienen grandes variaciones entre clases e intraclases. El aprendizaje en línea es otro componente vital para el seguimiento a largo plazo de los equipos de movimiento de tierras,

los datos de entrenamiento específicos del objeto pueden generarse automáticamente a partir de las imágenes reales que se están probando, y el detector puede personalizarse para cada objeto de estudio.

- Redes neuronales convolucionales: Evaluación de la actividad de la mano de obra en la construcción basada en la visión por ordenador (Luo et al., 2018)

En el artículo se describe una CNN mejorada que combina el RGB, el flujo óptico y el flujo de grises para monitorear y evaluar las actividades de los trabajadores de manera precisa y automática, con el objetivo de mejorar la gestión de proyectos de construcción. Los resultados experimentales indican que la CNN mejorada tiene un buen rendimiento, con una precisión media del 85%, y es prometedora para futuras aplicaciones en situaciones reales. Las principales contribuciones de esta investigación son dos: primero, el uso de técnicas avanzadas de procesamiento de imágenes para analizar las operaciones de construcción, y segundo, el método de CNN desarrollado que permite el seguimiento automático en tiempo real de la productividad, lo que brinda información instantánea a gerentes y trabajadores. Sin embargo, se presentan varias limitaciones que deben abordarse para mejorar el control en tiempo real de manera eficiente y efectiva.

- Cálculo de rendimiento de retroexcavadora, excavadora y cargador frontal en movimiento de tierras, Chachapoyas, Amazonas-2016 (Aguilar & Ysla, 2016)

En este estudio se destaca que, el cálculo para el rendimiento de maquinaria pesada en el movimiento de tierras depende de en qué condiciones y factores se van a realizar las actividades. Cabe resaltar que esta investigación es de tipo descriptiva donde se mencionan maquinarias pesadas como: Cat 420F, excavadora Cat 329D y cargador frontal Cat 962H. Los datos obtenidos son mediante observación directa a la maquinaria y procesados en gabinete tomando en cuenta los factores y condiciones anteriormente mencionadas. Los resultados se presentan en una tabla la cual nos muestra información confiable y real con respecto al rendimiento de la maquinaria pesada analizada y de esa forma compararlo con la información básica brindada por los fabricantes en sus fichas técnicas.

- Una revisión sobre la importancia de los subcampos en la inteligencia artificial (VijiPriya et al., 2016)

Es importante destacar en el estudio las aplicaciones que tiene el reconocimiento de la visión (*Vision Recognition*). Entre estas tenemos los procesos de monitoreo, colaboraciones, inspecciones automáticas, navegaciones, modelamiento de sustancias o entornos. En las diferentes aplicaciones de visión por ordenador, las computadoras están preprogramadas para resolver ciertas tareas, pero las técnicas basadas en el aprendizaje continuo están siendo más comunes. Otra aportación del artículo que nos interesa destacar son las aplicaciones que tiene las redes neuronales como lo es el reconocimiento de caracteres, compresión de imágenes, predicciones de stock. Las redes neuronales artificiales fueron reconocidas en 1940, estas pueden ser categorizadas en atributos arquitectónicos y cualidades neuro dinámicas. El primero define la construcción de la red, el segundo, la funcionalidad de las ANN.

- Eficiencia y productividad óptima en movimiento de tierras para la construcción de plataformas de lixiviación (Flores, 2015)

En la presente investigación se resalta la importancia de conocer la eficiencia y productividad óptimas de maquinarias para movimientos de tierras masivos y compararlos con las recomendaciones del fabricante. Además, se utilizó un procedimiento de control de horas trabajadas y análisis de datos. En resumen, esta investigación se centra en la construcción del PAD La Quinoa 8A y analiza la eficiencia y productividad con información de campo en varias jornadas de trabajo con la conclusión de que siempre se busca la mejora continua y nunca se encuentra un máximo absoluto en estos parámetros.

- Redes neuronales convolucionales profundas para una inspección eficiente de túneles basada en la visión (Makantasis et al., 2015)

En el artículo se menciona la importancia de la inspección visual para determinar la seguridad en estructuras de concreto y que representa uno de los mayores desafíos para los ingenieros debido a que estos se realizan de forma manual. Por lo tanto, requiere de un nivel de esfuerzo significativo al involucrar a los inspectores que caminan a lo largo de la superficie de las

estructuras usando solo sus ojos. De esta forma, se arrojan valores subjetivos propensos a errores humanos. Por lo que, ante esto, se propone enfoques automatizados mediante desarrollo de algoritmos como el *Support Vector Machine* (SVM) el cual detecta grietas en las superficies de túneles. También se menciona que si este algoritmo se combina con otros algoritmos de aprendizaje automático como el *Artificial Neural Network* (ANN), resulta en una combinación óptima en términos de precisión de detección. De esta forma, se estaría automatizando el proceso de inspección de estructuras de concreto en diferentes proyectos de construcción lo cual beneficiaría en el corto plazo.

- Evaluación de rendimientos de equipos en las operaciones de movimiento de tierras en el Minado Cerro Negro Yanacocha – Cajamarca (Malpica, 2014)

Dentro del estudio de esta investigación, se analiza la funcionalidad de la maquinaria según el tipo de material involucrado y las propiedades del suelo en que se trabaja. Las actividades de maquinaria pesada analizadas son: carga con excavadora, empuje del tractor sobre orugas, carguío con cargador frontal, acarreo con volquetes de 15 m³ y el perfilado del terreno con motoniveladora. Se hace una comparación llegando a la conclusión de que los rendimientos reales son menores a los otorgados por el fabricante.

- Un método de reconocimiento de objetos, seguimiento e interpretación de videos basado en el razonamiento contextual para el análisis rápido de la productividad de las operaciones de construcción (Gong & Caldas, 2011)

En este estudio podemos destacar los algoritmos de visión por ordenador para la identificación y seguimiento de objetos de construcción que presentan. Por un lado, en el reconocimiento de objetos de construcción, se implementa un método de sustracción de fondo. Los métodos de sustracción de fondo suelen utilizar un proceso de entrenamiento en línea, lo que significa que utilizan una porción de datos de vídeo en vivo como como muestras de entrenamiento para desarrollar modelos de fondo y primer plano. Estos métodos pueden aplicarse directamente a los vídeos de construcción para aislar los objetos interesados de las escenas de fondo. Por el otro lado, en el seguimiento de objetos de construcción, los

autores evalúan dos métodos de seguimiento: el filtrado y la asociación de datos y la Representación y localización de objetivos. El filtrado y la asociación de datos es un proceso descendente que se ocupa de la dinámica del objeto rastreado, el conocimiento de los antecedentes de la escena y la evaluación de diferentes hipótesis. La representación y localización del objetivo es un proceso ascendente que se ocupa de los cambios en la apariencia del objetivo. En la práctica, los métodos mencionados se utilizan a menudo en combinación.

En resumen, haciendo un recorrido por los resultados importantes de las investigaciones realizadas en la temática del rendimiento en excavadoras, se puede concluir que para su determinación primero hay que analizar las actividades realizadas para remover y acomodar la subrasante del terreno denominada movimiento de tierra, el cual hace uso de maquinarias pesadas como: excavadoras, cargadores frontales, tractores, volquetes, motoniveladoras, apisonadoras, etc. Además de los factores y condiciones de material involucrado y propiedades del suelo que afectan la funcionalidad de la maquinaria y por ende los cálculos realizados para la obtención del rendimiento por tipo de modelo de maquinaria.

Por otro lado, con respecto al uso de CNN en el rendimiento de excavadoras se han utilizado diferentes algoritmos, como el algoritmo de visión por ordenador para el reconocimiento y seguimiento de objetos de construcción, el Seguimiento-Aprendizaje-Detección (TLD), y otros que han sido mejorados con el uso de RGB, el flujo óptico y flujo de grises (Gong & Caldas, 2011).

También se observa en la literatura que se incluye factores para determinar la productividad de las excavadoras, como, por ejemplo, la variable dependiente que depende de variables independientes como la competencia de operador, además de factores espaciales, como los ángulos de rotación, distancias horizontales, etc. (Holt, 2015).

Se evidencia que la mayoría de los estudios concuerdan en la importancia de inspeccionar y evaluar continuamente las obras de infraestructura civil con la ayuda de inteligencia artificial ya que con una visión continua de la productividad es posible seguir la dinámica del rendimiento y detectar a tiempo las acciones desfavorables, como en la referencia (Koch et al., 2015).

CAPÍTULO III: MARCO METODOLÓGICO

La elaboración de este capítulo fue posible gracias a la base teórica de la revisión de la literatura. Según Hernández et al. (2014), la metodología científica de la investigación de este trabajo es de tipo sistémico, en relación con la comprensión de 10 artículos indexados que detallan una combinación de cálculos de rendimiento de excavadoras y algoritmos aplicados con CNN que han sido validadas en investigaciones similares.

Este capítulo consideró las características de las metodologías de automatización con el fin de comprender su alcance para desarrollar un programa capaz de obtener el rendimiento real de excavadoras.

La metodología de esta investigación se basa en el estudio del reconocimiento de objetos por medio de la colocación de múltiples cámaras en el lugar de trabajo para de esta forma realizar un monitoreo automatizado del movimiento de tierras.

3.1 Tipo de estudio

Según Hernández et al. (2014), la presente investigación cuenta con un enfoque cuantitativo por recopilar datos numéricos que apoyan o rechazan la hipótesis planteada. También, se generalizará los resultados mediante cuadros comparativos para así comprobar la capacidad de calcular el rendimiento de la maquinaria de manera precisa.

La investigación actual es de tipo observacional, es decir, no experimental, por tener una variable que no es posible controlar como lo es el rendimiento de las excavadoras (variable independiente). Además, corresponde a clasificarse como una investigación técnica porque desde el conocimiento obtenido en la investigación aplicada, éste se enfocaría en la obtención de nuevos productos, procedimientos, tecnologías, etc.

3.2 Sujeto de Estudio

Esta investigación tiene como sujeto de estudio a la excavadora. Este vehículo autopropulsado es usado para el movimiento de tierras, cuenta con actividades principales como la carga, transporte y descarga. Evaluaremos la detección de la excavadora, su seguimiento, la identificación del estado al ralentí, el reconocimiento de actividades principales y el cálculo del rendimiento.

