

Informe Final Proyecto

**MODELO PREDICTIVO DE FACTORES DE RIESGOS LABORALES
CON USO DE INTELIGENCIA ARTIFICIAL**

Código: 221-2018

ASOCIACIÓN CHILENA DE SEGURIDAD

Safety for Life SpA

Mario Villalobos Reyes

Santiago, Chile Diciembre-2019

Este trabajo fue seleccionado en la Convocatoria de Proyectos de Investigación e Innovación en Prevención de Accidentes y Enfermedades Profesionales 2018 de la Superintendencia de Seguridad Social (Chile) y fue financiado por la Asociación Chilena de Seguridad, a través de la Fundación Científica y Tecnológica (FUCYT-ACHS), con recursos del Seguro Social de la Ley N°16.744 de Accidentes del Trabajo y Enfermedades Profesionales.

INDICE DE CONTENIDOS

A. ANTECEDENTES DEL INNOVADOR	4
B. RESUMEN DEL PROYECTO	5
C. INTRODUCCIÓN Y ANTECEDENTES	6
D. DEFINICIÓN DE PROBLEMA O DESAFÍO	7
E. DEFINICIÓN DE LOS USUARIOS Y MASA CRITICA PARA VIABILIDAD	8
F. REVISIÓN DE LA LITERATURA O EXPERIENCIAS RELEVANTES	8
G. ETAPAS DEL DISEÑO DE LA INNOVACIÓN	10
H. DESARROLLO DE LA INNOVACIÓN	11
PLANTEAMIENTO DE LOS OBJETIVOS	11
MARCO METODOLÓGICO	11
DEFINICIÓN DE EMPRESA USUARIA DEL PILOTO	11
DETERMINACIÓN DE FACTORES DE RIESGOS	15
MATERIALES / IMPLEMENTACIÓN	16
EQUIPOS:	16
CONEXIONES Y CABLEADOS:	17
PROFESIONAL TÉCNICO:	17
INSTALACIÓN	17
PRUEBAS Y CAPTURA DE IMÁGENES	19
PREPROCESAMIENTO PARA ADAPTACIÓN A LA RED NEURONAL	20
POSTPROCESAMIENTO Y PREDICCIÓN	25
VISUALIZACIÓN DE FACTORES DE RIESGOS.	26
I. RESULTADOS	28
J. CONCLUSIONES	29
K. REFERENCIAS	31

TABLA DE ILUSTRACIONES

ILUSTRACIÓN 1. PLATAFORMA DE GESTIÓN DEL PROYECTO DE INNOVACIÓN	10
ILUSTRACIÓN 2. PROCESO PRODUCTIVO PLANTA POLPAICO Y AREA SELECCIONADA	12
ILUSTRACIÓN 3. LAYOUT DE CÁMARAS	18
ILUSTRACIÓN 4. DETECCIÓN DE VEARIOS OBJETOS CON YOLO 3	20
ILUSTRACIÓN 5. ARQUITECTURA YOLO.....	21
ILUSTRACIÓN 6. DIAGRAMA DE FUNCIONAMIENTO AMAZON MTURK	22
ILUSTRACIÓN 7. IMÁGENES CARGADAS EN AMAZON MECHANICAL TURK	22
ILUSTRACIÓN 8. ETIQUETADO.....	22
ILUSTRACIÓN 9. REQUERIMIENTOS DE ETIQUETADO COMPLETADOS.	23
ILUSTRACIÓN 10. CONTROL DE CALIDAD DEL PROCESO DE ETIQUETADO	23
ILUSTRACIÓN 11. SCRIPT PROCESO DE APROBACIÓN ETIQUETADO.....	24
ILUSTRACIÓN 12. IMAGEN ETIQUETADA	24
ILUSTRACIÓN 13. ANTECÁMARA SUR	25
ILUSTRACIÓN 14. ANTE CÁMARA COSTA.....	25
ILUSTRACIÓN 15. PRE FRÍO NORTE.....	26
ILUSTRACIÓN 16. PRE FRÍO SUR.....	26
ILUSTRACIÓN 17. VISTA DE FACTORES DE RIESGOS IDENTIFICADOS	27
ILUSTRACIÓN 18. VISTA DE BASE DE DATOS EN PLATAFORMA WEB	27

TABLA DE FOTOGRAFÍAS

FOTOGRAFÍA 1. ÁREA DE ALMACENAMIENTO Y DESPACHO (FRÍO). PLANTA POLPAICO	12
FOTOGRAFÍA 2. ALMACENAMIENTO Y DESPACHO (PREFRIO). PLANTA POLPAICO	13
FOTOGRAFÍA 3. ALMACENAMIENTO Y DESPACHO (PREFRIO). PLANTA POLPAICO	13
FOTOGRAFÍA 4. OPERACIÓN DE GRÚA HORQUILLA. PLANTA POLPAICO	14
FOTOGRAFÍA 5. PALLETS EN ZONA DE DESPACHO. PLANTA POLPAICO	14
FOTOGRAFÍA 6. VISTA GENERAL DE ÁREA EN ESTUDIO. PLANTA POLPAICO.....	15
FOTOGRAFÍA 7. VISITA A TERRENO EQUIPO SAFETY FOR LIFE.....	16
FOTOGRAFÍA 8. CABLEADO.....	18
FOTOGRAFÍA 9. INSTALACIÓN DE CÁMARAS.....	18
FOTOGRAFÍA 10. CONFIGURACIÓN DE CÁMARAS.....	19
FOTOGRAFÍA 11. PRUEBAS DE TRANSMISIÓN DE DATOS.....	19

A. ANTECEDENTES DEL INNOVADOR

En Safety for Life creemos en las empresas preocupadas por la protección de la vida, el bienestar de los trabajadores, la calidad de sus procesos y en la posibilidad de generar cambios significativos a través de la innovación y tecnología.

¿Cómo lo hacemos? Somos una empresa con un equipo de profesionales con más de 15 años de experiencia en implementación, control y seguimiento de sistemas de gestión, tanto en el mundo privado como desde los organismos administradores de la ley de accidentes laborales y enfermedades profesionales.

Transformamos los problemas en soluciones. Convertimos ideas en productos para mejorar la productividad y sustentabilidad de nuestros clientes, buscando diseños y experiencias centradas en los usuarios finales.

¿Qué hacemos? Contamos con un laboratorio de innovación (SafetyLab) que nos permite en un ambiente creativo, experimentar sistemáticamente distintas alternativas para abordar problemas complejos fuera de la contingencia organizacional, articulando soluciones de manera colaborativa y basadas en el aprendizaje.

Durante nuestra trayectoria hemos sido reconocidos en diversas instancias técnicas nacionales e internacionales tales como ganadores del NFC Challenge Claro (Grupo Carso), ORP Conference Internacional, Exponor / Expomin, Clúster Minero Antofagasta, Jornapraso, Asonap HSE (Colombia) y Asociación de Prevencionistas del Perú.

