

Quantum Learning Transfer Model for the classification of people with safety helmets

Jose Sulla-Torres, Dr¹, Jorge Martínez Muñoz, Mg¹, César Castillo Cáceres, Dr¹ and Abraham Pacheco Oviedo, Dr¹

¹Universidad Católica de Santa María, Arequipa, Perú,

jsullato@ucsm.edu.pe, jmartinez@ucsm.edu.pe, ccastill@ucsm.edu.pe, aapacheco.edo@ucsm.edu.pe

Abstract— The problem of personal accidents in a work environment in many cases is due to the lack of use of helmets, among other safety elements. The objective of this work was to classify images of people who use or not use safety helmets, in the classes identified as correct use of the helmet, incorrect use and without a safety helmet, with a Quantum Transfer Learning model. For this, the method used has allowed the collection of a data set of 750 images of people in different work activities. The classical learning transfer model chosen was ResNet-18; the variational layers of the proposed model were built with the Basic Entangler Layers template for four qubits with the Pennylane quantum simulator. The results were 95.47% accurate in classifying the correct Safety Helmets. The conclusion reached is that the proposed model is a good option to detect and classify people with the use of safety helmets in a work environment.

Keywords— Classification, safety helmet, Quantum Transfer Learning, Machine Learning.

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

Modelo de Transferencia de Aprendizaje Cuántico para la clasificación de personas con cascos de seguridad

Jose Sullato-Torres, Dr¹, Jorge Martínez Muñoz, Mg¹, César Castillo Cáceres, Dr¹ and Abraham Pacheco Oviedo, Dr¹
¹Universidad Católica de Santa María, Arequipa, Perú,
jsullato@ucsm.edu.pe, jmartinez@ucsm.edu.pe, ccastill@ucsm.edu.pe, aapacheco.edo@ucsm.edu.pe

Resumen— *El problema de accidentes personales en un entorno laboral en muchos casos se debe a la falta de uso de cascos, entre otros elementos de seguridad. El objetivo de este trabajo fue clasificar imágenes de personas que utilizan o no cascos de seguridad, en las clases identificadas como uso correcto del casco, uso incorrecto y sin casco de seguridad, con un modelo de Quantum Transfer Learning. Para ello, el método utilizado ha permitido recoger un conjunto de datos de 750 imágenes de personas en diferentes actividades laborales. El modelo clásico de transferencia de aprendizaje elegido fue ResNet-18; las capas variacionales del modelo propuesto se construyeron con la plantilla Basic Entangler Layers para cuatro qubits con el simulador cuántico PennyLane. Los resultados fueron que el 95.47% de precisión en la clasificación de las Cascos de seguridad correctas. La conclusión a la que se llegó es que el modelo propuesto es una buena opción para detectar y clasificar a las personas con el uso de cascos de seguridad en un entorno laboral.*

Palabras Clave— *Clasificación, casco de seguridad, Quantum Transfer Learning, Aprendizaje Automático.*

I. INTRODUCCIÓN

Según la Organización Internacional del Trabajo OIT [1], casi 2 millones de muertes por año ocurren a causa de accidentes laborales. En la gestión de la seguridad en un lugar de trabajo, es esencial supervisar el estado de uso del equipo de protección de seguridad de los trabajadores y el recordatorio a tiempo de la falta de uso de un casco de seguridad que son de particular importancia para evitar accidentes laborales. En las últimas décadas, el aumento de los accidentes centros laborales industriales ha llamado la atención sobre el monitor de seguridad. Con el fin de mejorar este problema, se han desarrollado cada vez más sistemas de vigilancia inteligentes basados en visión artificial o procesamiento de imágenes [2]. Esta medida no solo puede abordar el problema del monitor laboral, sino también resaltar la operación insegura para evitar accidentes inesperados.

Además, cabe señalar que para la Organización Mundial de la salud señala que la primera causa de muerte es el cáncer, seguido de los accidentes laborales, por lo que es importante la prevención respecto a minimizar estos problemas. Una de las

formas es contar con el equipamiento de seguridad, entre ellos el casco personal.

En ese sentido es importante la detección de cascos de seguridad, considerando el uso de imágenes surge ciertos problemas como la interoclusión, las variaciones de escala, la distorsión de la perspectiva, la detección de objetos pequeños y el reconocimiento del portador del casco de seguridad.

La detección de cascos de seguridad se puede realizar básicamente de tres formas, detección basada en sensores RFID [3], detección basada en aprendizaje automático [4] y detección basada en aprendizaje profundo.

Diversas técnicas de inteligencia artificial se han utilizado para la detección de cascos de seguridad en el campo laboral como el uso de aprendizaje profundo [5] con el uso de redes neuronales convolucionales, así como equipos de protección personal [6]. Se han utilizado técnicas de Transferencia de Aprendizaje cuántico para la clasificación de imágenes [7].

En este contexto, se presenta esta propuesta de clasificación de cascos de seguridad en un entorno laboral mediante un modelo de *Quantum Transfer Learning* con un modelo clásico de transferencia de aprendizaje Res-Net18 que permita realizar el trabajo de clasificación.

