

Uso del aprendizaje profundo para la discriminación automática de imágenes que contienen autopartes defectuosas

Rafael Guzmán-Cabrera¹, Daniel Alberto May-Arriola²,
Mary Carmen Peña-Gomar³, Miguel Torres-Cisneros¹

¹ Universidad de Guanajuato,
Grupo de Física Aplicada y Tecnologías Avanzadas, División de Ingenierías,
México

² Centro de Investigaciones en Óptica A.C.,
Laboratorio de Fibras Ópticas y Óptica Integrada,
México

³ Universidad Michoacana de San Nicolás de Hidalgo, FCFM,
México

torres.cisneros@ugto.mx

Resumen. Se muestra la clasificación automática de imágenes de autopartes con defectos de soldadura, usando lenguaje de máquina que involucra la RESNET50 en el escenario de clasificación; conjuntos de entrenamiento-prueba se usaron 4 diferentes clasificadores con 2 métricas de evaluación. Se obtuvo 100 % de precisión en los resultados.

Palabras clave: manufactura, clasificación automática, lenguaje de máquina, redes neuronales.

Using Deep Learning for Automatic Discrimination of Images Containing Defective Auto Parts

Abstract. The automatic classification of images of auto parts with welding defects is shown, using machine language that involves the RESNET50 in the classification scenario; training-test sets, 4 different classifiers with 2 evaluation metrics were used. 100% accuracy was obtained in the results.

Keywords: Manufacturing, automatic classification, machine language, neural networks.

1. Introducción

En las últimas décadas, el uso de los sistemas de cómputo en diversas tareas humanas es cada vez más frecuente. Uno de los principales objetivos de su uso es el de respaldar

las tareas humanas. Por ejemplo, en esta tarea de asistencia se ha incorporado el uso de herramientas de inteligencia artificial, tales como el aprendizaje profundo (*Deep Learning*), en el diagnóstico médico [1].

De la misma manera, la calidad en los procesos industriales se ha incrementado notablemente al utilizar inteligencia artificial para mejorar la precisión en la detección de diversos tipos de defectos en manufactura [2]. De manera particular, es posible utilizar imágenes en las diversas etapas del proceso de fabricación e incluso en la pieza terminada y ayudarse de ellas, clasificándolas, para determinar su calidad.

Como es sabido, la clasificación de imágenes se refiere a la tarea de extraer todo tipo de información de una imagen. Aunque existen dos tipos de clasificación, nosotros usaremos la clasificación supervisada. Este tipo de clasificación, parte de un conjunto de clases conocido. Estas clases deben caracterizarse en función de valores establecidos en un conjunto de variables que poseen los objetos de interés en las imágenes.

En el presente trabajo se aplica la inteligencia artificial en la clasificación automática de imágenes de piezas automotrices que presentan o no, omisión de puntos de soldadura. Por lo anterior, estas imágenes son clasificadas en dos posibles categorías: defectuosas y no defectuosas.

El Resto del artículo se encuentra organizado de la siguiente manera: en la sección 2 se presenta una breve descripción del problema a resolver. En la sección 3 se presenta el método propuesto, con una breve descripción de las variables y algoritmos utilizados. Posteriormente, en la sección 4, se presentan los resultados de la evaluación del método propuesto y finalmente, en la sección 5 hemos colocado las conclusiones del trabajo.

2. Descripción del problema

Una cierta compañía que fabrica autopartes, produce una en la que es necesario colocar 8 puntos de soldadura en ciertas posiciones de la pieza. En la figura 1a es posible apreciar la pieza fabricada con los 8 puntos de soldadura necesarios, ya que han sido etiquetados de forma manual con un recuadro en rojo.

Debido a que el proceso de colocar los puntos de soldadura lo realizan varios operadores de forma manual, es posible que pueda existir un error en la pieza al omitir uno o más puntos de los 8 necesarios, como se puede apreciar en la Figura 1b. Por esta razón, al final del proceso, cada pieza es inspeccionada, también manualmente, para verificar el cumplimiento de esta condición.