Destacan el desarrollo de productos que han agregado valor significativos en las operaciones, tales como: Plataforma de Reportabilidad Operacional (web / móvil); Safety Analytics para la toma de decisiones basadas en datos; implementación ágil de Sistemas de Gestión; Plataforma para la selección, acreditación y control de Empresas Contratistas; y desde hoy Inteligencia Artificial aplicada a la Seguridad y Salud en el Trabajo (Safety AI).

En esta ocasión, invitamos al proyecto a la Empresa KAUEL, Invenciones Tecnológicas SpA, Empresa con más de 12 años de experiencia, con sede en Estados Unidos, Chile y Ecuador que se

ha transformado en líder de desarrollo tecnológico en los ámbitos de Industria 4.0 (Fotoaerometría, Analítica de imágenes, IoT, Big Data, Inteligencia Artificial (AI), Realidad Virtual, Realidad Aumentada). Con patentes presentadas en Estados Unidos y Chile, enfocadas en trabajo de método de imágenes relacionadas con scanner tridimensional, visión estereoscópica, etc.

Posee alta experiencia en importantes desarrollos de software y electrónica con multinacionales y destacados clientes de clase mundial como: el Massachusetts Institute of Technology (MIT, EE.UU), PG&E (monitoreo de líneas de transmisión eléctrica en California, EE.UU), SuKarne (reconstrucción de plantas tridimensionalmente, México), ISAGEN (Reconstrucción de centrales y subestaciones eléctricas en tres dimensiones, Colombia), SIPEC (monitoreo de líneas de transmisión y ductos en el Amazonas, Ecuador), ENAP (Ecuador), entre otras extranjeras.

B. RESUMEN DEL PROYECTO

El objetivo central del proyecto fue desarrollar una prueba de concepto que permita identificar potenciales escenarios de riesgos laborales al interior de una planta productiva, a través de la captura y análisis de imágenes procesadas con inteligencia artificial (computer vision).

Se realiza acuerdo de colaboración con la empresa Agrícola y Exportadora AGRICOM S.A. para ejecutar el piloto en el área de almacenamiento y despacho de su planta Polpaico, ya que concentraba el mayor número de tareas críticas de la empresa.

Se utiliza la metodología de identificación de peligros y evaluación de riesgos propuesta por la ISO 45.001 como elemento central para determinar los factores de riesgos laborales, tales como tránsito de grúa por sobre línea peatonal, pallet mal cargado o estibado, entre otros.

Se logra implementar con éxito el piloto, identificado diversos factores de riesgos a través de algoritmos que procesan las imágenes capturadas por las cámaras instaladas en las áreas productivas los cuales permitieron diseñar planes de acción personalizados.

C. INTRODUCCIÓN Y ANTECEDENTES

La Política Nacional de Seguridad y Salud en el Trabajo en Chile busca desarrollar y promover una cultura preventiva en toda la sociedad, además de disminuir la ocurrencia de accidentes del trabajo y enfermedades profesionales.

Grandes esfuerzos se han realizado por parte de organismos públicos y privados para sociabilizar, difundir y trabajar sobre los peligros propios de cada industria y, al mismo tiempo, avanzar en estándares cada vez más rigurosos en las empresas. Sin embargo, el año 2018 se registraron 208 accidentes fatales del trabajo (221 en 2017) y una tasa de mortalidad de 3,4 fallecidos cada 100.000 trabajadores protegido¹, lo que es un signo de que aún queda mucho por avanzar en esta materia. Es una dimensión ética en que todos debemos participar.

En el mismo sentido, las conclusiones de la Comisión Presidencial² indicó que “los accidentes laborales son causados tanto por la presencia de condiciones inseguras, como por la existencia de conductas personales inseguras, falta de autocuidado y responsabilidad personal en las conductas de trabajo”.

De esta forma vemos un desafío importante en utilizar las actuales capacidades de cómputo de las máquinas para aplicar técnicas de machine learning e inteligencia artificial (IA), que permitan de manera temprana a las empresas identificar de forma eficiente los peligros en los procesos productivos, evaluar los riesgos a los cuales se exponen los trabajadores, y gestionar los controles operacionales con la información correcta y en el momento adecuado.

La inteligencia artificial se basa en los tipos de modelos que puede elegir según las necesidades de negocio. Por ejemplo, podemos crear un modelo de detección de objetos que reconozca las maquinarias en una imagen, o un modelo de predicción para obtener estimaciones o pronósticos de valores futuros en función de patrones aprendidos por los algoritmos de IA a partir de los datos históricos.

¹ Informe Anual Estadísticas de Seguridad Social, SUSESO 2018

² Comisión Asesora Presidencial para la Seguridad en el Trabajo, 2010

D. DEFINICIÓN DE PROBLEMA O DESAFÍO

La identificación de factores de riesgos que resultan en daño a las personas, pérdidas de tiempo y material resultan difícil de controlar, pues requieren un equipo considerable (supervisores, prevencionistas, jefaturas u otros) que ejecute la gestión preventiva en terreno ya sea verificando el cumplimiento de la jerarquía de controles, o en su defecto interviniendo de forma directa ante un acto o condición que pudiese generar incidentes.

En la actualidad existen demasiadas variables que influyen en la productividad y nivel de riesgo en un proceso, lo que hace imposible de correlacionar con herramientas convencionales. Por ello, se presenta una metodología embebida en una plataforma que haga todas las combinaciones posibles para aumentar la seguridad y productividad de los procesos.

Con lo anterior, el costo asociado a los tiempos que ocupamos completando formularios, la papelería y el procesamiento de la información recogida nos lleva a tomar decisiones de forma tardía y muy reactiva, pues al no contar con medios "conectados en línea" podemos pasar jornadas completas sin conocer el desempeño en materias de seguridad.

Por otra parte, los avances tecnológicos aumentan exponencialmente año a año, poniendo al servicio de la comunidad herramientas que permiten resolver distintas problemáticas de los distintos ámbitos del quehacer laboral, en materias de salud, smartcity, entre otros.

¿Pero qué pasaría si ponemos al servicio de la "prevención de riesgos" la tecnología desarrollada en relación a Inteligencia Artificial?

¿Será posible utilizar la Inteligencia Artificial para la identificación de factores de riesgos que detonan los incidentes?

Con la literatura disponible y de forma hipotética, combinar estos 2 pilares: AI + Prevención de Riesgos Laborales, supondría los siguientes beneficios:

- La optimización de recursos asignados a las medidas de control necesarias para evitar incidentes
- Disminución de registro en papel de actividades preventivas.
- Menores costos, ya que no se requiere de equipos, hardware o software especializados.
- Información oportuna, a través de la entrega de reportes de prevención de riesgos en tiempo real y automatizados.