El sujeto de estudio se verá afectado por diferentes factores entre ellos tenemos las condiciones climáticas, eficiencia de operación, resistencia al rodamiento, entre otros.

3.2.1 Ubicación

El objeto de estudio se encuentra ubicado en la avenida Javier Prado Este 4600, Santiago de Surco 15023, Lima-Perú. La obra de construcción, donde se encuentran localizadas las excavadoras, es parte del plan maestro que está implementando la Universidad de Lima para mejorar y modernizar las infraestructuras.

Figura 3.1

Ubicación del pabellón II



Nota. De Google Earth Pro

3.2.2 Peculiaridades

La edificación en la cual las excavadoras operarán, denominado Pabellón I1, es una estructura en forma de L que contará con cinco niveles con terraza en techo y dos sótanos que se unirán con el antiguo pabellón S a través de dos fachadas. Albergará laboratorios de las facultades de Ingeniería y Arquitectura: Ingeniería Civil, Ing. Industrial, Ing. de Sistemas y Arquitectura.

3.2.3 Necesidades o flujo de los usuarios

El pabellón I1 propiciará escenarios de creación y producción para plantear y solucionar problemas que atañen a la sociedad, a la academia y a las empresas. Su modelo de acción está en línea con la misión, la visión institucional y las estrategias de la Universidad de Lima.


3.3 Técnicas y procesos de recolección y procesamiento de datos

3.3.1 Metodología para el cálculo del rendimiento automatizado

Esta metodología empieza con la información recolectada de la investigación de artículos científicos que contienen cálculos de rendimiento de excavadoras. Con ayuda de esa información se procedió a diseñar una hoja de Excel automatizada. Además, se creó un programa con la información de la hoja Excel con el mismo objetivo de automatizar el proceso de cálculo de rendimiento de excavadoras denominado RENDEXCA.

Figura 3.2

Metodología para el cálculo del rendimiento automatizado



3.3.2 Metodología para el análisis comparativo

Los aspectos seleccionados en el análisis comparativo fueron elegidos debido a su relevancia en la evaluación de la calidad y eficacia de programas de cálculo de rendimiento de excavadoras. La funcionalidad, facilidad de uso, velocidad y capacidad de registro y comparación de resultados son factores clave en la capacidad del programa para realizar la tarea requerida de manera efectiva y eficiente. La portabilidad y compatibilidad son importantes para adaptarse a diferentes necesidades y sistemas operativos, mientras que el costo, soporte y mantenimiento son factores importantes en la elección del programa. Finalmente, el tipo de interfaz es un aspecto importante para evaluar la accesibilidad y usabilidad del programa. Se proporcionará una explicación detallada de cada aspecto para que resulte más comprensible y completo el análisis comparativo.

- **Funcionalidad.** Se refiere a la capacidad del programa para realizar la tarea de cálculo del rendimiento de excavadoras.
- **Facilidad de uso.** Se refiere a la simplicidad y accesibilidad del programa para el usuario, incluyendo la interfaz, la claridad de los campos de entrada y la facilidad de navegar entre las diferentes opciones del programa.
- **Velocidad.** Se refiere a la rapidez con la que el programa procesa los datos y genera los resultados.
- **Capacidad de registro y comparación de resultados.** Se refiere a la capacidad del programa para guardar registros de cálculos previos y comparar diferentes resultados.

- Portabilidad. Se refiere a la capacidad del programa para ejecutarse en diferentes sistemas operativos y hardware.
- Compatibilidad. Se refiere a la capacidad del programa para trabajar con otros programas y formatos de archivo.
- Costo. Se refiere al precio o la disponibilidad del programa para el usuario.
- Soporte. Se refiere a la disponibilidad de asistencia técnica o actualizaciones para el programa.
- Escalabilidad. Se refiere a la capacidad del programa para manejar grandes cantidades de datos y para expandirse en el futuro.
- Mantenimiento. Se refiere a la facilidad y costo de mantener el programa funcionando correctamente.
- Tipo de interfaz. Se refiere al tipo de interfaz que utiliza el programa para ingresar y presentar los datos, como una hoja de cálculo o una interfaz gráfica de usuario.

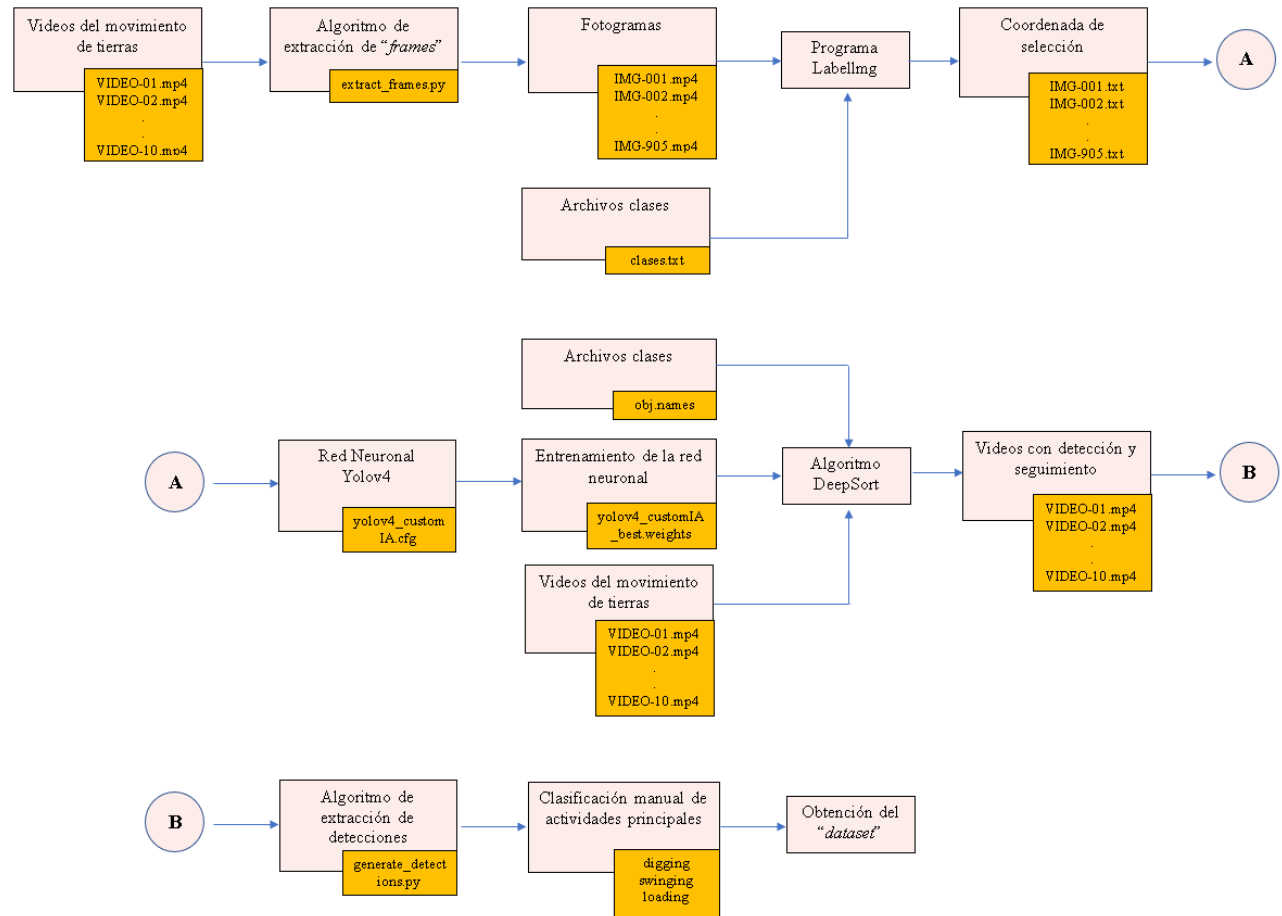
3.3.3 Metodología para la obtención del *dataset*

Esta metodología comienza con la recolección de datos mediante videos de movimientos de tierras (10 videos con extensión mp4) que mediante el algoritmo de extracción de *frames* (*Extract_frames.py*) se procesan y nos da como resultado 905 fotogramas (extensión jpg). Estos junto con el archivo “classes.txt”, en donde va el sujeto de estudio a analizar, se introducen al programa LabelImg en donde de forma manual se seleccionó a las excavadoras y nos da como resultado las coordenadas de selección (extensión txt). Estos datos son introducidos a su vez en Yolov4 mediante la extensión *yolov4_customIA_best.weights* y nos da como resultado los pesos de la red neuronal, es decir, el entrenamiento de la red neuronal. Estos pesos son de vital importancia porque junto al archivo de clases “obj.names” y los videos de movimiento de tierras, se introducen al algoritmo DeepSort para obtener videos con detección y seguimiento de las excavadoras. Con la ayuda del algoritmo de extracción de detecciones (*generate_detections.py*) se extrae fotogramas del video de cada

excavadora. Por último, mediante una clasificación manual de las actividades principales de la excavadora (*digging*, *swinging* y *loading*) se obtendrá el *dataset* clasificado.