El documento está organizado de la siguiente manera: Se ha presentado la Introducción en el Capítulo I, en el Capítulo II se presenta el Estado del Arte, luego en el Capítulo III se muestra los Materiales y Métodos utilizados en el trabajo, a continuación, en el Capítulo IV se presentan las Pruebas y Resultados obtenidos y finalmente se presenta las conclusiones a las se ha llegado en la investigación.

II. ESTADO DEL ARTE

A continuación, se presenta los estudios relacionados a la materia de la propuesta.

Li et al [2], presentan un estudio sobre la detección de uso de casco de seguridad en una subestación eléctrica. Este artículo propuso un método de detección de uso de casco de seguridad innovador y práctico basado en el procesamiento de imágenes y el aprendizaje automático. Utiliza el algoritmo de modelado de fondo ViBe para detectar objetos en movimiento con una cámara de vigilancia. Después de obtener la región de movimiento de interés, se extrae la función Histogram of Oriented Gradient (HOG), luego, en función del resultado de la

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

extracción de características de HOG, la máquina de vectores de soporte (SVM) se entrena para clasificar a los peatones. Finalmente, la detección del casco de seguridad se implementó mediante el reconocimiento de características de color. Los resultados experimentales demostraron la corrección y eficacia del método propuesto. En la Fig. 1 se muestra el framework de detección de uso de cascos de seguridad utilizado en la investigación.

En el trabajo de Li et al. [5], utiliza el algoritmo SSD-MobileNet que se basa en redes neuronales convolucionales. Utilizaron un conjunto de datos de 3261 imágenes de cascos de seguridad recopilados de dos fuentes, de captura manual del sistema de monitoreo de video en el lugar de trabajo e imágenes abiertas obtenidas mediante tecnología de rastreo web. El conjunto de imágenes se divide en un conjunto de entrenamiento, conjunto de validación y conjunto de prueba, con una relación de muestreo de casi 8:1:1. Los resultados del experimento demuestran que el modelo basado en el aprendizaje profundo presentado que utiliza el algoritmo SSD-MobileNet es capaz de detectar la operación insegura de la falla del uso de un casco en el sitio de construcción, con precisión y eficiencia satisfactorias.

Reyes et al. [8] desarrollaron un marco para reconocer el cumplimiento de la seguridad del personal de construcción con el equipamiento de protección personal, que está diseñado para implementarse en el procedimiento operativo de una organización. Construyeron un modelo de red neuronal convolucional empleando el aprendizaje automático en una versión básica del modelo de aprendizaje profundo YOLOv3 para el estudio. En los datos de prueba, el método de detección generó una puntuación F1 de 0,9299.

En el trabajo de Gong et al. [9], proponen un método para detectar trabajadores en el sitio y obtiene el cuadro delimitador de personal. El resultado de la detección de candidatos se utiliza como entrada del reconocimiento de gestos para detectar puntos clave del cuerpo humano. En función de los puntos clave detectados, el área de interés (área de la cabeza y área del uniforme de la ropa de trabajo) se ubica en función de las relaciones espaciales entre los puntos clave del cuerpo humano. Los cascos de seguridad se reconocen mediante el aprendizaje de transferencia profundo basado en ResNet50 mejorado, de acuerdo con la simetría entre los cascos y los uniformes de ropa de trabajo, el mismo método se utiliza para reconocer los uniformes de ropa de trabajo para realizar la identificación del equipo de protección. Las precisiones de detección del método propuesto para cascos y uniformes de trabajo son del 94,8 % y 95,4 %, respectivamente.

En el artículo de Sharada et al. [10], utilizan un detector de objetos Yolov3 en tiempo real para entrenar al modelo para que reconozca máscaras faciales y cascos en filmaciones de video, transmisiones en vivo o fotos para buscar higiene y seguridad

públicas. Esto se hace para garantizar que las personas no estén expuestas a condiciones potencialmente peligrosas. Ellos utilizaron una red neuronal para la predicción de cuadros delimitadores y las posibilidades asociadas con esos cuadros en toda la imagen. Tanto la exactitud como la precisión son bastante buenas en los resultados que se lograron.

En el Trabajo de Abib y Kiefer [11], utilizan el aprendizaje de transferencia con diferentes enfoques de canalización de preprocesamiento como un medio de amplificación y aumento de datos para mejorar un pequeño conjunto de datos mediante una combinación de las siguientes transformaciones: rotación, escalado, volteo y conversión de escala de grises. Se entrena un modelo de detección de cascos de seguridad en la construcción utilizando varias canalizaciones de preprocesamiento de datos experimentales.

Han et al. [12], proponen un método basado en el aprendizaje profundo para detectar el uso de cascos de seguridad con una precisión satisfactoria y una alta velocidad de detección. El método que usaron fue YOLO v5 como línea de base, luego agregaron una cuarta escala de detección para predecir más cuadros delimitadores para objetos pequeños y se adoptaron mecanismo de atención en la columna vertebral de la red para construir características más informativas para las siguientes operaciones de concatenación. Lograron una precisión promedio del 92,2 %, y solo se necesitan 3,0 ms para detectar una imagen a 640×640 .