E. DEFINICIÓN DE LOS USUARIOS Y MASA CRITICA PARA VIABILIDAD

Se identifican como potenciales usuarios a Empresas que:

- Desempeñen actividades de alto riesgo en una o más partes de su proceso productivo.
- Cuenten con procesos productivos en infraestructura fija (esto debido a la instalación de cámaras para la colecta de datos y su posterior etiquetado y configuración).
- Destinen presupuesto acorde a la magnitud del riesgo para la ejecución de proyectos de estas características.

F. REVISIÓN DE LA LITERATURA O EXPERIENCIAS RELEVANTES

a. Actualmente existen algunos estudios puntuales que abordan el análisis de grandes cantidades de datos no estructurados (imágenes) para establecer patrones de comportamientos de los trabajadores, relacionados principalmente a centros de investigación universitarias. El 2015 un equipo científico integrado por expertos en estadística, ingeniería e informática aplicada a la salud de la Universidad de Harvard y del Boston Children's Hospital (EE UU), desarrollaron un modelo, que combinando información epidemiológica y búsquedas de Google, es capaz de predecir los brotes de gripe una o dos semanas antes que los métodos clínicos tradicionales. Según los autores, el modelo podría ser utilizado para mejorar la toma de decisiones de salud pública en tiempo real, como por ejemplo, la distribución de personal y recursos hospitalarios.

b. A nivel internacional recién se están visualizando las primeras aplicaciones de la visión computacional a la prevención de riesgos, destacando el acuerdo firmado en diciembre del 2019 entre Amazon y la National Football League (NFL) para incorporar los servicios de almacenamiento,

base de datos, análisis de datos, inteligencia artificial y machine learning para mejorar la seguridad de los jugadores de fútbol americano, sus entrenamientos, tratamientos médicos y, en última instancia, predecir y prevenir lesiones (blog.aboutamazon.com).

c. En otras experiencias destaca lo realizado por el profesor Xiao-Wei Ye, quien desarrolló tecnología basada en la visión por computadora para evitar colisiones en la navegación de barcos con los puentes de Hangzhou, China. Se analizaron diversas variables tales como características estructurales, volumen de tráfico, velocidad y el peso de los barcos. Como resultados lograron una evaluación y advertencia de colisión en ambos lados del puente a través de tres áreas de seguridad con diferentes niveles de advertencia.

d. También destaca la investigación realizada en el monitoreo de especies de fauna silvestre para determinar cambios en el ecosistema realizada por el Tecnológico Nacional de México en el 2019, quienes utilizando algoritmos de visión por computadora lograron realizar la detección y clasificación. En la discusión del documento el autor señala la necesidad de profundizar en la separación de las clases en características de cada especie, así como el entrenamiento y la fase final del etiquetado.

e. Por otro lado, el artículo publicado por Gregory R. Wagner, M.D., Senior Advisor to the NIOSH Director, en octubre del año 2014 bajo el título "Can Predictive Analytics Help Reduce Work place Risk?", recoge diferentes ejemplos de cómo el Big Data y el Análisis Predictivo está ya siendo utilizado en diversos sectores y resalta la potencialidad de esta herramienta en la mejora de la prevención de riesgos laborales, ya que si somos capaces de predecir con exactitud un accidente, seremos capaces de prevenirlo.

f. Ya en el año 2012, una investigación llevada a cabo por Predictive Solutions Corporation y la Carnegie Mellon University concluyó que los accidentes de trabajo pueden ser predecidos a partir del análisis de grandes volúmenes de datos. Los resultados plasmados en el white paper "Predictive Analytics in Work Place Safety: Four Safety Truths that Reduce Workplace Injuries", indican que a partir del análisis de un conjunto de más de 112 millones de observaciones de seguridad y sus 15.000 incidentes/accidentes asociados a las mismas, es posible prever los incidentes/accidentes antes de que ocurran con altos niveles de precisión.

G. ETAPAS DEL DISEÑO DE LA INNOVACIÓN

Para ordenar y sistematizar la información relevante de este proyecto, se actualizó el plan de trabajo en conjunto con las partes interesadas y fue gestionado en la plataforma de Trello, la cual sirvió de guía en la interrelación de los recursos humanos, financieros, materiales y tecnológicos disponibles.

Planificación:

- Definición de situaciones apropiadas para la generación de un modelo de análisis computacional de imágenes.
- Desarrollo de un sistema de reconocimiento de patrones basado en métodos de visión computacional.

Implementación:

- Implementación de los métodos y compilación de los algoritmos de visión computacional en la unidad de procesamiento (hardware).
- Instalación del prototipo mínimo viable en las instalaciones del cliente.

Medición y Mejora:

- Establecer variables que podrán ser cuantificadas y tomadas en consideración según su nivel de factibilidad y relevancia en la toma de decisiones del proceso de seguridad de la empresa.
- Mejora correctivas que pudieran requerirse después de las pruebas y estudios de factibilidad.

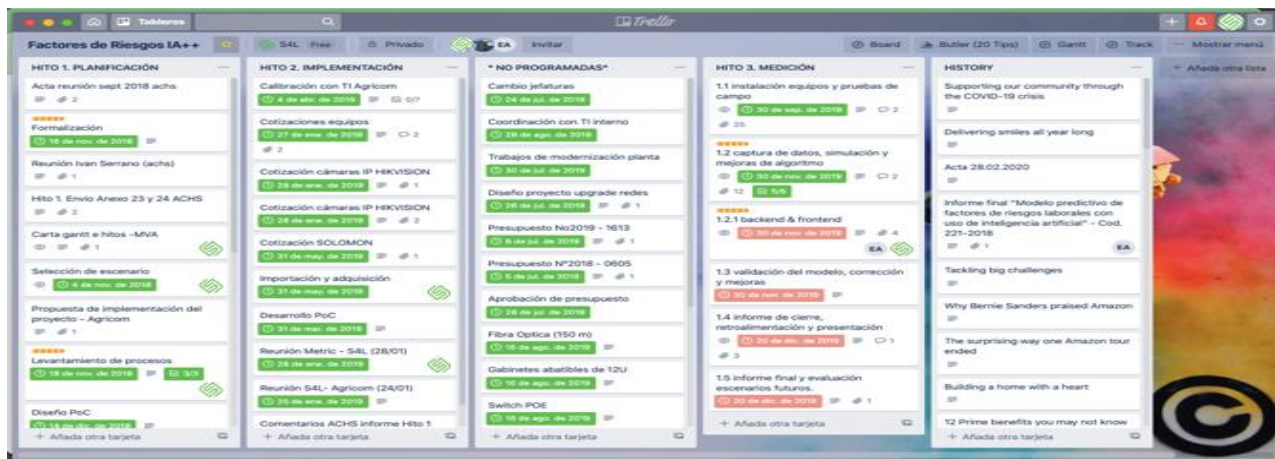


Ilustración 1. Plataforma de gestión del proyecto de innovación

H. DESARROLLO DE LA INNOVACIÓN

Esta prueba de concepto busca aportar en la cultura de seguridad laboral de las empresas con procesos productivos riesgosos, a través de la identificación de peligros y evaluación de los riesgos asociados de forma oportuna, para los cual implementaremos tecnologías en el procesamiento y análisis de las imágenes de videos capturadas en los procesos.