Figura 3.3

Metodología para la obtención del dataset



3.4 Diseño de Recolección de Datos

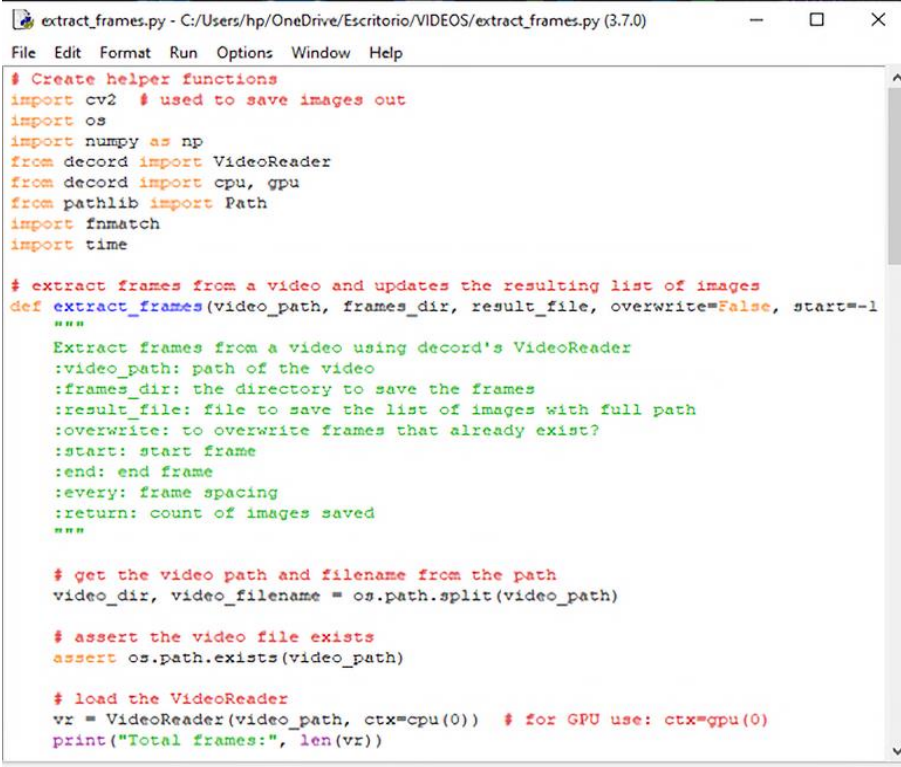
Para la recolección de datos se utilizarán diferentes cámaras que estarán ubicadas en sitios estratégicos, los cuales grabarán videos del movimiento de tierras. Estas cámaras graban hasta 12 horas, y serán utilizadas de lunes a sábado. Según el cronograma de obra, la etapa de movimiento de tierras durará aproximadamente 3 meses.

Las fuentes de recolección están guardadas en memorias (Micro SD) y se trasladaron a un computador vía web. A partir de los videos se desglosó los fotogramas mediante el lenguaje de programación Python 3.7.0, con ayuda del algoritmo “extract_frames” que procesó los 10 videos, dando como resultado 905 fotogramas. Para el proceso de selección de fotogramas, se utilizará el programa LabelImg para seleccionar el sujeto de estudio manualmente en cada imagen y así entrenar a la IA. De esta manera los datos estarían listo para el procesamiento.

En el siguiente [enlace](#) se adjunta la recolección de datos donde se encuentran los videos, fotogramas y algoritmos mencionados.

Figura 3.4

Algoritmo de extracción de “frames”



```
extract_frames.py - C:/Users/hp/OneDrive/Escritorio/VIDEOS/extract_frames.py (3.7.0)
File Edit Format Run Options Window Help

# Create helper functions
import cv2 # used to save images out
import os
import numpy as np
from decord import VideoReader
from decord import cpu, gpu
from pathlib import Path
import fnmatch
import time

# extract frames from a video and updates the resulting list of images
def extract_frames(video_path, frames_dir, result_file, overwrite=False, start=-1
    """
    Extract frames from a video using decord's VideoReader
    :video_path: path of the video
    :frames_dir: the directory to save the frames
    :result_file: file to save the list of images with full path
    :overwrite: to overwrite frames that already exist?
    :start: start frame
    :end: end frame
    :every: frame spacing
    :return: count of images saved
    """

    # get the video path and filename from the path
    video_dir, video_filename = os.path.split(video_path)

    # assert the video file exists
    assert os.path.exists(video_path)

    # load the VideoReader
    vr = VideoReader(video_path, ctx=cpu(0)) # for GPU use: ctx=gpu(0)
    print("Total frames:", len(vr))
```

Nota. De GitHub Gist, Por Hayden Faulkner, 2020.
(<https://gist.github.com/HaydenFaulkner/3aa69130017d6405a8c0580c63bee8e6>)

Figura 3.5

Collage de las fotos extraídas



3.5 Procesamiento y Análisis de Datos

3.5.1 Validación del cálculo Manual

Para la validación del cálculo de rendimiento de excavadoras utilizaremos la fórmula de rendimiento descrita anteriormente.

Primero escogeremos el modelo de excavadora, que en este caso será la Hyundai Robex 200LC-9SB y el tipo de cucharón a utilizar será el SAE APILADO N04. La capacidad máxima del cucharón (Q), según su ficha técnica, es de $1,34 \text{ m}^3$. Utilizaremos el 80% de la capacidad máxima que sería:

$$Q = 0.80 \times 1.34 = 1.072 \text{ m}^3$$

Figura 3.6

Capacidad del cucharón 04



Nota. De COMREIVIC-impulsando el desarrollo. Excavadora Doosan DX225LCA (s. f.).
(<https://www.comreivic.com.pe/producto/dx225lca/>)

Luego para el factor de conversión de suelos (F) determinaremos que se comenzó excavando arena en estado de banco y el material tuvo un estado final de compactado. Para ello nos ayudaremos de la fórmula de compresibilidad:

$$\text{Compresibilidad (\%)} = \frac{1 - 0.95}{1} \times 100 = 5 \%$$

Luego se halla el volumen compactado:

$$F = 1 \times \left(1 - \frac{5}{100}\right) = 0.95 \text{ m}^3$$

Para la eficiencia de la máquina (E) se considerará un factor en un porcentaje fijo del 90%

$$E = 0.90$$

Para la eficiencia del cucharón (K) se considerará un factor en un porcentaje fijo del 70%

$$K = 0.70$$

Para el tiempo de ciclo de trabajo (C_m) se considerará el promedio de observación de 5 videos en 10 ciclos de trabajo en segundos. Para el caso mencionado se analizó las 3 actividades principales que son la excavación, carga y balanceo de la excavadora:

$$C_m = \frac{207.96 + 304.30 + 263.18 + 188.11 + 131.79}{5} = 219.068 \text{ s}$$

Finalmente hallamos el rendimiento:

$$R = \frac{3600 \times 1.072 \times 0.95 \times 0.90 \times 0.70}{219.068} = 10.54 \text{ m}^3/\text{h}$$

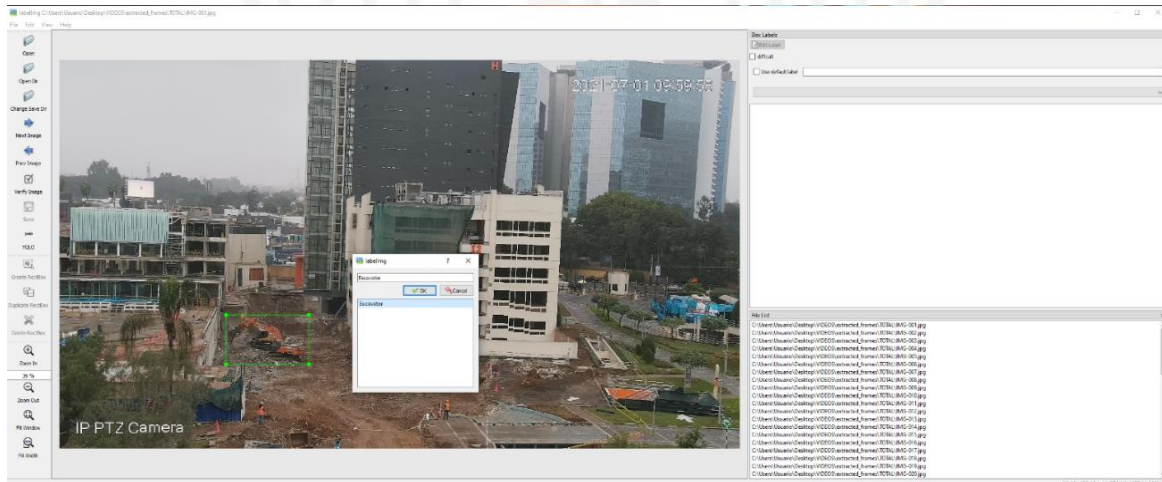
3.5.2 Modelo para generación del *dataset*

El modelo a ser desarrollado nos va a servir para el seguimiento y monitoreo de la productividad en las actividades de movimiento de tierras. Sus funciones serán: recopilar información pertinente como el reconocimiento del estado de la excavadora y la duración de cada actividad operativa. De esta manera, estos datos son luego utilizados para calcular la productividad real de cada excavadora.

El modelo utiliza YOLO v4 (*You Only Look Once*), una red neuronal de detección de objetos. Para esto, de los videos recopilados, se extrajo los *frames* respectivos. Luego se procesaron estos fotogramas en LabelImg donde se procedió a la clasificación manual de las excavadoras, como se muestra en la Figura 3.7.

Figura 3.7

Clasificación manual de fotogramas en LabelImg




La clasificación manual de las excavadoras se guardó como un archivo XML de cada imagen. Este archivo muestra las coordenadas del sujeto de estudio como se muestra en la Figura 3.8, donde la primera columna representa el ID del objeto clasificado, el listado de objetos empieza desde 0. La segunda y tercera columna consta de una coordenada X, Y del

inicio de la selección. La cuarta y quinta columna consta de una coordenada X, Y del final de la selección.

Figura 3.8

Coordenadas de las excavadoras de un fotograma



Para el entrenamiento de la red neuronal se ordenaron las 905 imágenes con sus respectivos archivos XML en dos carpetas de manera aleatoria: “Entrenamiento” con el 70% del total y “Validación” con el 30%. Se procedió a entrenar la red neuronal, lo que consistió en instalar una serie de requisitos previos como opencv, CUDA, cudnn, Cmake, darknet para finalmente utilizar YOLOv4. Todos los programas instalados y utilizados para esta investigación se localizan en el siguiente enlace: <https://drive.google.com/drive/folders/1ELFLPJ5PqAnnFXGvBLp-r4QE0kZcqSuV>

CAPÍTULO IV: RESULTADOS

4.1 Rendimiento de excavadoras automatizado en Excel

Junto con la validación del cálculo manual descrito anteriormente, usaremos los mismos datos y lo ingresaremos en la hoja de Excel automatizada. Es decir, elegiremos la excavadora modelo Hyundai Robex 200LC-9SB, material arena y un estado de banco a compactado tal como muestra la figura 4.1.