Shen et al. [13] proponen una nueva metodología para detectar el uso de cascos de seguridad, que utiliza la detección de rostros basada en redes neuronales convolucionales y la regresión de cuadro delimitador. El método puede ayudar a reconocer al portador del casco de seguridad y detectar un casco de seguridad multiescala y pequeño. Por otro lado, el aprendizaje de transferencia profundo basado en DenseNet lo utiliza como extractor de características de objetos y el ajuste fino para el reconocimiento de cascos de seguridad. Para mejorar aún más la precisión del reconocimiento, el modelo de red con dos redes DenseNet pares se entrena mediante destilación mutua. Los resultados logrados han alcanzado una precisión de detección promedio del 94,47 %. Estos resultados, la curva de recuperación de precisión (PR) y la curva característica operativa del receptor (ROC) demuestran la viabilidad del nuevo modelo.

III. MATERIALES Y MÉTODOS

La metodología utilizada fue la del KDD (Knowledge Discovery in Databases). KDD es el proceso de encontrar información útil y patrones dentro de los datos [14]. El KDD está compuesto de 5 fases que se muestran a continuación en la Fig. 1.

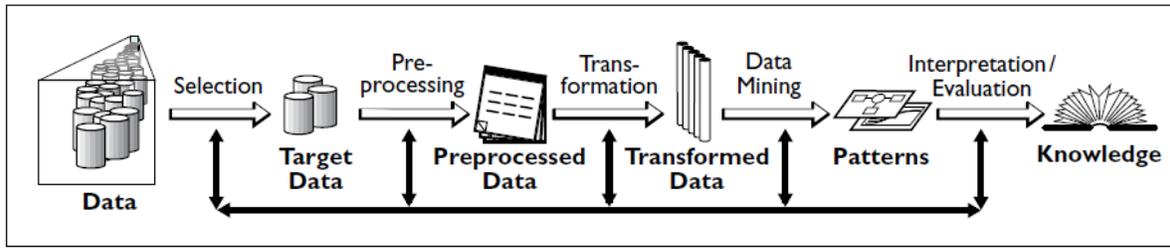


Fig. 1 Descripción general de los pasos que constituyen el proceso KDD [14].

A. Datos

Para el desarrollo del aprendizaje automático, se utilizó un conjunto de datos de cascos de seguridad proporcionado por el repositorio de *Kaggle* [15], este conjunto de datos contiene 5000 imágenes con anotaciones de cuadro delimitador en formato PASCAL VOC para estas 3 clases: Casco; Persona y Cabeza.

La base de datos tiene imágenes con extensión .png, con una dimensión de 416 x 416 pixels y con un bit de profundidad de 24.

Se tomó una muestra representativa, la cual se define en la Ec. (1),

$$n = \frac{N \times Z^2 \times p \times q}{e^2 \times (N - 1) + Z^2 \times p \times q} \quad (1)$$

donde:

n : Tamaño de la muestra.

N : Tamaño de la población.

p : Probabilidad de ocurrencia del evento estudiado.

q : Probabilidad de no ocurrencia del evento estudiado.

Z : Parámetro que depende del nivel de confianza.

e : Error de estimación.

Del total de imágenes consideradas se convirtieron en la población inicial, además se estimó un nivel de confianza del 95 %, es decir una $Z = 1.96$, un error estimado de 5%, y los valores de p y q se calculan para que tengan la misma probabilidad de ocurrencia del 50% cada uno. Ejecutando los cálculos con (1), se obtuvo que la muestra seleccionada fue $n = 750$ en total, luego, el siguiente paso fue recuperar aleatoriamente las imágenes, considerando un 66% para entrenamiento y un 34% para prueba como se muestra en la Tabla I.

TABLA I

CANTIDAD DE IMÁGENES PARA ENTRENAMIENTO Y PRUEBAS

Fase	Porcentaje	Imágenes totales	Total por Clase
Entrenamiento	66	750	250
Pruebas	34	250	250

B. Preprocesamiento

Para el preprocesamiento de los datos, se determinaron las clases de salida que son:

- Casco Correcto: Representa un uso correcto de la mascarilla protectora, que cubre nariz y boca (Fig. 2).

- Casco Incorrecto: Representa un uso incorrecto de la mascarilla protectora, que no cubre la nariz (Fig. 3).
- Sin Casco: Representa la ausencia de una mascarilla que proteja al individuo (Fig. 4).



Fig. 2 Cascos de seguridad correctos.



Fig. 3 Cascos de seguridad incorrectos.



Fig. 4 Sin Cascos de seguridad.

C. Transformación

Se realizaron las transformaciones a las imágenes de muestra para garantizar que todas las imágenes tengan el mismo tamaño. Inicialmente estas tenían una resolución de 416×416 píxeles, pero como era la red residual ResNet-18 requería que fueran transformados a la forma (3×224×224), además se realizó una normalización con la media y la desviación estándar a [0.485, 0.456, 0.406] y [0.229, 0.224, 0.225] respectivamente, tanto para entrenamiento como para prueba. Los datos se cargaron en un diccionario con la ayuda de Pytorch DataLoader, con un tamaño de lote de ocho como se muestra en la Fig. 5.