Planteamiento de los objetivos

Desarrollar un prototipo que permita tener capacidad predictiva y logre anticipar la ocurrencia de accidentes laborales de alto potencial en empresas con procesos productivos riesgosos, por medio de la captura y análisis de imágenes procesadas con inteligencia artificial (computer visión).

Marco Metodológico

Definición de Empresa usuaria del Piloto

Considerando los antecedentes levantados en la etapa de diseño, se realiza acuerdo de colaboración con la empresa Agrícola y Exportadora AGRICOM S. A. para ejecutar el piloto en sus instalaciones.

AGRICOM S. A. es una empresa productora y exportadora chilena de fruta fresca. Fue fundada en 1980 y posee más de 1.700 hectáreas de producción sustentable y 1.800 trabajadores. Son pioneros en la producción de paltas y cítricos utilizando tecnología de punta en sus plantas de embalaje.

AGRICOM S.A. posee actualmente 2 plantas de procesamiento certificadas con Buenas Prácticas de Manufactura (BPM) y realizan trabajos con productores para la obtener la certificaciones EUREP-GAP, Naturés Choice y NutriClean® .

AGRICOM S.A. posee un departamento de prevención de riesgos corporativo, responsable de planificar, organizar, asesorar, ejecutar, supervisar y promover acciones permanentes para evitar accidentes del trabajo y enfermedades profesionales en los trabajadores.

En conjunto con el departamento de Prevención de Riesgos se analizó las áreas factibles de implementación del Piloto y se determinó el almacenamiento y despacho de la Planta Polpaico, ya que concentraba el mayor número de tareas críticas de la Empresa.

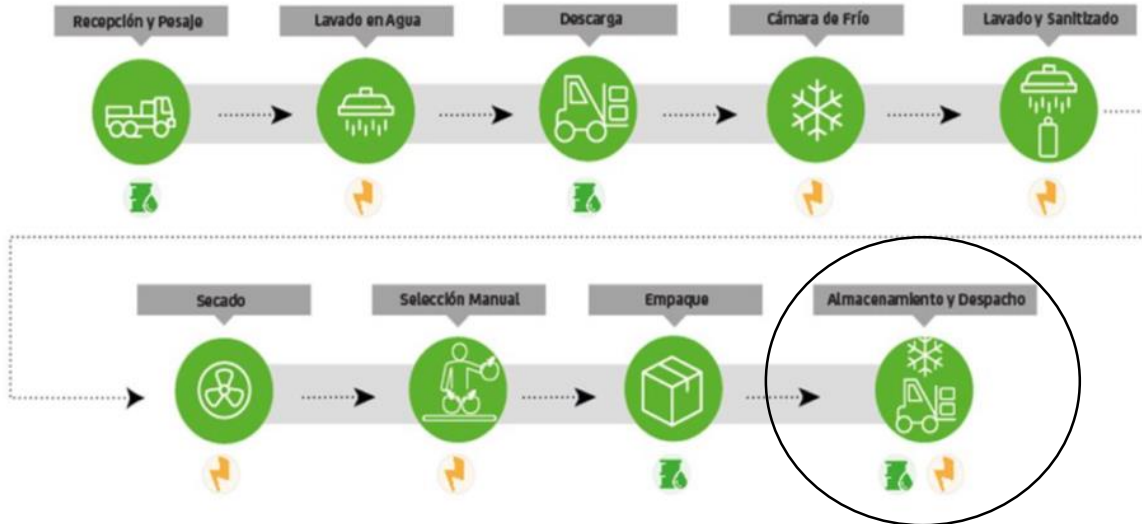


Ilustración 2. Proceso productivo planta Polpaico y área seleccionada



Fotografía 1. Área de almacenamiento y despacho (frío). Planta Polpaico



Fotografía 4. Operación de grúa horquilla. Planta Polpaico



Fotografía 5. Pallets en zona de despacho. Planta Polpaico



Fotografía 6. Vista general de área en estudio. Planta Polpaico

Determinación de Factores de Riesgos


En base al análisis estadístico de accidentes realizado en conjunto con el área de Prevención de Riesgos de Agricom, se determinan los Factores de Riesgos que podrían ocasionar incidentes de alto potencial.

Considerando la Norma ISO 45001, se utiliza la metodología de identificación de peligros y evaluación de riesgos como elemento central para la configuración del proyecto, es así que se opta por determinar los Factores de Riesgos Laborales que son determinantes para la ocurrencia de incidentes.

1. Tránsito de grúa por sobre línea peatonal.
2. Tránsito de traspaleta por sobre línea peatonal.
3. Pallet mal cargado sobre otro.
4. Pallet mal cargado (estiva inadecuada)
5. Pallet sobre paso peatonal
6. Pallet en área de tránsito de carga.
7. Persona sobre grúa
8. Persona sobre traspaleta

Los objetos se encuentran agrupadas en cinco clases distintas divididas en tres grupos: persona, vehículos e interior. Estos tres grupos se dividen en las siguientes clases:

- Persona: persona
- Vehículo: grua horquilla, transpaleta.
- Interior: pallet, paso peatonal.



Fotografía 7. Visita a terreno equipo Safety for Life

Materiales / Implementación

Se definen los recursos necesarios en cuanto a cámaras, sus características, infraestructura en áreas y equipo técnico para llevar a cabo el Piloto.

Equipos:

- 2 Hikvision CCTV Domo 2.0 MP IP66
- 4 Hikvision CCTV Bullet 2.0MP IP66
- Hikvision DVR 8T

- Netgear Prosafe 16 Puertos Gigabit Poe Router
- DD video vigilancia 8TB
- UTP CAT caja 305 MTS
- Transformador interior 12V
- Balun pasivo x2 ahd atornillable
- Conector DC macho 2PIN
- Conector DC Hembra 2 Pin
- Cable Ethernet (rj45)
- Maquinas Kaul AI
- Enchufe industrial

Conexiones y cableados:

- Provisión e instalación de Enlace F/UTP categoría 6ª con canalización metálica EMT
- Provisión e instalación de gabinete mural y puntos de red para 6 cámaras.
- Switch PH Aruba de 8 bocas 1920 10/100/1000.

Profesional Técnico:

- 2 ingenieros civiles telemático/informático/electrónico con experiencia en el área de Inteligencia Artificial y Deep Learning.
- 1 diseñador UX / UI
- 2 técnicos de redes para instalación de infraestructura, conexiones y cables.
- 1 encargado de la gestión del proyecto.

Instalación

Respecto a las cámaras y sus componente, se dispone el cableado, canalización e instalación de 6 cámaras para abarcar la totalidad de zonas de tránsito de grúas horquillas y traspaletas.