Figura 4.1

Resultado del cálculo en la hoja de Excel

CÁLCULO DE RENDIMIENTO DE EXCAVADORAS

1. MODELO DE MAQUINARIA

Maquinaria:

2. DATOS (ELECCIÓN)

Clase de material:

Estado actual:

Estado convertido:

3. DATOS (COMPLETAR)

Capacidad del cucharón (Q) =

4. RESULTADO

Rendimiento (R) =

1. FÓRMULA DE RENDIMIENTO

$$R = \frac{3600 \times Q \times F \times E \times K}{C_m}$$

Donde:

3600:	Número de segundos en una hora.
Q:	Capacidad del cucharón de la pala.
F:	Factor de conversión de los suelos.
E:	Eficiencia de la máquina
K:	Factor de eficiencia del cucharón.
C_m:	Tiempo que dura el ciclo de trabajo en segundos.

Según datos:

F =

E =

K =

Ciclo =

Según videos

#ciclos	Tiempo (s)
10	207.96
10	304.3
10	263.18
10	188.11
10	131.79
Promedio	219.07

1 ciclo

Digging	Excavación
Swinging	Balanceo
Loading	Carga

EXCAVADORA HYUNDAI ROBEX EXCAVADORA DX225LCA DOOSAN

4.2 Rendimiento de excavadoras automatizado en el programa RENDEXCA

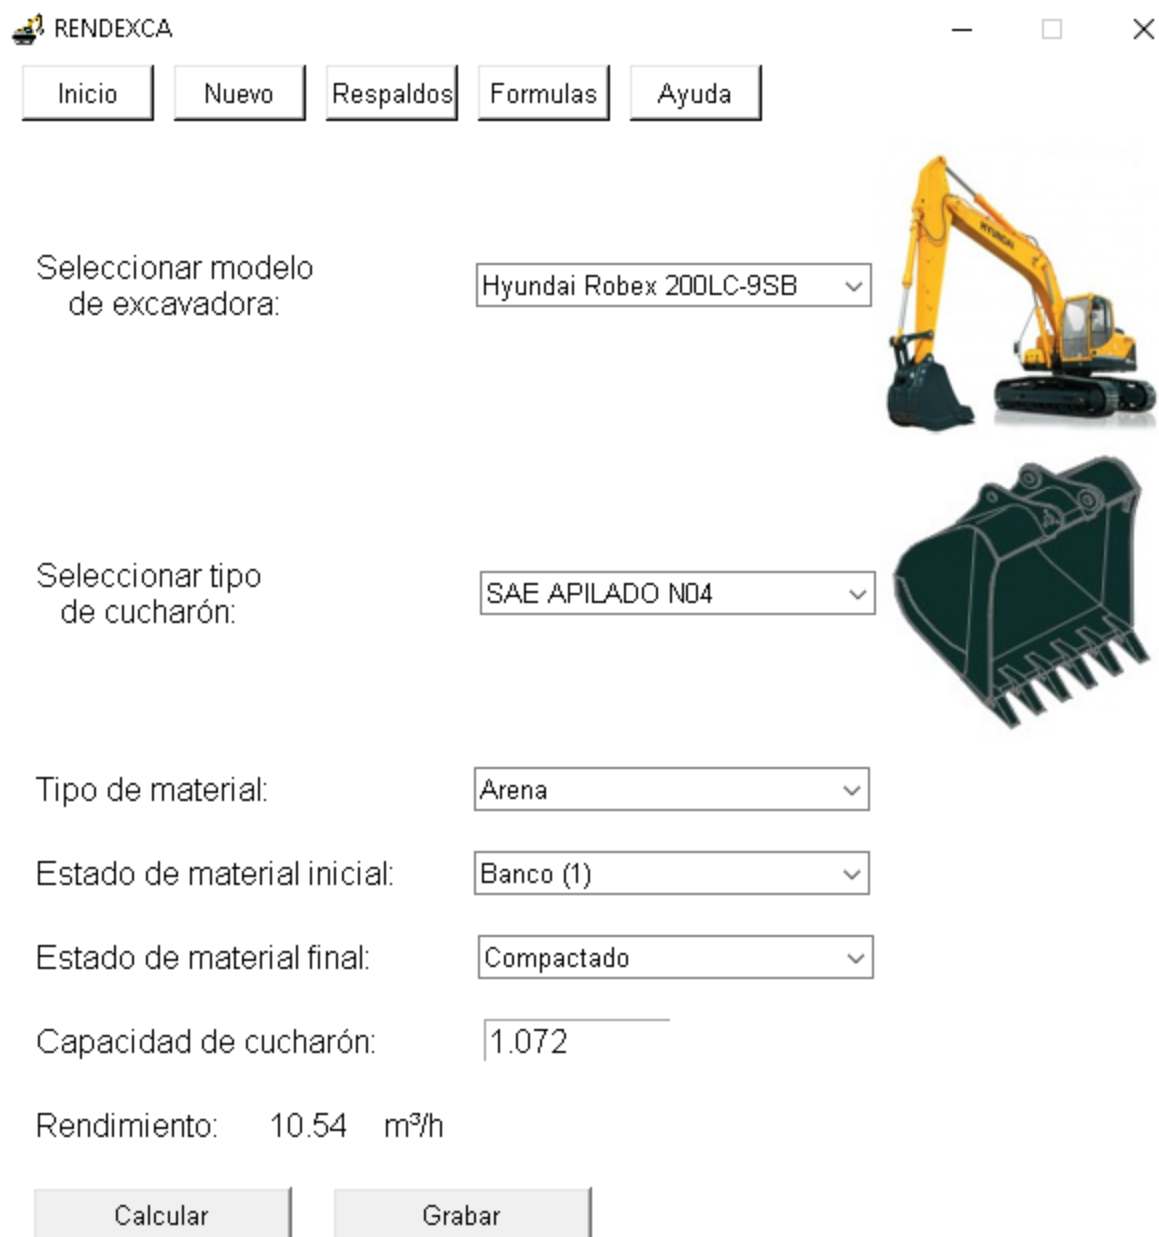
Para tener acceso al programa y poder descargarlo, ejecutarlo o incluso editar el código, se ha subido a la plataforma de GitHub y se ha creado un repositorio público en el que se encuentra el código fuente y los archivos necesarios para ejecutarlo. GitHub es una plataforma muy conocida y utilizada por desarrolladores de software de todo el mundo para compartir y colaborar en proyectos de código abierto. Al compartir el enlace del repositorio (<https://github.com/Dorkom/Programa-automatizado-de-rendimiento-de-excavadoras>), se facilita el acceso al programa a cualquier persona interesada en utilizarlo o aprender de su funcionamiento interno. Además, GitHub ofrece herramientas para hacer seguimiento a los cambios realizados al código fuente, colaborar con otros desarrolladores y recibir retroalimentación de la comunidad de usuarios del programa.

Dentro del programa se ha incluido un manual de usuario detallado que explica todas las funciones y características del programa. Este manual está diseñado para guiar al usuario a través de todas las herramientas disponibles, proporcionando instrucciones claras y detalladas sobre cómo utilizar cada una de ellas.

De la misma manera que en la hoja de Excel, se ingresaron los mismos datos para el cálculo de rendimiento de excavadoras como se observa en la figura 4.2.

Figura 4.2

Resultado del cálculo en RENDEXCA



RENDEXCA

Inicio Nuevo Respaldos Formulas Ayuda

Seleccionar modelo de excavadora: Hyundai Robex 200LC-9SB

Seleccionar tipo de cucharón: SAE APILADO N04

Tipo de material: Arena

Estado de material inicial: Banco (1)

Estado de material final: Compactado

Capacidad de cucharón: 1.072

Rendimiento: 10.54 m³/h


Calcular Grabar

The screenshot shows a software window titled 'RENDEXCA' with a menu bar containing 'Inicio', 'Nuevo', 'Respaldos', 'Formulas', and 'Ayuda'. The main area contains several dropdown menus and a text input field. The first dropdown is 'Seleccionar modelo de excavadora:' with the value 'Hyundai Robex 200LC-9SB'. The second is 'Seleccionar tipo de cucharón:' with the value 'SAE APILADO N04'. The third is 'Tipo de material:' with the value 'Arena'. The fourth is 'Estado de material inicial:' with the value 'Banco (1)'. The fifth is 'Estado de material final:' with the value 'Compactado'. Below these is a text input field for 'Capacidad de cucharón:' containing the value '1.072'. At the bottom, there is a label 'Rendimiento: 10.54 m³/h' and two buttons: 'Calcular' and 'Grabar'. To the right of the dropdown menus, there are two images: a yellow excavator and a dark green bucket.

4.3 Dataset generado para entrenar la CNN

Figura 4.3

Resultado del entrenamiento



Nota. De Yolov4.

En la figura 4.3 en el eje Y se observa la pérdida (*Loss*), lo que se quiere o lo que se obtuvo. Al inicio del entrenamiento siempre el valor va a ser alto. En la línea roja tenemos el mAP (*mean average precision*), éste se refiere a la precisión media para el valor de recuperación de 0 a 1, que comprueba si el modelo está generalizando bien en un grupo de datos nunca visto o en un grupo de validación (en la gráfica tiene un valor de 99% de validez). La curva azul es la pérdida de entrenamiento o el error en el conjunto de datos de entrenamiento (en la gráfica, disminuye en el tiempo). A medida que se va entrenando, va

disminuyendo. Por otro lado, en el eje X, tenemos el número de iteración dentro del número máximo de lotes (*batches*), que es como un bucle que realiza predicciones. Al final del lote, las suposiciones se comparan con las variables de salida esperadas y se obtiene un error. A partir de este error, el algoritmo de actualización se utiliza para optimizar el modelo.

Figura 4.4

Resultado del entrenamiento para la identificación de excavadoras



Nota. De Yolov4.

En la figura 4.4 se observa que se logró identificar las excavadoras en videos, con los resultados de la CNN se pasó al algoritmo Deepsort, donde se procesó los videos y se obtuvo la detección y seguimiento de las excavadoras. Seguidamente se extrajo los fotogramas con el algoritmo de extracción de detecciones, para finalmente obtener el *dataset* clasificado manualmente por sus tres actividades principales (cavar, balancear, cargar), que se encuentran disponibles en el enlace anteriormente mencionado.