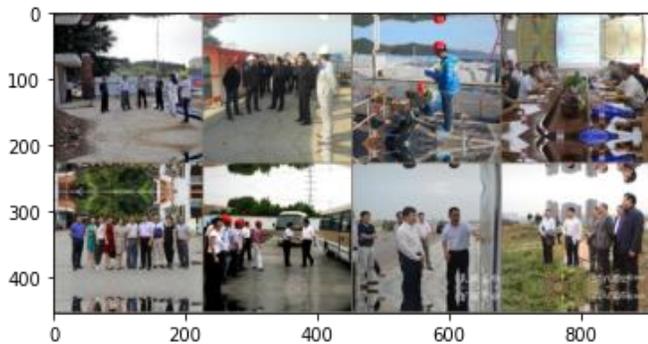


Fig. 5 Transformaciones Realizadas para Entrenamiento en un Lote de Imágenes de Tamaño Ocho.

D. Patrones

Se escogió el modelo de arquitectura ResNet18 para hacer el clasificador ya es más rápida para entrenar. Luego se detallan en 8 partes los temas más importantes en la construcción del modelo propuesto de Transferencia de Aprendizaje Cuántico.

1) *Número de Qubits*: Un qubit es la unidad básica de las computadoras cuánticas, por el principio de superposición, podría tener una parte de 0 y una parte de 1. Para el estudio se utilizaron cuatro qubits. Un qubit es un vector de módulo

unitario en un espacio vectorial bidimensional complejo, los estados cuánticos son $|0\rangle$ en Ec. (2) y $|1\rangle$ en Ec. (3).

$$|0\rangle = \begin{pmatrix} 1 \\ 0 \end{pmatrix} \quad (2)$$

$$|1\rangle = \begin{pmatrix} 0 \\ 1 \end{pmatrix} \quad (3)$$

2) *Circuito cuántico*: PennyLane [16] es una biblioteca Python multiplataforma para programar computadoras cuánticas. Los cálculos cuánticos, que implican la ejecución de uno o más circuitos cuánticos, se representan como objetos de nodos cuánticos (QNodes). Se utiliza un nodo cuántico para declarar el circuito cuántico y también vincula el cálculo a un dispositivo específico que lo ejecuta. QNodes puede interactuar con cualquiera de las bibliotecas numéricas y de aprendizaje automático admitidas (NumPy, PyTorch, TensorFlow y JAX). Existen los métodos de diferenciación, para la simulación en PennyLane que son: *backprop*, *adjoint* y *reversible*. Se eligió "reversible" ya que la red cuántica se ejecutará en un simulador y dar mejores resultados que las demás.

3) *Dispositivo*: Para ejecutar, y luego optimizar, un circuito cuántico, primero se debe especificar un dispositivo computacional. Un "dispositivo" es aquel que permite indicar en qué hardware ejecutar el circuito cuántico. El dispositivo es una instancia de la clase *Device* y puede representar un simulador o un dispositivo de hardware. PennyLane ofrece algunos dispositivos básicos como 'default.qubit', 'default.mixed', lightning.qubit, 'default.gaussian', se eligió "default.qubit" que es el simulador local por defecto de PennyLane. El argumento *shots* es un número entero que define cuántas veces se debe evaluar el circuito para estimar cantidades estadísticas. El número de "disparos" se estableció como "exacto", esto solo es posible porque son simuladores, en computadoras cuánticas reales el número de "disparos" está determinado por una ecuación en particular.

4) *Red neuronal cuántica*: Es un modelo de red neuronal que está basado en los principios de la mecánica cuántica. La propuesta es una red similar a una red neuronal clásica totalmente conectada; recibe un vector de 512 características y tiene tres salidas asociadas con las clases casco correcta, casco incorrecto y sin casco. La estructura está compuesta por una capa de preprocesamiento de tipo Lineal, una función de activación de tipo *tangente hiperbólica*, una arquitectura en capas *Basic Entangler* y una capa de postprocesamiento. La arquitectura de capa se construye con un circuito cuántico variacional [17]; este algoritmo híbrido combina la computación cuántica y clásica y está diseñado para ser ejecutado en computadoras cuánticas. Para implementar este tipo de circuito variacional, primero se debe definir un nodo con una función cuántica que reciba como parámetros el número de características y los pesos seleccionados; debemos cambiar el

tamaño de los pesos a la forma: número de capas cuánticas x número de qubits.

Luego por cada cable (wire) hay que colocar una puerta cuántica de Hadamard (H), la cual opera sobre un solo *qubit*, esta se encarga de transformar el estado $|0\rangle$ en $|+\rangle$ y el estado $|1\rangle$ en $|-\rangle$, su representación matricial se observa en Ec. (4) así como las representaciones de $|+\rangle$ y $|-\rangle$ en Ec. (5) y Ec. (6) respectivamente.

$$H = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \quad (4)$$

$$|+\rangle = \frac{|0\rangle + |1\rangle}{\sqrt{2}} \quad (5)$$

$$|-\rangle = \frac{|0\rangle - |1\rangle}{\sqrt{2}} \quad (6)$$

Luego se agregan tres tipos de capas cuánticas, como se detalla:

- Capa de incrustación: Esta capa consta de rotaciones de un solo *qubit*, con puertas de rotación como R_x , R_y y R_z , donde ϕ es el ángulo de rotación, para esto se usó la plantilla “Angle Embedding”.
- Capas variacionales: Construidas con la plantilla *Basic Entangler Layers*, la cual recibe como parámetros los pesos, un vector de alambres y el eje sobre el cual rotar, este se encarga de construir la cantidad de capas especificadas en la forma de los pesos; Esta plantilla inserta puertas CNOT y rotaciones de un solo *qubit*, como se muestra en la Fig. 6.