Ilustración 3. Layout de cámaras



Fotografía 8. Cableado



Fotografía 9. Instalación de cámaras



Fotografía 10. Configuración de cámaras



Fotografía 11. Pruebas de transmisión de datos

Pruebas y captura de imágenes

Para entrenar el modelo de detección de objetos se debe recopilar imágenes que contengan estos objetos en cantidad y la calidad suficiente para comenzar el proceso de entrenamiento. El riesgo de utilizar pocas imágenes es que el modelo aprenda conceptos que son solo ruido o irrelevantes, afectando negativamente la precisión.

Del mismo modo los datos deben estar equilibrados con respecto a la cantidad de imágenes de cada objeto en el proceso de entrenamiento, para que el modelo sea igual de bueno reconociendo uno u otro objetos. Se recomienda para obtener resultados coherentes, mantener al menos una relación 1:2 entre el objeto con menos imágenes y el que tiene más.

Otro aspecto a considerar es usar imágenes variadas y representativas de cada objeto, con la finalidad de asegurar de que el modelo sea imparcial y pueda generalizar correctamente.

Preprocesamiento para adaptación a la red neuronal

El entrenamiento del modelo considera la detección de objetos en imágenes las cuales fueron realizadas a través de YOLO 3 (You Only Look Once. Sólo miras una vez). La detección de objetos, consiste en localizar dentro de una imagen la posición de varios objetos indicando además la categoría a la que pertenecen dichos objetos. En otras palabras, detección incluye clasificación y las coordenadas de la localización de los objetos.




Ilustración 4. Detección de varios objetos con YOLO 3

YOLO utiliza deep learning y CNN (convolutional neural network) para detectar objetos, y se diferencia de las demás alternativas del mercado debido a su rapidez para identificarlos en tiempo real en videos (hasta 30 fps).

El modelo se implementó como una red neuronal convolucional. Las capas convolucionales iniciales de la red se encargan de la extracción de características de la imagen, mientras que las capas de conexión completa predicen la probabilidad de salida y las coordenadas del objeto. Estas redes, se construyen apilando una serie de capas, que van transformando la imagen de entrada través de una serie de filtros que aplican un operador de convolución, y cuyos valores podemos inicializar aleatoriamente. Estos valores serán los que se actualicen durante el proceso de aprendizaje.

La arquitectura del modelo YOLO está basado en una red convolucional inspirada en GoogleNet para la clasificación de imágenes. Dicha red fue entrenada inicialmente para resolver el problema de clasificación de ImageNet y luego fue adaptada para abordar problemas de detección.



Ilustración 6. Diagrama de funcionamiento Amazon MTurk

De esta forma, por cada cámara (6) se ingresan las imágenes en Mturk y se configuran las variables para el etiquetado de detección de objetos: personas, grúa horquilla, traspaleta y pallet.

Name	Size	Type	Modified
Canal01	1.248 items	Folder	dic 3 2019
Canal02	1.018 items	Folder	dic 3 2019
Canal03	2.458 items	Folder	dic 3 2019
Canal04	1.626 items	Folder	dic 3 2019
Canal05	1.098 items	Folder	dic 3 2019
Canal06	2.266 items	Folder	dic 3 2019
csv	26 items	Folder	dic 9 2019

Ilustración 7. Imágenes cargadas en Amazon Mechanical Turk

Draw bounding boxes around the requested items

Labels ×

- Forklift 1
- Palletload 2
- Pallettruck 3
- Person 4

Box
Delete
Undo
Redo
Zoom in
Zoom out
Move
Fit image

Nothing to label Submit

Ilustración 8. Etiquetado

Los servicios de Amazon MTurk proceden al etiquetado a través de una fuerza laboral distribuida que puede realizar estas tareas virtualmente (Human Intelligence Tasks, HIT)

The screenshot shows the 'Manage Batches' interface in the Amazon MTurk console. It displays three batches, each with a progress bar indicating 100% completion. The batches are:

- Bounding Box Industry Elements 22:** Created December 04, 2019, 4 days elapsed, 500/500 assignments completed, estimated completion time COMPLETE.
- Bounding Box Industry Elements 21:** Created December 04, 2019, 4 days elapsed, 518/518 assignments completed, estimated completion time COMPLETE.
- Bounding Box Industry Elements 20:** Created December 04, 2019, 4 days elapsed, 607/607 assignments completed, estimated completion time COMPLETE.

Ilustración 9. Requerimientos de etiquetado completados.

Una vez realizado el proceso de etiquetado se realiza un proceso de aprobación de las tareas de etiquetas realizados con inteligencia humana (HIT). La aprobación de los HIT se realizó de forma semi manual, a través de un script que permitió garantizar la calidad de etiquetado.

The screenshot shows the 'Review Results' page for a batch of 'Bounding Box Industry Elements 13'. It features a table of results with columns for Worker ID, Lifetime Approval Rate, Input Image Url, Annotated Result Bounding Boxes, and Annotated Result Input Image Properties (Height and Width). A red box highlights the 'Approve' and 'Reject' buttons for each row.

	Worker ID	Lifetime Approval Rate	Input Image Url	Annotated Result Bounding Boxes	Annotated Result Input Image Properties.Height	Annotated Result Input Image Properties.Width
<input type="checkbox"/> Approve <input type="checkbox"/> Reject	A33C5KMSHFAW1X	100% (9/9)	https://dataframes.blob.core.windows.net/f1cana...	[[{"height":158,"label":"Person","left":104,"top"...	720	1280
	A1DY7SWOKFSIY1	100% (25/25)	https://dataframes.blob.core.windows.net/f1cana...	[[{"height":129,"label":"Person","left":153,"top"...	720	1280
	A0B25WRNFGUFE	100% (90/90)	https://dataframes.blob.core.windows.net/f1cana...	[[{"height":127,"label":"Person","left":528,"top"...	720	1280
	A221PKDKHD7UDN	100% (141/141)	https://dataframes.blob.core.windows.net/f1cana...	[[{"height":36,"label":"Forklift","left":453,"to...	720	1280
	A7L22YAP07QQ6	100% (100/100)	https://dataframes.blob.core.windows.net/f1cana...	[[{"height":105,"label":"Person","left":597,"top"...	720	1280
	A0UV3OYNCS9PL	100% (14/14)	https://dataframes.blob.core.windows.net/f1cana...	[[{"height":88,"label":"Person","left":542,"top"...	720	1280
	A1P9GEHDQQA087	100% (8/8)	https://dataframes.blob.core.windows.net/f1cana...	[[{"height":172,"label":"Forklift","left":385,"l...	720	1280
	A2A5TPFU0S36V	100% (7/7)	https://dataframes.blob.core.windows.net/f1cana...	[[{"height":213,"label":"Person","left":77,"top"...	720	1280
	A1DY7SWOKFSIY1	100% (25/25)	https://dataframes.blob.core.windows.net...		720	1280