4.4 Análisis Comparativo del rendimiento de excavadora con la forma automatizada en la hoja de Excel y el programa RENDEXCA

El análisis comparativo del rendimiento de excavadoras entre la forma automatizada en Excel y el programa RENDEXCA se llevó a cabo con el fin de determinar cuál de estos programas es más efectivo y eficiente en la tarea de cálculo de rendimiento de excavadoras. Para lograr esto, se seleccionaron 11 aspectos relevantes para evaluar la calidad y la funcionalidad de ambos programas. Estos aspectos se compararon y se presentaron en una tabla para proporcionar una visión general clara de las fortalezas y debilidades de cada programa. A continuación, se presenta en la tabla 4.1 el análisis comparativo de ambos programas evaluados y en la tabla 4.2 se presenta la tabla comparativa más sintetizada.



Tabla 4.1*Comparación entre los programas automatizados*

Aspectos	Hoja de Excel	Programa RENDEXCA
Funcionalidad	Calcula el rendimiento de 2 modelos de excavadoras. Usa listas para desplegar opciones.	Calcula el rendimiento de 2 modelos de excavadoras. Puede guardar, comparar y editar registros.
Facilidad de uso	Requiere cierta familiaridad con el uso de Excel.	Cuenta con un manual de usuario. Interfaz intuitiva.
Velocidad	Similar al programa RENDEXCA, ya que ambos usan fórmulas matemáticas simples.	Tiene una ventaja debido a que está diseñado específicamente para esta tarea.
Capacidad de registro y comparación de resultados	No incluye esta característica, pero puede programarse.	Permite guardar registros, comparar resultados y editarlos.
Portabilidad	Depende de si el usuario tiene Microsoft Excel instalado.	Puede ejecutarse en cualquier dispositivo.
Compatibilidad	Compatible en todos los sistemas operativos y en las diferentes versiones de Microsoft Excel.	Compatible en todos los sistemas operativos.
Costo	Hay un costo de licencia para activar el Microsoft Excel.	No hay costo, ya que el programa RENDEXCA es de código abierto y gratuito.
Soporte	Soporte limitado a través de recursos en línea.	Puede haber una comunidad de usuarios y desarrolladores más grande que ofrezca soporte.
Escalabilidad	Por el momento cuenta con dos modelos de excavadoras, pero puede ampliarse a futuro.	Por el momento cuenta con dos modelos de excavadoras, pero puede ser más escalable y personalizable debido a que está escrito en Python.
Mantenimiento	Puede que en versiones posteriores cambien los comandos del programa.	Puede ser más fácil de mantener y actualizar debido a su arquitectura de software.
Tipo de interfaz	Debe ingresar los datos en celdas específicas de una hoja de cálculo y luego seleccionar las listas para que genere los resultados.	Presenta al usuario una ventana con campos organizados de forma clara para ingresar los datos necesarios.

CAPÍTULO V: DISCUSIÓN

Ambos programas, la hoja de Excel y RENDEXCA, tienen como objetivo principal el cálculo del rendimiento de excavadoras en un proyecto de construcción. Aunque difieren en cuanto a las herramientas utilizadas, ambos están validados para ofrecer el mismo resultado para los mismos datos de entrada.

Al comparar los dos programas automatizados, en cuanto a la elección de datos, ambos cuentan con la capacidad de seleccionar la información necesaria para el cálculo. El programa RENDEXCA cuenta con la característica de limitar rangos en ciertas opciones y generar alertas si se superan o si se dejan espacios en blanco lo que permite una mayor precisión en el cálculo; además, tiene la capacidad de guardar registros y comparar resultados lo que facilita el seguimiento del rendimiento de la excavadora a lo largo del tiempo, que a diferencia de la hoja de Excel no ha sido programado con esas funciones.

En cuanto a la interfaz, la facilidad de uso y la portabilidad, RENDEXCA supera a la hoja de Excel. A pesar de que Microsoft Excel es un programa ampliamente utilizado y conocido, RENDEXCA tiene la ventaja de ser diseñado específicamente para el cálculo de rendimiento de excavadoras, lo que lo hace más eficiente y preciso. Asimismo, ambos pueden ser actualizados y utilizados en diferentes sistemas operativos sin mayores dificultades.

En resumen, ambos programas cuentan con características similares. Sin embargo, el programa RENDEXCA que está específicamente diseñado para el cálculo de rendimiento de excavadoras es una excelente opción para su implementación en proyectos de construcción a largo plazo.

CONCLUSIONES

A continuación, presentamos las conclusiones:

- El uso de la inteligencia artificial en nuestra investigación mediante redes neuronales convolucionales fue de gran utilidad para comprender el funcionamiento de los algoritmos. Sin embargo, evaluando más posibilidades se optó por un proceso más factible mediante la creación del código del programa RENDEXCA.
- El programa RENDEXCA tiene la finalidad de calcular el rendimiento de las excavadoras que implementa múltiples herramientas para obtener resultados fácilmente. El aporte principal de nuestra investigación es el código abierto que se creó para obtener el programa RENDEXCA. Este código puede ser modificado y mejorado ya que se encuentra en un repositorio online donde cualquier programador o persona interesada pueda aportar al código y así se desarrollaría activamente el programa.
- Se demostró mediante el análisis comparativo que ambos programas cuentan con características similares sin embargo el programa automatizado RENDEXCA tiene mayor precisión en el cálculo de datos, otorga resultados inmediatos y presenta una interfaz más intuitiva.
- Con la metodología propuesta se esclareció y comprendió el seguimiento y control del movimiento de tierras para la obtención del rendimiento de excavadoras.
- Los resultados de datos ingresados respaldan la viabilidad y aplicabilidad del método automatizado propuesto en la práctica para analizar de forma directa el rendimiento.
- Se logró generar la *dataset* mediante las operaciones de detección y seguimiento del algoritmo Deepsort y `generate_detections.py` previamente entrenado con la red neuronal YOLOv4.

RECOMENDACIONES

A continuación, detallaremos las recomendaciones:

- Sobre la base de los resultados obtenidos de esta investigación, se recomienda tener conocimientos previos en base de datos y de lenguajes de programación como Python para la creación del programa RENDEXCA.
- Se recomienda tener nociones básicas y conocimientos previos de la partida de movimiento de tierras en cualquier proyecto de construcción.
- Para la implementación de la metodología de generación de la *dataset* se recomienda tener un ordenador con características no inferiores a un procesador Inter Core i7 7ma generación, una memoria RAM de 24GB y una tarjeta de video GTX 1080 (6GB).
- Cabe recalcar que todos los datos se encuentran en esta carpeta drive en el siguiente enlace:<https://drive.google.com/drive/u/1/folders/1ELFLPJ5PqAnnFXGvBLp-r4QE0kZcqSuV>

REFERENCIAS

- Aguilar, A., & Ysla, L. (2016). Cálculo de rendimiento de retroexcavadora,excavadora y cargador frontal en movimiento de tierras,Chachapoyas,Amazonas-2015. Tesis Titulación. Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas, Chachapoyas.
- Bello, A., & Álvarez, J. (2015). Estudio de los rendimientos de maquinaria pesada en los movimientos de tierras en la ciudad de Cartagena caso estudio: Urbanización Coral Lakes y Zona Franca Parque Central. *Trabajo de grado - Pregrado*. Universidad de Cartagena, Cartagena.
- Boden, M. (2016). *Inteligencia Artificial*. Turner Publicaciones S.L.
- Caballero, J., Salazar, M., Moradillos, M., & Pavoni, S. (2014). Implementación de la función sigmoïdal logarítmica en un FPGA. *Artículo*. SCIELO, La Habana.
- Carranza, P., & Combita, W. (2015). Análisis del desempeño de la excavadora CAT 320D en la construcción de una vía, ejecutando actividades de movimiento de tierra, caso de estudio - Proyecto Caricare en el Departamento Arauca. *Tesis Titulación*. Universidad La Gran Colombia, Bogotá.
- Chen, C., Zhu, Z., & Hammad, A. (2019). Automated excavators activity recognition and productivity analysis from construction site surveillance videos. *ARTICLE*. ELSEVIER, Montreal.
- El Naqa, I., & Murphy, M. (2015). *What is Machine Learning?* Springer International Publishing Switzerland. doi:10.1007/978-3-319-18305-3_1
- Fisk, E., & Reynolds, W. (2006). *Construction Project Administration*. Pearson Prentice Hall.
- Flores, R. (2015). Eficiencia y Productividad óptima en Movimiento de Tierras para la construcción de Plataformas de Lixiviación. *Tesis Titulación*. Universidad Nacional del Centro del Perú, Huancayo.