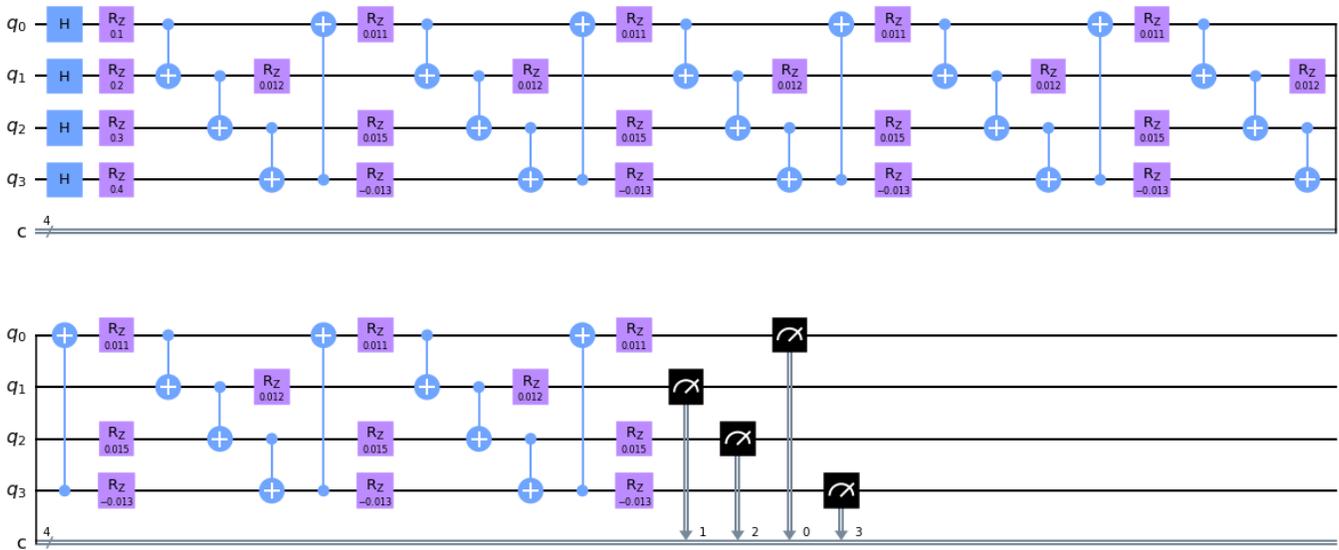


Fig. 6 Capas Variacionales con Capas Entangler Básicas para cuatro Qubits y una Profundidad de 7 Capas, con Puertas CNOT y Rotaciones de Qubit Simple Puertas R_z .

- Capa de medición: Esta capa contiene 4 operadores *Pauli Z* (Fig. 7), que permiten medir el estado de los cuatro *qubits*, los cuales al ser observados irán hacia un estado u otro.

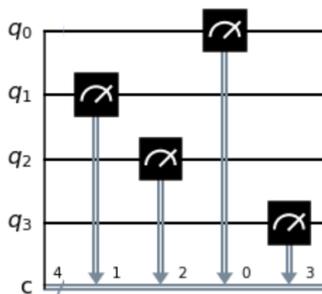


Fig. 7 Capa de Medida con 4 Operadores *Pauli Z*.

5) *Red neuronal cuántica con capas fuertemente entrelazadas*: de manera similar a Red neuronal cuántica con *Basic Entangler Layers*, la red neuronal cuántica recibe un vector de 512 características y proporciona tres salidas correspondientes a casco correcta, casco incorrecto y no casco, de igual forma consta de una capa de procesamiento, una capa de postprocesamiento y tiene una función de activación \tanh .

6) *Red Neuronal Cuántica con Capas Personalizadas*: la red neuronal cuántica está completamente conectada como se describió en una sección previa, la diferencia es que la arquitectura de las capas variacionales se basa en los ejemplos detallados en [18], esta última propuesta de diseño de capas se basa en el entrelazado de puertas CNOT y rotaciones de un solo qubit.

7) *Aprendizaje de transferencia*: El aprendizaje de transferencia clásico, considera dos tipos: ajuste fino y extracción de características. En el ajuste fino, se parte de un modelo previamente entrenado y se actualizan todos los parámetros para una nueva tarea; esencialmente, todo el modelo se vuelve a entrenar por completo. En la "extracción de características", comenzamos con un modelo previamente entrenado y solo actualizamos los pesos de la capa final, con los que ahora podemos hacer predicciones. Ambos métodos de aprendizaje por transferencia siguen los siguientes pasos:

- Paso 1: Inicializar el modelo previamente entrenado con los parámetros seleccionados.
- Paso 2: Remodelar la capa final.
- Paso 3: Llevar a cabo el entrenamiento.