Ilustración 10. Control de calidad del proceso de etiquetado

```

@kueal:/media/kueal/Data/Agricom/YOLOV3_TensorFlow
768 | 1 global_step: 500 | loss: total: 15.19, xy: 1.37, wh: 1.55, conf: 7.55, class: 4.71 | Last batch: rec: 0.855, prec: 0.007 | lr: 5.8685e-05 | 216/284 [00:33:00:10, 6.01t/s]Ep
100% | 1 global_step: 600 | loss: total: 9.82, xy: 1.03, wh: 1.16, conf: 4.78, class: 2.85 | Last batch: rec: 0.882, prec: 0.006 | lr: 7.0423e-05 | 284/284 [00:43:00:00, 6.58t/s]Ep
11% | 2 global_step: 700 | loss: total: 9.70, xy: 1.04, wh: 1.14, conf: 4.78, class: 2.74 | Last batch: rec: 0.915, prec: 0.013 | lr: 8.216e-05 | 32/284 [00:05:00:38, 6.00t/s]Ep
och: 1 | 2 global_step: 800 | loss: total: 9.36, xy: 1.02, wh: 1.21, conf: 4.03, class: 2.49 | Last batch: rec: 0.919, prec: 0.011 | lr: 9.3897e-05 | 132/284 [00:20:00:23, 6.57t/s]Ep
och: 2 | 3 global_step: 900 | loss: total: 7.01, xy: 0.88, wh: 0.95, conf: 4.03, class: 1.75 | Last batch: rec: 0.873, prec: 0.010 | lr: 0.0001 | 232/284 [00:35:00:07, 6.01t/s]Ep
och: 3 | 4 global_step: 1000 | loss: total: 7.51, xy: 0.88, wh: 0.99, conf: 3.97, class: 1.67 | Last batch: rec: 0.986, prec: 0.010 | lr: 0.0001 | 284/284 [00:43:00:00, 6.48t/s]Ep
och: 4 | 5 global_step: 1100 | loss: total: 7.09, xy: 0.82, wh: 0.93, conf: 3.79, class: 1.54 | Last batch: rec: 0.986, prec: 0.007 | lr: 0.0001 | 48/284 [00:07:00:35, 6.02t/s]Ep
och: 5 | 6 global_step: 1200 | loss: total: 6.23, xy: 0.75, wh: 0.79, conf: 3.43, class: 1.25 | Last batch: rec: 1.000, prec: 0.009 | lr: 0.0001 | 148/284 [00:22:00:20, 6.59t/s]Ep
och: 6 | 7 global_step: 1300 | loss: total: 6.13, xy: 0.72, wh: 0.77, conf: 3.39, class: 1.25 | Last batch: rec: 0.970, prec: 0.013 | lr: 0.0001 | 248/284 [00:38:00:05, 6.58t/s]Ep
och: 7 | 8 global_step: 1400 | loss: total: 6.05, xy: 0.70, wh: 0.76, conf: 3.40, class: 1.20 | Last batch: rec: 0.986, prec: 0.010 | lr: 0.0001 | 284/284 [00:43:00:00, 6.49t/s]Ep
100% | 9 global_step: 1500 | loss: total: 5.54, xy: 0.66, wh: 0.67, conf: 3.17, class: 1.05 | Last batch: rec: 0.966, prec: 0.012 | lr: 0.0001 | 64/284 [00:10:00:33, 6.00t/s]Ep
och: 10 | 1600 | loss: total: 5.43, xy: 0.62, wh: 0.66, conf: 3.13, class: 1.02 | Last batch: rec: 1.000, prec: 0.010 | lr: 0.0001 | 164/284 [00:25:00:18, 6.56t/s]Ep
och: 11 | 1700 | loss: total: 5.05, xy: 0.58, wh: 0.57, conf: 2.96, class: 0.94 | Last batch: rec: 0.987, prec: 0.011 | lr: 0.0001 | 284/284 [00:43:00:00, 6.47t/s]Ep
och: 12 | 1800 | loss: total: 5.02, xy: 0.57, wh: 0.57, conf: 2.96, class: 0.93 | Last batch: rec: 0.984, prec: 0.009 | lr: 0.0001 | 751/751 [00:15:00:00, 47.55t/s]Ep
===== Epoch: 4, global_step: 1419.0, lr: 0.0001 =====
EVAL: Class 0: Recall: 0.1387, Precision: 0.0016, AP: 0.0000
EVAL: Class 1: Recall: 0.7709, Precision: 0.0030, AP: 0.6003
EVAL: Class 2: Recall: 0.0031, Precision: 0.0006, AP: 0.0065
EVAL: Class 3: Recall: 0.1032, Precision: 0.0001, AP: 0.0243
EVAL: Recall: 0.2921, Precision: 0.0014, mAP: 0.1593
EVAL: loss: total: 5.84, xy: 0.57, wh: 0.67, conf: 2.00, class: 1.00
28% | 5 global_step: 1500 | loss: total: 5.54, xy: 0.66, wh: 0.67, conf: 3.17, class: 1.05 | Last batch: rec: 0.966, prec: 0.012 | lr: 0.0001 | 80/284 [00:12:00:30, 6.01t/s]Ep
och: 6 | 1600 | loss: total: 5.50, xy: 0.63, wh: 0.67, conf: 3.17, class: 1.03 | Last batch: rec: 0.904, prec: 0.009 | lr: 0.0001 | 100/284 [00:20:00:15, 6.58t/s]Ep
och: 7 | 1700 | loss: total: 5.43, xy: 0.62, wh: 0.66, conf: 3.13, class: 1.02 | Last batch: rec: 1.000, prec: 0.010 | lr: 0.0001 | 199/284 [00:43:00:00, 6.36t/s]Ep
och: 8 | 1800 | loss: total: 5.05, xy: 0.58, wh: 0.57, conf: 2.96, class: 0.94 | Last batch: rec: 0.987, prec: 0.011 | lr: 0.0001 | 284/284 [00:44:00:00, 6.42t/s]Ep
och: 9 | 1900 | loss: total: 5.02, xy: 0.57, wh: 0.57, conf: 2.96, class: 0.93 | Last batch: rec: 0.984, prec: 0.009 | lr: 0.0001 | 96/284 [00:15:00:20, 6.59t/s]Ep
och: 10 | 2000 | loss: total: 4.53, xy: 0.51, wh: 0.53, conf: 2.63, class: 0.87 | Last batch: rec: 0.988, prec: 0.012 | lr: 0.0001 | 196/284 [00:30:00:13, 6.57t/s]Ep
och: 11 | 2100 | loss: total: 4.57, xy: 0.53, wh: 0.52, conf: 2.67, class: 0.84 | Last batch: rec: 0.987, prec: 0.011 | lr: 0.0001 | 284/284 [00:43:00:00, 6.47t/s]Ep
100% | 75% | 2100 | loss: total: 4.57, xy: 0.53, wh: 0.52, conf: 2.67, class: 0.84 | Last batch: rec: 0.987, prec: 0.011 | lr: 0.0001 | 751/751 [00:14:00:00, 52.72t/s]Ep
===== Epoch: 6, global_step: 1987.0, lr: 0.0001 =====
EVAL: Class 0: Recall: 0.1334, Precision: 0.0016, AP: 0.0002
EVAL: Class 1: Recall: 0.7950, Precision: 0.0031, AP: 0.5801
EVAL: Class 2: Recall: 0.0097, Precision: 0.0005, AP: 0.0031
EVAL: Class 3: Recall: 0.1190, Precision: 0.0001, AP: 0.0230
EVAL: Recall: 0.1970, Precision: 0.0013, mAP: 0.1551
EVAL: loss: total: 4.69, xy: 0.50, wh: 0.69, conf: 2.65, class: 0.85
4% | 7 global_step: 2000 | loss: total: 4.53, xy: 0.51, wh: 0.53, conf: 2.63, class: 0.87 | Last batch: rec: 0.988, prec: 0.012 | lr: 0.0001 | 12/284 [00:02:00:44, 6.15t/s]Ep
och: 8 | 2100 | loss: total: 4.57, xy: 0.53, wh: 0.52, conf: 2.67, class: 0.84 | Last batch: rec: 0.987, prec: 0.011 | lr: 0.0001 | 112/284 [00:17:00:26, 6.59t/s]Ep
och: 9 | 2200 | loss: total: 4.57, xy: 0.53, wh: 0.52, conf: 2.67, class: 0.84 | Last batch: rec: 0.987, prec: 0.011 | lr: 0.0001 | 212/284 [00:32:00:10, 6.56t/s]Ep