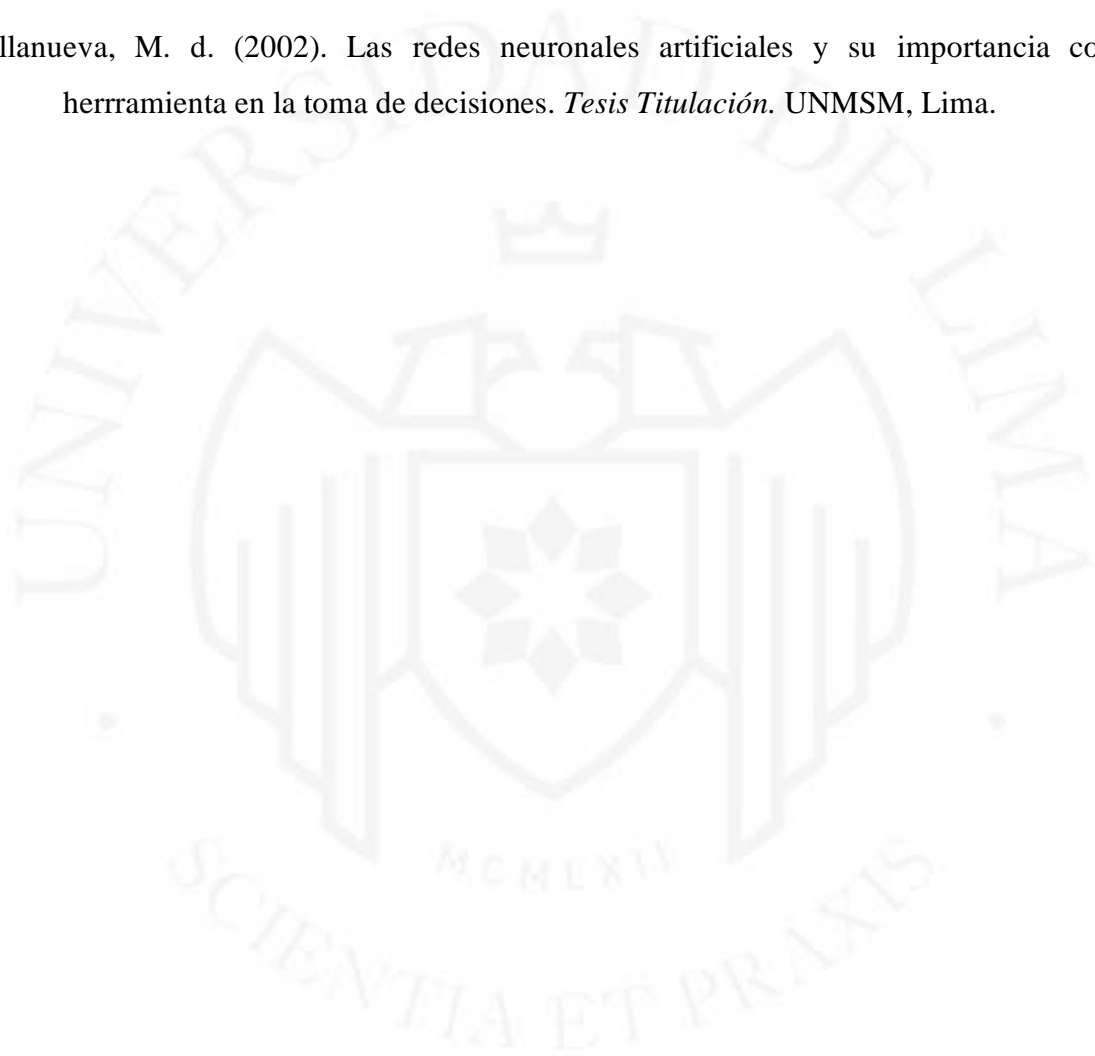
- Gong, J., & Caldas, C. (2011). An object recognition, tracking, and contextual reasoning-based video interpretation method for rapid productivity analysis of construction operations. *Article*. ELSEVIER, Texas.
- Haugeland, J. (1985). *La Inteligencia Artificial*. Siglo veintiuno editores.
- Hernández, R., Fernández, C., & Baptista, M. (2014). *Metodología de la Investigación*. Mc Graw Hill.
- Holt, G. (2015). Analysis of interrelationships among excavator productivity modifying factors. *Article*. International Journal of Productivity and Performance Management, Kentucky.
- Ideconsa. (2018, Mayo 16). *El movimiento de tierras, etapa fundamental en las obras*. Retrieved from <https://ideconsa.net/2018/05/16/movimiento-tierras-etapa-fundamental-las-obras/>
- Ipesa. (2020, Junio 3). *Tipos de excavadoras y sus diferentes usos*. Retrieved from <https://www.ipesa.com.pe/blog/tipos-excavadoras-usos/>
- Kim, J., & Chi, S. (2019). Action recognition of earthmoving excavators based on sequential pattern analysis of visual features and operation cycles. *Article*. University National Seoul, Republic of Korea.
- Koch, C., Georgieva, K., Kasireddy, V., Akinci, B., & Fieguth, P. (2015). A review on computer vision based defect detection and condition assesment of concrete and asphalt civil infrastructure. *Article*. ELSEVIER, Bochum.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Article*. Review, New York.
- Liu, T., Fang, S., Zhao, Y., Wang, P., & Zhang, J. (2015). Implementation of Training Convolutional Neural Networks. *Article*. University of Chinese Academy of Sciences, Beijing.
- Luo, H., Xiong, C., Fang, W., Love, P., Zhang, B., & Ouyang, X. (2018). Convolutional neural networks: Computer vision-based workforce activity assessment in construction. *Article*. ScienceDirect, Wuhan.

- Makantasis, K., Protopapadakis, E., & Doulamis, A. (2015). Deep Convolutional Neural Networks for Efficient Vision Based Tunnel Inspection. *Article*. Technical University of Crete, Athens.
- Malpica, C. (2014). Evaluación de rendimientos de equipos en las operaciones de movimiento de tierras en el minado Cerro Negro Yanacocha - Cajamarca. *Tesis titulación*. Universidad Privada del Norte, Cajamarca.
- Mitacc, E. (2006). Automatización de una Subestación para el Mejoramiento del Servicio en una Empresa de Distribución de Energía Eléctrica. *Tesis titulación*. Universidad de Lima, Lima.
- MOTORGIGA. (2023). *Excavadora-definición-significado*. Retrieved from <https://diccionario.motorgiga.com/diccionario/excavadora-definicion-significado/gmx-niv15-con194086.htm>
- ONU. (2015). *Objetivos de desarrollo Sostenible*. Retrieved from <https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/>
- Peru21. (2023, Febrero 13). *Inteligencia artificial al 2030: ¿qué tipo de empresas demandarán más a profesionales especializados?* Retrieved from <https://peru21.pe/economia/inteligencia-artificial-permitiria-duplicar-el-pbi-del-peru-al-2030-noticia/>
- Peurifoy, R., Schexnayder, C., & Shapira, A. (2006). *Construction Planning, Equipment, and Methods*. Mc Graw Hill.
- Singh, A. (2020, February). *Demystifying the Mathematics Behind Convolutional Neural Networks (CNNs)*. Retrieved from https://www.analyticsvidhya.com/blog/2020/02/mathematics-behind-convolutional-neural-network/?utm_source=blog&utm_medium=cnn-vs-rnn-vs-mlp-analyzing-3-types-of-neural-networks-in-deep-learning
- Sopie, M., Vukomanovic, M., Car-Pusic, D., & Zavrski, I. (2021). Estimation of the excavator actual productivity at the construction site using video analysis. *Articulo*.

Thamm, A. (2023). *Red neuronal directa*. Retrieved from <https://www.alexanderthamm.com/es/data-science-glossary/red-neuronal-feedforward/>

VijiPriya, J., Ashok, J., & Suppiah, S. (2016). A Review on Significance of Sub Fields in Artificial Intelligence. *Article*. International Journal of Latest Trends in Engineering and Technology.

Villanueva, M. d. (2002). Las redes neuronales artificiales y su importancia como herramienta en la toma de decisiones. *Tesis Titulación*. UNMSM, Lima.



BIBLIOGRAFÍA

- Chen, C., Zhu, Z., & Hammad, A. (2020). Automated excavator's activity recognition and productivity analysis from construction site surveillance videos. *Automation in Construction*, 110, 103045. <https://doi.org/10.1016/j.autcon.2019.103045>
- Gong, J., & Caldas, C. H. (2011). An object recognition, tracking, and contextual reasoning-based video interpretation method for rapid productivity analysis of construction operations. *Automation in Construction*, 20(8), 1211–1226. <https://doi.org/10.1016/j.autcon.2011.05.005>
- Kim, J., & Chi, S. (2019). Action recognition of earthmoving excavators based on sequential pattern analysis of visual features and operation cycles. *Automation in Construction*, 104, 255–264. <https://doi.org/10.1016/j.autcon.2019.03.025>
- Kim, J., & Chi, S. (2020). Multi-camera vision-based productivity monitoring of earthmoving operations. *Automation in Construction*, 112, 103121. <https://doi.org/10.1016/j.autcon.2020.103121>
- VijiPriya, J., Ashok, Jammi., & Suppiah, S (2016). A review on significance of sub fields in artificial intelligence. (n.d.). Retrieved May 11, 2021, from https://www.ijltet.org/journal_details.php?id=898&j_id=2900
- Koch, C., Georgieva, K., Kasireddy, V., Akinci, B., & Fieguth, P. (2015). A review on computer vision-based defect detection and condition assessment of concrete and asphalt civil infrastructure. *Advanced Engineering Informatics*, 29(2), 196–210. <https://doi.org/10.1016/j.aei.2015.01.008>
- Luo, H., Xiong, C., Fang, W., Love, P. E. D., Zhang, B., & Ouyang, X. (2018). Convolutional neural networks: Computer vision-based workforce activity assessment in construction. *Automation in Construction*, 94, 282–289. <https://doi.org/10.1016/j.autcon.2018.06.007>

- Ramezani, M., & Tafazoli, S. (2021). Using Artificial Intelligence in Mining Excavators: Automating Routine Operational Decisions. *IEEE Industrial Electronics Magazine*, 15(1), 6–11. <https://doi.org/10.1109/MIE.2020.2964053>
- Šopić, M., Vukomanović, M., Car-Pušić, D., & Završki, I. (2021). Estimation of the excavator actual productivity at the construction site using video analysis. *Organization, Technology and Management in Construction*, 13(1), 2341–2352. <https://doi.org/10.2478/otmcj-2021-0003>
- Yoon, J., Kim, J., Seo, J., & Suh, S. (2014). Spatial factors affecting the loading efficiency of excavators. *Automation in Construction*, 48, 97–106. <https://doi.org/10.1016/j.autcon.2014.08.002>
- Salem, A., & Moselhi, O. (2018). Automated monitoring and assessment of productivity in earthmoving projects. *Canadian Journal of Civil Engineering*, 45(11), 958–972. <https://doi.org/10.1139/cjce-2018-0183>
- Holt, G. D., & Edwards, D. (2015). Analysis of interrelationships among excavator productivity modifying factors. *International Journal of Productivity and Performance Management*, 64(6), 853–869. <https://doi.org/10.1108/IJPPM-02-2014-0026>
- Lampinen, A. K., & McClelland, J. L. (2021). Transforming task representations to perform novel tasks. *Proceedings of the National Academy of Sciences of the United States of America*, 117(52), 32970–32981. <https://doi.org/10.1073/PNAS.2008852117>
- Makantasis, K., Protopapadakis, E., Doulamis, A., Doulamis, N., & Loupos, C. (2015). Deep Convolutional Neural Networks for efficient vision-based tunnel inspection. *Proceedings - 2015 IEEE 11th International Conference on Intelligent Computer Communication and Processing, ICCP 2015*, 335–342. <https://doi.org/10.1109/ICCP.2015.7312681>
- Muzahid, A. A. M., Wan, W., Sohel, F., Wu, L., & Hou, L. (2021). CurveNet: Curvature-Based Multitask Learning Deep Networks for 3D Object Recognition. *IEEE/CAA*