Para hacer aprendizaje de transferencia cuántica, se debe tomar una red clásica pre-entrenada, para este caso, ResNet-18 (Tabla II), a la que se le remodela la capa final para conectarla con una red neuronal cuántica cuya arquitectura se basa en un circuito variacional que será ejecutado en una computadora cuántica.

TABLA II
ARQUITECTURA RESNET-18

Nombre de Capa	Tamaño de filtro	Stride	Padding	Número de filtros	Salida
Entrada de imagen	-	-	-	-	120x240x3
Conv 1_x	7x7x3	2	3	64	60x120x64
	3x3	2	1	-	30x60x64
Conv 2_x	3x3x64	1	1	64	30x60x64
	3x3x64	1	1	64	
	3x3x64	1	1	64	
	3x3x64	1	1	64	
Conv 3_x	3x3x64	2	1	128	15x30x128
	3x3x128	1	1	128	
	1x1x64	2	0	128	
	3x3x128	1	1	128	
Conv 4_x	3x3x128	2	1	256	8x15x256
	3x3x256	1	1	256	
	1x1x128	2	0	256	
	3x3x256	1	1	256	
Conv 5_x	3x3x256	2	1	512	4x8x512
	3x3x512	1	1	512	
	1x1x256	2	0	512	
	3x3x512	1	1	512	
	4x8	-	0	-	1x1x512

Se realizaron la "extracción de características", y la capa final de ResNet-18 se vincula a la red neuronal cuántica con 512 características. Se utiliza una capa L , $n_0 \rightarrow n_1$, donde n_0 representa las entradas y n_1 las salidas, x es un vector de entrada e y es un vector de salida como en Ec. (7).

$$L_{n_0 \rightarrow n_1}: x \rightarrow y \quad (7)$$

Q es un circuito cuántico variacional con la capa de incrustación E y la capa de medición M según Ec. (8).

$$Q = M \circ Q' \circ E \quad (8)$$

Para aplicar el aprendizaje de transferencia cuántico híbrido, se crea la red neuronal cuántica \bar{Q} como se muestra en Ec. (9), en base a lo formulado en Ec. (7) y (8).

$$\bar{Q} = L_{n_q \rightarrow n_{out}} \circ Q \circ L_{n_{in} \rightarrow n_q} \quad (9)$$

En la Fig. 8, se muestra gráficamente el modelo de aprendizaje de transferencia cuántica propuesto.

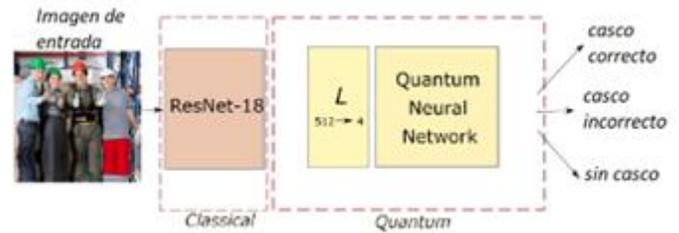


Fig. 8 El modelo de aprendizaje de transferencia cuántica con la Computación Clásica de ResNet-18 y la Computación Cuántica de la Red Neuronal Cuántica.

8) *Entrenamiento*: Para ello se define una función de entrenamiento que recibe parámetros de entrada como un modelo, un diccionario con la información de las imágenes cargadas, una función de pérdida de validación cruzada (cross-validation), varias épocas para entrenar y un indicador "is inception" que se usa para preparar la función para trabajar con Inception v3. La función de entrenamiento se probó en el lado cuántico con resnet-18 y densenet. Esta función de entrenamiento realiza 2 fases: una de entrenamiento y otra de testeo; se eligen los mejores pesos para permitir que el modelo resultante se clasifique entre máscara correcta, máscara incorrecta y sin máscara. Finalmente, se recuperaron los resultados obtenidos al ejecutar de 10 a 50 épocas, y cada modelo fue probado con las imágenes seleccionadas. Se tomó como base la propuesta de [19]. La Fig. 9 muestra el resultado.

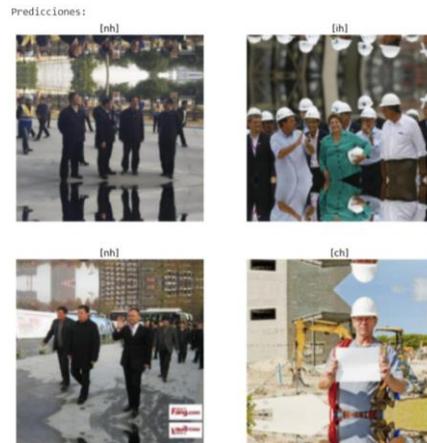


Fig. 9 Predicciones de modelos compuestos con capas entrelazadas para 50 épocas.