```

Ilustración 11. Script proceso de aprobación etiquetado



Ilustración 12. Imagen etiquetada

Para realizar el preprocesamiento para adaptación a la red neuronal, se realizó un entrenamiento a la máquina de IA ingresando las imágenes etiquetadas en un script programado en python. De acuerdo al número de vectores cargados, la máquina de IA entrega un % de probabilidad de detección por cada objeto, lo que permite el ajuste de variables con el objetivo de aumentar el grado de precisión.

Como en cualquier modelo de aprendizaje automático, fue muy importante descomponer el conjunto de datos en dos subconjuntos de forma aleatoria (data split):

- El 80% de las imágenes se usa para entrenamiento.
- El 20% de las imágenes se usa para evaluar el modelo. Estas imágenes no se usan en el entrenamiento.

La evaluación del proceso se realizó pasando las imágenes de test por la red, para obtener los resultados de detección obtenidos por la red y compararlos con los de la realidad. La finalidad de este proceso nos permitirá extraer información acerca del comportamiento del modelo y datos relacionados con el rendimiento, lo que nos permite clasificarlo como aceptable o no. En este caso el mAP (mean Average Precision) fue del 83,48%.

Postprocesamiento y predicción

La próxima etapa consistió en probar nuestro modelo con imágenes que no se encuentran ni en el conjunto de entrenamiento ni en el test. Vemos que el modelo ha detectado correctamente los diversos objetos de las imágenes capturadas por las cámaras de video.




Ilustración 13. Antecámara sur



Ilustración 14. Ante cámara costa



Ilustración 15. Pre frío Norte



Ilustración 16. Pre frío sur

Visualización de Factores de riesgos.

Después de procesar las imágenes se entrena un modelo capaz de detectar y clasificar los objetos dentro de una imagen. Este proceso resulta relevante, ya que la máquina de AI procesa cada imagen etiquetada, pero para lograr la interpretación de estos datos, es necesario complementar el proceso con la programación de cada factor de riesgo que luego será almacenado y puesto a disposición del usuario a través de la plataforma web.

En el caso de la plataforma web se definió un modelo de visualización que permitiera:

- Demostración gráfica de los Factores de Riesgos
- Descarga de datos para su análisis (fecha, hora, id cámara, area, factor de riesgo, duración)
- Aplicación de filtros por fecha, horas, factores de Riesgos y otros