Journal of Automatica Sinica, 8(6), 1177–1187.
<https://doi.org/10.1109/JAS.2020.1003324>

Zhang, X.-D. (2020). Machine Learning. A Matrix Algebra Approach to Artificial Intelligence, 223–440. https://doi.org/10.1007/978-981-15-2770-8_6

Rafael Lahoz-Beltrá. Bioinformática: simulación, vida artificial e inteligencia artificial - Rafael Lahoz-Beltrá - Google Libros. (n.d.). Retrieved November 12, 2021, from <https://books.google.es/books?hl=es&lr=&id=1Lxt1Eviy8cC&oi=fnd&pg=PA3&dq=Inteligencia+artificial&ots=OtHs7r23o7&sig=g8KNooPYLKIVbZGdYud0KPq0Fw4#v=onepage&q=Inteligencia+artificial&f=false>

Margaret A. Boden. Inteligencia Artificial. Retrieved November 12, 2021, from <https://books.google.es/books?hl=es&lr=&id=LCnYDwAAQBAJ&oi=fnd&pg=PT3&dq=Inteligencia+artificial&ots=drSrCWfJhd&sig=ICwkicKmeS6gE4hioaPsuJsUUdc#v=onepage&q=Inteligencia+artificial&f=false>

Decord version of video_to_frame.py · GitHub. (n.d.). Retrieved November 12, 2021, from <https://gist.github.com/HaydenFaulkner/3aa69130017d6405a8c0580c63bee8e6>

El Naqa, I., & Murphy, M. J. (2015). What Is Machine Learning? Machine Learning in Radiation Oncology, 3–11. https://doi.org/10.1007/978-3-319-18305-3_1

La inteligencia artificial - John Haugeland - Google Libros. (n.d.). Retrieved November 12, 2021, from https://books.google.es/books?hl=es&lr=&id=BcKGEg_HBvYC&oi=fnd&pg=PA4&dq=inteligencia+artificial&ots=fqL5Kq8H8E&sig=xf9U0DBsUwGJFwg_spAoTwXOYb8#v=onepage&q=inteligencia+artificial&f=false

Kassem, M., Mahamedi, E., Rogage, K., Duffy, K., & Huntingdon, J. (2021). Measuring and benchmarking the productivity of excavators in infrastructure projects: A deep neural network approach. Automation in Construction, 124, 103532. doi:10.1016/j.autcon.2020.103532

- Jin-Young Kim and Sung-Bae Cho, A deep neural network ensemble of multimodal signals for classifying excavator operations, Neurocomputing, <https://doi.org/10.1016/j.neucom.2020.01.127>
- Germán, G. Z. (2016, 12 julio). Análisis y ejecución de movimiento de tierras en una obra empleando el diagrama de curva masa. <https://pirhua.udep.edu.pe/handle/11042/2441>
- Edwin, D. O. (2016). Cálculo de rendimiento de retroexcavadora, excavadora y cargador frontal en movimiento de tierras, Chachapoyas, Amazonas - 2015. <https://repositorio.untrm.edu.pe/handle/20.500.14077/651>
- Alejandro, C. B. (2015, 8 enero). Evaluación de rendimientos de equipos en las operaciones de movimiento de tierras en el minado Cerro Negro Yanacocha – Cajamarca. <https://repositorio.upn.edu.pe/handle/11537/6653>
- COMREIVIC-impulsando el desarrollo. Excavadora Doosan DX225LCA (s. f.). <https://www.comreivic.com.pe/producto/dx225lca/>
- Hyundai Construction Equipment. (s. f.). Excavadora R220LC-9SB - Equipos de construcción. <https://www.hce.com.uy/productos/excavadoras/excavadoras-sobre-bandas/r220lc-9sb>
- Flores, R.E. (2015). Eficiencia y productividad optima en movimiento de tierras para la construcción de plataformas de lixiviación. (Tesis de licenciatura) UNCP



Anexo 1: Hoja de materialidad

ID	Tipo de publicación	Revista	Rango cuartil	Factor de impacto	Año de publicación
1	Tesis	-	-	-	2016
2	Tesis	-	-	-	2015
3	Tesis	-	-	-	2014
4	Artículo	Automation in Construction	Q1	5.669	2020
5	Artículo	Automation in Construction	Q1	5.669	2011
6	Artículo	Automation in Construction	Q1	5.669	2020
7	Artículo	Automation in Construction	Q1	5.669	2019
8	Artículo	Proceedings of the National Academy of Sciences of the USA	Q1	9.412	2021
9	Artículo	Organization Technology and Management in Construction	-	-	2021
10	Artículo	Canadian Journal of Civil Engineering	Q2	5,7	2018
11	Artículo	Advanced Engineering Informatics	Q2	3.879	2015
12	Artículo	Automation in Construction	Q1	5.669	2021
13	Artículo	International Journal of Productivity and Performance Management	Q2	2.77	2015
14	Proceedings Paper	2015 IEEE 11th International Conference on Intelligent Computer Communication and Processing	-	0.164	2015
15	Artículo	Automation in Construction	Q1	5.669	2018

ID	Título	Autores	Palabras claves
1	Cálculo de rendimiento de retroexcavadora, excavadora y cargador frontal en movimiento de tierras, Chachapoyas, Amazonas-2015	Aguilar Azañero,A; Ysla Oyarce,L.	Rendimiento, maquinaria pesada, movimiento de tierras.
2	Análisis y Ejecución de movimiento de tierras en una obra empleando el diagrama de Curva masa	Guevara Martinez, F.	Movimiento de tierras, rendimiento, vías terrestres.
3	Evaluación de rendimientos de equipos en las operaciones de movimiento de tierras en el Minado Cerro Negro Yanacocha-Cajamarca	Malpica Quijada, C.	Movimiento de tierras, maquinaria pesada, rendimiento.
4	Multi-camera vision-based productivity monitoring of earthmoving operations	Jinwoo Kim, Seokho Chi	Action recognition, tracking, simulation.
5	An object recognition, tracking, and contextual reasoning-based video	Jie Gong,Carlos H.Caldas	Visualization, simulation.
6	Automated Excavators Activity Recognition and Productivity Analysis from Construction Site Surveillance Videos	Chen Chena, Zhenhua Zhub, Amin Hammad	Earthmoving excavators, workers activities, equipment.
7	Action Recognition of Earthmoving Excavators Based on Sequential Pattern	Jinwoo Kim, Seokho Chi	Construction workers, vision, tracking.
8	Transforming task representations to perform novel task	Lampinen, A.K., McClelland, J.L.	Cognitive science, artificial intelligence, transfer.
9	Estimation of the excavator actual productivity at the construction site using video analysis	Sopic, Martina; Vukomanovic, Mladen; Car-Pusic, Diana; Zavrski, Ivica	Earthmoving excavators, action recognition, equipment.
10	Automated Monitoring and Assesment of Productivity in Earthmoving Projects	Salem, A., Moselhi, O.	Automated data acquisition, earthmoving operations, productivity measurement.
11	A review on computer vision-based defect detection and condition assessment of concrete and asphalt civil infrastructures	Koch Christian, Kristina Georgieva, Varun Kasireddy, Burcu Akinci and Paul Fieguth.	Of-the-art, crack detection, scene reconstruction.
12	Spatial factors affecting the loading efficiency of excavators	Jungho Yoon, Jeonghwan Kim, Jongwon Seo, Sangwook Suh	Hydraulic excavator, system.

(continúa)

(continuación)

ID	Título	Autores	Palabras claves
13	Analysis of interrelationships among excavator productivity modifying factors	Holt, Gary D; Edwards, David	Performance, plant.
14	Deep Convolutional Neural Networks for efficient vision-based tunnel inspection	Makatansis K., Protopapadakis E., Doulamis A., Doulamis N., Loupos C.	Machine visión, concrete, system.
15	Convolutional neural networks: Computer vision-based workforce activity assessment in construction	Luo, Hanbin; Xiong, Chao-hua; Fang, Weili; Love, Peter E. D; Zhang, Bowen; Ouyang, Xi	Action recognition, workers, productivity.

ID	Resumen	Veces citado	Fecha de búsqueda
1	En este estudio se destaca que, el cálculo para el rendimiento de maquinaria pesada en el movimiento de tierras en la ciudad de Chachapoyas depende de en qué condiciones y factores se van a realizar las actividades. Cabe resaltar que esta investigación es de tipo descriptiva donde nos mencionan maquinarias pesadas como: Cat 420F, excavadora Cat 329D y cargador frontal Cat 962H.	-	13/1/2023
2	En la presente investigación se resalta la importancia del diseño de rutas de transporte terrestre para el acceso minero con todos los parámetros necesarios para determinar la cantidad de material que será removido para acomodar la subrasante del terreno. Esto se denomina "Movimiento de Tierra" y es de vital importancia para analizar la pérdida o ganancia de tiempo y dinero.	-	13/1/2023
3	Dentro del estudio de esta investigación, se analiza la funcionalidad de la maquinaria según el tipo de material involucrado y las propiedades del suelo en que se trabaja. Las actividades de maquinaria pesada analizadas son: carga con excavadora, empuje del tractor sobre orugas, carguío con cargador frontal, acarreo con volquetes de 15 m ³ y el perfilado del terreno con motoniveladora.	-	13/1/2023
4	Este artículo aborda la metodología empleada para llevar a cabo un monitoreo de productividad a fin de evaluar correctamente la eficiencia operativa de los equipos pesados a través del uso de múltiples cámaras que mediante datos de video nos permiten un monitoreo preciso de estos y por preferencia se ubican en diferentes posiciones físicas en el sitio.	62	27/4/2021
5	Este artículo propone mejorar la productividad en operaciones de construcción mediante el elementos, procesos y algoritmos que componen un método de interpretación de video de construcción inteligente y computacional. De esta forma, automatizando esta interpretación de video a uno de forma semiautomático mediante algoritmos, se pueden mejorar procesos de trabajo, tiempos de ciclo y retrasos con una precisión comparable al análisis manual sin las limitaciones de la observación humana.	40	27/4/2021

(continúa)

(continuación)