D. Evaluación del modelo

Para evaluar el modelo [20], se utilizaron *Precisión* (Ec. 10), *Recall* (Ec. 11) y *F1-score* (Ec. 12). Para muchas clases C_i , fp_i representa falso positivo, tp_i verdadero positivo, fn_i falso negativo y tn_i verdadero negativo.

$$Precision = \frac{\sum_{i=1}^l \frac{tp_i}{l}}{tp_i + fp_i} \quad (10)$$

$$Recall = \frac{\sum_{i=1}^l \frac{tp_i}{l}}{tp_i + fn_i} \quad (11)$$

$$F1 - score = \frac{(\beta^2 + 1)(Precision)(Recall)}{(\beta^2)(Precision) + Recall} \quad (12)$$

IV. RESULTADOS

La Tabla III muestra los resultados de la clasificación, tomando como factores relevantes la Precisión y el Tiempo de Entrenamiento; para 10, 20, 25, 30, 35, 40, 45 y 50 épocas, considerando un conjunto de datos de 750 imágenes, 300 para entrenamiento y 150 para prueba, en el lado cuántico, hay cuatro qubits, el número de disparos fue "exacto", la profundidad de las capas variacionales fue de 7, El método de diferenciación fue "reversible", y el procesador utilizado fue la GPU proporcionada por Google Colab [21], el simulador seleccionado fue "Pennylane" con *Basic Entangler Layers* La red residual seleccionada para el aprendizaje por transferencia fue ResNet-18. La tabla de resultados funciona con los mismos hiperparámetros descritos anteriormente:

TABLA III
RESULTADOS DE LAS PRUEBAS DE CLASIFICACION CON RESNET CUANTICO Y EL CIRCUITO BASIC ENTANGLER LAYER

épocas	Precisión Pruebas (%)	Tiempo de Entrenamiento (min) - CPU	Tiempo de Entrenamiento (min) - GPU
10	70.67	32.20	12.70
20	81.67	58.55	18.21
25	81.00	80.50	23.30
30	89.07	101.57	27.57
35	84.67	131.53	33.45
40	90.13	185.48	40.50
45	93.07	189.45	42.20
50	95.47	190.54	46.59

Como se muestra en la Tabla anterior el mejor resultado fue con 50 épocas y una precisión de 95.47%

En la tabla IV se muestra las métricas de Precisión, el *Recall* y el *F1-score* para determinar el modelo con la mejor clasificación.

TABLA IV
CLASIFICACIÓN PARA *BASIC ENTANGLER LAYERS* CON 40 ÉPOCAS

Clase	Precisión	ReCall	F1-Score
Casco Correcto	0.80	0.94	0.87
Casco Incorrecto	0.87	0.55	0.67
Sin Casco	0.79	0.95	0.86

En la Fig 10, se muestra la matriz de confusión resultante para Basic Entangler Layers con 50 épocas, donde los acrónimos de las clases son *ch* (*correct helmet*), *ih* (*incorrect helmet*) y *nh* (*no helmet*).

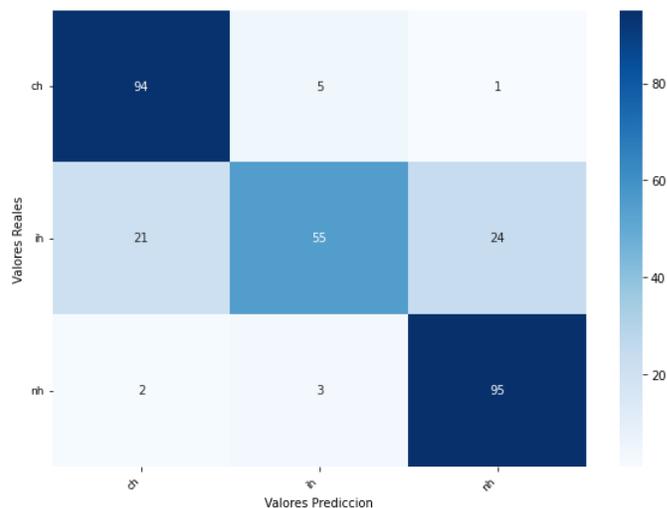


Fig. 10 Matriz de confusión para Basic Entangler Layers con 50 épocas.

CONCLUSIÓN

Se desarrolló un modelo de Quantum Transfer Learning con ResNet-18 para la clasificación del uso de cascos de seguridad en un entorno laboral. Se utilizó una red neuronal cuántica de 7 capas variacionales desarrolladas con la plantilla *Basic Entangler Layers*.

Las pruebas realizadas en la clasificación para el uso del casco correctamente, casco incorrecto (algunas personas si y otros no) y sin casco, con 750 imágenes, se obtuvieron una precisión del 95.47%. Estos resultados son satisfactorios si se comparan con problemas de clasificación cuántica con transfer learning de ResNet-18 y cuatro qubits en su implementación.

Como trabajos futuros, al modelo entrenado se sugiere utilizar las capas *Strongly Entangling Layers*, *CV Neural Net Layers*, así como capas personalizadas con diferentes épocas para evaluar la precisión, y mejorar también los hiperparámetros para potenciar su desempeño.

AGRADECIMIENTO

Se agradece al apoyo del Vicerrectorado de Investigación de la Universidad Católica de Santa María para hacer posible la publicación del artículo.

REFERENCIAS

- [1] Organización Internacional del Trabajo., "Salud y seguridad en el trabajo: OMS/OIT: Casi 2 millones de personas mueren cada año por causas relacionadas con el trabajo," OIT, 2021. https://www.ilo.org/global/about-the-ilo/newsroom/news/WCMS_819802/lang--es/index.htm (accessed Dec.