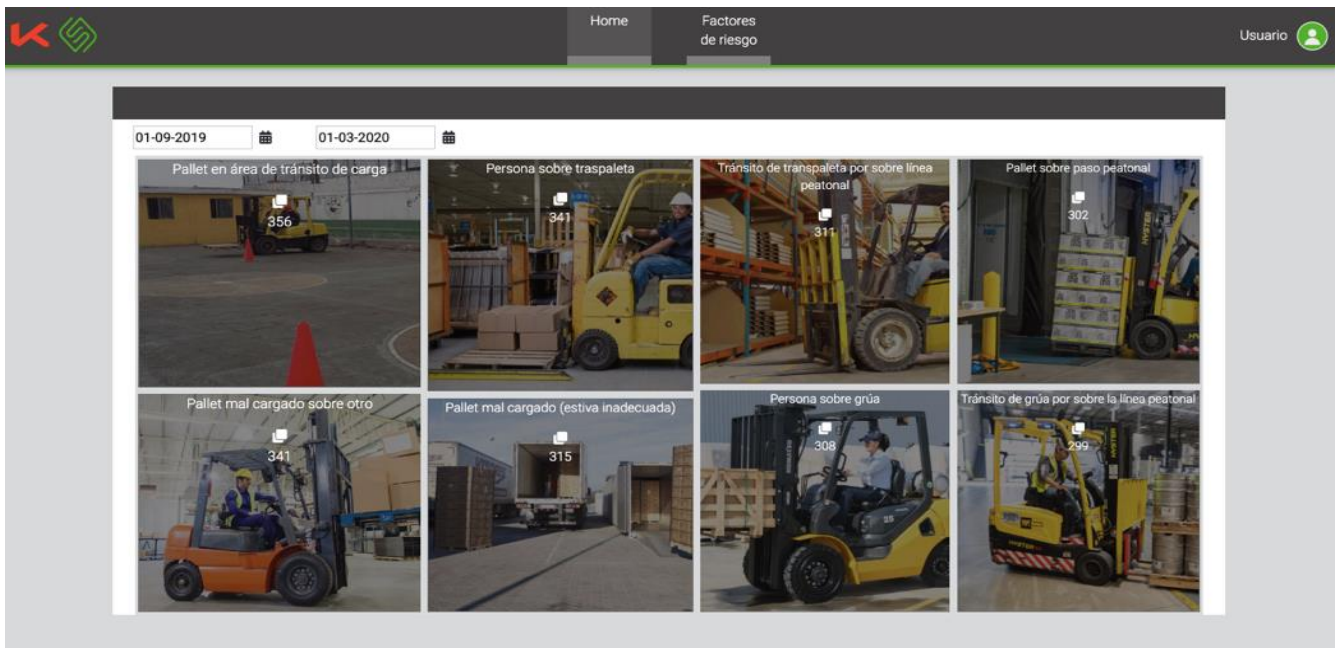


Ilustración 17. Vista de factores de riesgos identificados

N°	Factor de riesgo	Fecha	Hora	Duración [min]	Área	Color de uniforme asociado	N° Personas en el área
5	Pallet sobre paso peatonal	2020-01-15	15:01:11	10	Nombre o sigla del área	Nombre o sigla del color	8
8	Persona sobre traspaleta	2020-01-15	13:00:04	4	Nombre o sigla del área	Nombre o sigla del color	6
5	Pallet sobre paso peatonal	2020-01-15	11:02:39	1	Nombre o sigla del área	Nombre o sigla del color	10
2	Tránsito de traspaleta por sobre línea peatonal	2020-01-15	09:39:27	1	Nombre o sigla del área	Nombre o sigla del color	2
4	Pallet mal cargado (estiva inadecuada)	2020-01-15	07:24:16	1	Nombre o sigla del área	Nombre o sigla del color	1
8	Persona sobre traspaleta	2020-01-15	07:07:20	7	Nombre o sigla del área	Nombre o sigla del color	2
6	Pallet en área de tránsito de carga	2020-01-15	06:11:06	2	Nombre o sigla del área	Nombre o sigla del color	6

Ilustración 18. Vista de base de datos en Plataforma web

I. RESULTADOS

- Se logra implementar con éxito el piloto, identificado diversos factores de riesgos laborales reconocidos a través de un modelo de red convolucional que procesan las imágenes capturadas por cámaras de video.
- Se procesaron más de 10 mil imágenes desde 6 cámaras instaladas en 2 áreas productivas, las cuales fueron agrupadas en cinco clases: personas, grúa horquilla, transpaleta, pallet y paso peatonal.
- Se desarrolla una plataforma con elementos de back y front end que recoge los datos de la máquina de AI dispuesta de manera offline debido al bajo nivel de conectividad disponible en el sector de Polpaico. La empresa exportará informes consolidados semanalmente para la definición de planes de acción personalizados según las brechas detectadas en cada área.
- Algunos de los beneficios de sustituir las actividades rutinarias de inspección y control ejecutados manualmente por los supervisores por los de una máquina de AI, se traducen en reducción de sesgos y criterios en la evaluación, así como ahorro en la captura, consolidación y visualización de los datos recolectados. De esta forma los encargados de area enfocarían sus esfuerzos en interpretar y analizar la data consolidada, para tomar decisiones operacionales informadas.
- Respecto a los entregables del proyecto, se considera una plataforma web con gráficas, tablas y datos exportables en pdf y excel.

J. CONCLUSIONES

- Se utilizó YOLO para la identificación de factores de riesgos laborales ya que es una de las técnicas más populares para la detección de objetos en imágenes en la actualidad, permitiendo la construcción de modelos precisos que podrían implementarse en tiempo real. Sin embargo, una de las desventajas experimentadas fue su dificultosa curva de aprendizaje.
- El beneficio de utilizar el aprendizaje automático es que la identificación de objetos en una imagen puede llegar a ser mucho más efectiva que un humano, disminuyendo errores de sesgo, detectar situaciones anómalas, automatizar rutinas o tareas mecánicas que no aportan valor e incluso podría descubrir situaciones que hemos mantenido de forma subestánderes en el tiempo tales como pasillos obstruidos, pallet mal estibados, cruces peatonales riesgosos, etc.
- Es muy recomendable invertir previamente en un diseño adecuado de los factores de riesgos laborales para optimizar el proceso de etiquetado de imágenes. El primero, porque debe ajustarse a las capacidad de procesamiento de la máquina AI, ya que no es igual detectar objetos que distancias, altura o combinación de dos o más variables; y el segundo pues para ajustar el nivel de precisión del procesamiento de la máquina de AI se requiere un alto número de capturas, recogidas por las cámaras, que muestren la ocurrencia de cada factor de riesgo. Por lo tanto, como en cualquier problema de machine learning una de las primeras dificultades es obtener el set de datos, o crearlo por nuestra cuenta.
- Los servicios de Amazon MTurk a través de una fuerza laboral distribuida permiten ahorrar costos y eficiencia en las tareas de etiquetado de imágenes.
- Los resultados mostraron que la captura de imágenes permite un buen reconocimiento y detección de los factores de riesgos. Por las características del proceso en cuestión hay que supervisar constantemente el campo de grabación de las cámaras, ya que podrían ser obstaculizadas con almacenamiento inadecuado de pallets, materiales en él área, superposición de objetos o almacenamiento en altura.

- Con los datos obtenidos, es factible establecer mejoras a corto y largo plazo en los modelos de gestión de seguridad y salud de las empresas, logrando establecer planes de acción personalizados según los hallazgos levantados.
- Dado que el aprendizaje automático y la IA son disciplinas particularmente conemporáneas y que están estrechamente relacionadas con el desarrollo de la tecnología, muchas aplicaciones aún están en curso, por lo cual será factible replicar el piloto considerando los aprendizajes adquiridos.
- La validación técnica desarrollada en este proyecto de innovación, permitirá realizar una transferencia de los conocimientos adquiridos respecto de la metodología aplicada así como las herramientas utilizadas en el proceso.

K. REFERENCIAS

- International Social Security Association – 2019 - issa.int
- Estrategia LGF de la Asociación Chilena de Seguridad – 2019 - estrategialgf.achs.cl
- Partnering with the NFL to transform player health and safety - 2019 - blog.amazon.com
- Can predictive analytics help reduce workplace risk. G Wagner - NIOSH Science Blog, 2014
- Predictive analytics in workplace safety: Four “safety truths” that reduce work-place injuries
P Solutions - Oakdale, PA USA, 2012
- Ye, X. W., Jin, T., & Ang, P. P. (2020). Computer Vision-Based Monitoring of Ship Navigation for Bridge Collision Risk Assessment. In *Machine Vision and Navigation* (pp. 787-807).
- T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár. Focal loss for dense object detection. arXiv preprint [arXiv:1708.02002](https://arxiv.org/abs/1708.02002), 2017.
- González, Fernando González, & Luis Alberto Espejo Ponce. "Sistema para la detección y clasificación de fauna mediante visión por computadora" *Pistas Educativas* 41.133 (2019)
- Video Analytics for Visual Surveillance and Applications: An Overview and Survey. IE Olatunji, CH Cheng - *Machine Learning Paradigms*, 2019.
- Investigation of a Promoted You Only Look Once Algorithm and Its Application in Traffic Flow Monitoring. CY Cao, JC Zheng, YQ Huang, J Liu, CF Yang - *Applied Sciences*, 2019
- Safety assessment in megaprojects using artificial intelligence. BU Ayhan, OB Tokdemir - *Safety science*, 2019 – Elsevier
- Artificial Intelligence in Aviation Safety Applications-Exploring Myths and Truths of AI and ML. S Reeves, BL Matthews, S Chen - 2019 - ntrs.nasa.gov