ID	Resumen	Veces citado	Fecha de búsqueda
6	Marco automático basado en la visión para la supervisión del funcionamiento de múltiples excavadoras y el cálculo de la productividad cálculo. El marco integra los módulos de detección, seguimiento, reconocimiento de la actividad y el cálculo de la productividad.	43	27/4/2021
7	Marco de reconocimiento de acciones basado en la visión que incorpora los patrones secuenciales de las características visuales de las excavadoras y los ciclos de funcionamiento. Consta de tres procesos principales: detección de excavadoras, seguimiento de excavadoras y reconocimiento de acciones de excavadoras.	46	27/4/2021
8	Una de las capacidades más importantes que tiene la inteligencia es la de adaptarse a una tarea novedosa sin ninguna experiencia es lo que llamamos "flexibilidad cognitiva", típica en los seres humanos. Así mismo, este tipo de habilidad, podríamos aplicarlo a modelos que logran un rendimiento sobrehumano en tareas específicas mediante métodos computacionales (algoritmos) haciendo así que se puedan adaptar a tareas novedosas en función de su relación con tareas anteriores.	55	6/5/2021
9	Marco de investigación simple para estimar de forma rápida y práctica la productividad real de la excavadora y el tiempo de ciclo en una obra de construcción durante el movimiento de tierras.	45	5/6/2021
10	Este artículo presenta un modelo de adquisición de datos automatizado y personalizado de múltiples fuentes que adquiere datos de una variedad de tecnologías de detección inalámbrica. Los datos adquiridos de múltiples sensores se transmiten a una base de datos central MySQL. De esta forma el modelo propuesto realiza un seguimiento y la evaluación de la productividad real y sus desviaciones con respecto a la productividad planificada del movimiento de tierras.	4	5/6/2021
11	En los últimos años, se han incrementado los métodos de visión por computadora para aplicaciones en la ingeniería civil. Por ello, este artículo presenta una síntesis de estado del arte en la detección de defectos basado en visión por computadora.	119	5/6/2021
12	En este artículo se identifican los principales factores que afectan las operaciones de carga en los movimientos de la excavadora. Para observar estos tipos de cambios se centran en 2 hipótesis principales como: cambios en el tiempo de carga según la diferencia de altura y tiempo de carga cuando cambia el ángulo de rotación.	18	5/6/2021
13	En la productividad de las excavadoras, la variable dependiente (volumen de excavación por unidad de tiempo) depende de muchas variables independientes (como el tamaño de la máquina, el tamaño del caso, el tipo de suelo y las condiciones de la obra). Una variable clave de la productividad es la competencia del operario (OC), ya que puede influir en muchas de las demás variables.	45	6/6/2021
14	Actualmente la inspección visual representa uno de los mayores desafíos para los ingenieros para determinar la seguridad de las estructuras de concreto, debido a que estos se realizan de forma manual. Esto requiere un nivel de esfuerzo significativo al involucrar a los inspectores que caminan a lo largo de la superficie de las estructuras. Por lo que, ante esto, se propone enfoques automatizados mediante desarrollo de algoritmos que permitan superar el problema mencionado.	64	6/6/2021
15	Se propone una CNN mejorada que integra el RGB, el flujo óptico y el flujo de grises para supervisar con precisión y evaluar automáticamente las actividades de los trabajadores para mejorar la gestión de los proyectos de construcción.	55	6/6/2021

ID	Tipo de publicación	Título	Diseño	Enfoque	Tipo de investigación
1	Tesis	Cálculo de rendimiento de retroexcavadora, excavadora y cargador frontal en movimiento de tierras, Chachapoyas, Amazonas-2015	Observacional	Cuantitativo	Aplicada
2	Tesis	Análisis y Ejecución de movimiento de tierras en una obra empleando el diagrama de Curva masa	Observacional	Mixto	Técnica
3	Tesis	Evaluación de rendimientos de equipos en las operaciones de movimiento de tierras en el Minado Cerro Negro Yanacocha-Cajamarca	Observacional	Cualitativo	Técnica
4	Artículo	Multi-camera vision-based productivity monitoring of earthmoving operations	Experimental	Cuantitativo	Técnica
5	Artículo	An object recognition, tracking, and contextual reasoning-based video	Experimental	Cuantitativo	Técnica
6	Artículo	Automated Excavators Activity Recognition and Productivity Analysis from Construction Site Surveillance Videos	Experimental	Mixto	Aplicada
7	Artículo	Action Recognition of Earthmoving Excavators Based on Sequential Pattern	Experimental	Cuantitativo	Aplicada
8	Artículo	Transforming task representations to perform novel task	Observacional	Mixto	Aplicada
9	Artículo	Estimation of the excavator actual productivity at the construction site using video analysis	Observacional	Mixto	Aplicada
10	Artículo	Automated Monitoring and Assesment of Productivity in Earthmoving Projects	Experimental	Cuantitativo	Técnica
11	Artículo	A review on computer vision-based defect detection and condition assessment of concrete and asphalt civil infrastructures	Observacional	Cualitativo	Aplicada
12	Artículo	Spatial factors affecting the loading efficiency of excavators	Observacional	Cualitativo	Aplicada
13	Artículo	Analysis of interrelationships among excavator productivity modifying factors	Observacional	Mixto	Aplicada
14	Proceedings Paper	Deep Convolutional Neural Networks for efficient vision-based tunnel inspection	Observacional	Cualitativo	Aplicada
15	Artículo	Convolutional neural networks: Computer vision-based workforce activity assessment in construction	Experimental	Mixto	Técnica

Anexo 2: Variables de estudio

Variable de estudio	Definición Conceptual	Dimensiones	Indicadores	Escala de Medición
Rendimiento de excavadoras	El rendimiento de excavadoras se define como la cantidad de material movido, transportado, compactado o instalador por maquinaria pesada operada por trabajadores calificados y, dependiendo de la maquina se esté operando, el rendimiento suele ser expresado como la cantidad de actividad realizada por unidad de tiempo (Carranza, P Y Combita, W. 2015)	Tiempo de operación	Cronograma de obra	Razón
		Volumen excavado	Capacidad de cuchara	Razón

Anexo 3: Matriz ODS Objetivo #9

ODS 9 Industria, Innovación e Infraestructura	
9.1	Desarrollar una infraestructura resiliente centrada en el acceso equitativo y asequible
	9.1.1 Proporción de la población rural que vive a menos de 2 km de una carretera transitable todo el año 9.1.2 Volumen de transporte de pasajeros y carga, desglosado por medio de transporte
9.2	Promover la industrialización inclusiva y sostenible
	9.2.1 Valor añadido del sector manufacturero en proporción al PIB per cápita 9.2.2 Empleo del sector manufacturero en proporción al empleo total
9.3	Aumentar el acceso de pequeñas industrias y otras empresas a los servicios financieros
	9.3.1 Proporción del valor añadido total del sector industrial correspondiente a las pequeñas industrias 9.3.2 Proporción de las pequeñas industrias que han obtenido un préstamo o una línea de crédito
9.4	Modernizar la infraestructura y hacer industrias sostenibles
	9.4.1 Emisiones de CO2 por unidad de valor añadido
9.5	Fortalecer la investigación científica para mejorar las capacidades tecnológicas de los sectores industriales
	9.5.1 Gastos en investigación y desarrollo en proporción al PIB 9.5.2 Número de investigadores (en equivalente a tiempo completo) por cada millón de habitantes
9.a	Facilitar el desarrollo de infraestructura resilientes mediante el apoyo financiero tecnológico y técnico
	9.a.1 Total de apoyo internacional oficial (asistencia oficial para el desarrollo más otras corrientes oficiales de recursos) destinado a la infraestructura
9.b	Apoyar el desarrollo tecnológico, la investigación y la innovación para diversificar la industria y valorizar los productos básicos
	9.b.1 Proporción del valor añadido por la industria de tecnología mediana y alta en el añadido total
9.c	Aumentar el acceso a las tecnologías de información, comunicación y acceso a Internet a precios asequibles
	9.c.1 Proporción de la población con cobertura de red móvil, desglosada por tecnología

Revisión de originalidad 2

INFORME DE ORIGINALIDAD

9%

INDICE DE SIMILITUD

9%

FUENTES DE INTERNET

2%

PUBLICACIONES

%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1

repositorio.untrm.edu.pe

Fuente de Internet

1%

2

hdl.handle.net

Fuente de Internet

1%

3

www.scribd.com

Fuente de Internet

1%

4

repositorio.uned.ac.cr

Fuente de Internet

<1%

5

tesis.pucp.edu.pe

Fuente de Internet

<1%

6

repository.unimilitar.edu.co

Fuente de Internet

<1%

7

es.scribd.com

Fuente de Internet

<1%

8

repositorio.uts.edu.co:8080

Fuente de Internet

<1%

9

repositorio.upao.edu.pe

Fuente de Internet

<1%

10	pirhua.udep.edu.pe Fuente de Internet	<1 %
11	cybertesis.uni.edu.pe Fuente de Internet	<1 %
12	cathi.uacj.mx Fuente de Internet	<1 %
13	repositorioinstitucional.buap.mx Fuente de Internet	<1 %
14	zagan.unizar.es Fuente de Internet	<1 %
15	erecursos.uacj.mx Fuente de Internet	<1 %
16	tech.gobetech.com Fuente de Internet	<1 %
17	docplayer.es Fuente de Internet	<1 %
18	vsip.info Fuente de Internet	<1 %
19	www.ijltet.org Fuente de Internet	<1 %
20	link.springer.com Fuente de Internet	<1 %
21	repositorio.ulima.edu.pe Fuente de Internet	<1 %

22	www.coursehero.com Fuente de Internet	<1 %
23	repositorio.ucv.edu.pe Fuente de Internet	<1 %
24	repositorio.upsjb.edu.pe Fuente de Internet	<1 %
25	doczz.es Fuente de Internet	<1 %
26	dspace.ucuenca.edu.ec Fuente de Internet	<1 %
27	renati.sunedu.gob.pe Fuente de Internet	<1 %
28	repositorio.uncp.edu.pe Fuente de Internet	<1 %
29	1library.co Fuente de Internet	<1 %

Excluir citas

Activo

Excluir coincidencias < 15 words

Excluir bibliografía

Activo