- 01, 2022).
- [2] J. Li *et al.*, "Safety helmet wearing detection based on image processing and machine learning," in *2017 Ninth International Conference on Advanced Computational Intelligence (ICACI)*, Feb. 2017, pp. 201–205, doi: 10.1109/ICACI.2017.7974509.
 - [3] A. Kelm *et al.*, "Mobile passive Radio Frequency Identification (RFID) portal for automated and rapid control of Personal Protective Equipment (PPE) on construction sites," *Autom. Constr.*, vol. 36, 2013, doi: 10.1016/j.autcon.2013.08.009.
 - [4] A. H. M. Rubaiyat *et al.*, "Automatic detection of helmet uses for construction safety," 2017, doi: 10.1109/WIW.2016.10.
 - [5] Y. Li, H. Wei, Z. Han, J. Huang, and W. Wang, "Deep Learning-Based Safety Helmet Detection in Engineering Management Based on Convolutional Neural Networks," *Adv. Civ. Eng.*, vol. 2020, 2020, doi: 10.1155/2020/9703560.
 - [6] X. Ke, W. Chen, and W. Guo, "100+ FPS detector of personal protective equipment for worker safety: A deep learning approach for green edge computing," *Peer-to-Peer Netw. Appl.*, vol. 15, no. 2, 2022, doi: 10.1007/s12083-021-01258-4.
 - [7] H. Mogalapalli, M. Abburi, B. Nithya, and S. K. V. Bandreddi, "Classical-Quantum Transfer Learning for Image Classification," *SN Comput. Sci.*, vol. 3, no. 1, p. 20, Jan. 2022, doi: 10.1007/s42979-021-00888-y.
 - [8] R. C. Reyes, R. V Sevilla, G. S. Zapanta, J. V Merin, R. R. Maaliw, and others, "Safety Gear Compliance Detection Using Data Augmentation-Assisted Transfer Learning in Construction Work Environment," in *2022 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)*, 2022, pp. 1–6.
 - [9] F. Gong, X. Ji, W. Gong, X. Yuan, and C. Gong, "Deep Learning Based Protective Equipment Detection on Offshore Drilling Platform," *Symmetry (Basel)*, vol. 13, no. 6, p. 954, May 2021, doi: 10.3390/sym13060954.
 - [10] S. Ka, M. Mohan, U. Prakash, and S. Trisheela, "On Stream Face Mask and helmet detection System Using Machine Learning Techniques," in *2022 IEEE 2nd Mysore Sub Section International Conference (MysuruCon)*, Oct. 2022, pp. 1–6, doi: 10.1109/MysuruCon55714.2022.9972452.
 - [11] M. R. Abid and R. Kiefer, "Automated Dataset Amplification and its Application to Small Dataset Object Detection Transfer Learning," 2021, doi: 10.1145/3471287.3471305.
 - [12] K. Han and X. Zeng, "Deep Learning-Based Workers Safety Helmet Wearing Detection on Construction Sites Using Multi-Scale Features," *IEEE Access*, vol. 10, 2022, doi: 10.1109/ACCESS.2021.3138407.
 - [13] J. Shen, X. Xiong, Y. Li, W. He, P. Li, and X. Zheng, "Detecting safety helmet wearing on construction sites with bounding-box regression and deep transfer learning," *Comput. Civ. Infrastruct. Eng.*, vol. 36, no. 2, pp. 180–196, Feb. 2021, doi: 10.1111/mice.12579.
 - [14] U. Fayyad, G. Piatetsky-Shapiro, and P. Smyth, "The KDD process for extracting useful knowledge from volumes of data," *Commun. ACM*, vol. 39, no. 11, pp. 27–34, Nov. 1996, doi: 10.1145/240455.240464.
 - [15] "Hard Hat Dataset," *Make ML*, [Online]. Available: <https://makeml.app/datasets/hard-hat-workers>.
 - [16] V. Bergholm *et al.*, "Pennylane: Automatic differentiation of hybrid quantum-classical computations," *arXiv Prepr. arXiv1811.04968*, 2018.
 - [17] J. R. McClean, J. Romero, R. Babbush, and A. Aspuru-Guzik, "The theory of variational hybrid quantum-classical algorithms," *New J. Phys.*, vol. 18, no. 2, p. 023023, Feb. 2016, doi: 10.1088/1367-2630/18/2/023023.
 - [18] A. Mari, T. R. Bromley, J. Izaac, M. Schuld, and N. Killoran, "Transfer learning in hybrid classical-quantum neural networks," *Quantum*, vol. 4, 2020, doi: 10.22331/Q-2020-10-09-340.
 - [19] C. Soto-Paredes and J. Sulla-Torres, "Hybrid Model of Quantum Transfer Learning to Classify Face Images with a COVID-19 Mask," *Int. J. Adv. Comput. Sci. Appl.*, vol. 12, no. 10, 2021, doi: 10.14569/IJACSA.2021.0121092.
 - [20] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf. Process. Manag.*, vol. 45, no. 4, 2009, doi: 10.1016/j.ipm.2009.03.002.
 - [21] E. Bisong and E. Bisong, "Google Colaboratory," in *Building Machine Learning and Deep Learning Models on Google Cloud Platform*, 2019.