Este trabajo propone el uso de aprendizaje de máquina en imágenes de las piezas, en las que sea posible reconocer, de manera muy precisa, cualquier pieza defectuosa, es decir, que no cuente con los 8 puntos de soldadura.

3. Descripción del experimento

Para el presente trabajo creamos una base de datos mediante la adquisición de 115 imágenes, de las cuales 70 de ellas corresponden autopartes con 8 puntos de soldadura (No defectuosa) y las 45 imágenes restantes son de piezas en las que falta uno o más puntos de soldadura (Defectuosas).




Fig. 1. Autopartes fabricadas, manualmente etiquetadas. a) Con 8 puntos de soldadura (no defectuosa). b) Con 7 puntos de soldadura (defectuosa).




Fig. 2. Diagrama de flujo de la metodología realizada bajo el escenario de “Conjunto de entrenamiento y Prueba”.

Posteriormente, correspondiendo al escenario de; Conjunto de entrenamiento y Prueba, a las imágenes se les realizó un pre-procesamiento a las imágenes utilizadas, ver Fig. 2. Este procedimiento es simple y es un requisito necesario para el siguiente paso. El pre-procesamiento, consiste en dos partes: (1) Relleno (*Padding*) y (2) Redimensionamiento (*Resizing*). Al final de esta etapa tendremos una matriz para cada imagen con dimensiones de 224 x 224 y con números del 0 al 255 en 3 canales (RGB).

El objetivo del pre-procesamiento es la de estandarizar todas las imágenes a las dimensiones mencionadas. Posteriormente, con el objetivo de mejorar los resultados de los métodos de clasificación, la matriz de imágenes es ingresada a la red neuronal; ResNet50, con el fin de obtener un vector de características de las imágenes.

La dimensión del vector resultante es 2048 y posee las características generales de las imágenes tales como: intensidad, brillo, luminosidad, etc. Estas, alimentarán a los




Fig. 3. a) Resultados de las métricas “Precisión” y “F1” para cada uno de los 4 métodos de clasificación utilizados, b) Curva ROC para el método de Máquina de Vector de Soporte (SVM).

clasificadores con la finalidad de que puedan ayudar a discernir de mejor forma entre las dos clases posibles. Posteriormente, se crearon los conjuntos de Entrenamiento y Prueba, con el 80 % y 20 % del total de las 115 imágenes, respectivamente.

Posteriormente, con el fin de comparar resultados, utilizamos 4 métodos de clasificación: Máquinas de vector de soporte, Regresión Logística, Vecinos Cercanos y Árbol de Decisiones. Finalmente, los resultados son evaluados mediante dos métricas; Precisión y F1.

4. Resultados

Una vez realizadas las métricas de “Precisión” y “F1” a los resultados de clasificación realizada en el conjunto de prueba, los resultados arrojan un 0 % de error, como puede observarse en la fig. 3a. El mismo resultado es obtenido, independientemente del método de clasificación utilizado. La figura 3b presenta la curva ROC obtenida para el método de clasificación; Máquina de Vector de Soporte (SVM, por sus siglas en inglés).

Otra forma de poder apreciar los resultados es mostrada en la Tabla 1. En ella es posible verificar la forma en que las imágenes de las piezas, en el conjunto de prueba, fueron clasificadas. Puede observarse que todas las piezas fueron clasificadas de manera correcta, es decir, todas las imágenes de piezas no defectuosas fueron clasificadas como no-defectuosas (ND), de la misma forma con las imágenes que contienen piezas defectuosas fueron clasificadas como defectuosas (D).

5. Conclusiones

Los resultados obtenidos permiten concluir que la metodología propuesta es suficiente para obtener un sistema que permita discriminar las piezas defectuosas, mediante sus imágenes, con una precisión del 100 %. Esto es independientemente del método de clasificación usado y no es necesario probar un escenario distinto.

Agradecimientos. Este trabajo ha sido apoyado parcialmente por el Consejo Mexicano de Ciencia y Tecnología (CONACyT) mediante los apoyos: CB2016-286368 and CB-2016-01-286629, así como por la Universidad de Guanajuato mediante el apoyo CIIC-57/2022.

Referencias

1. Bagchi, S., Huong, A.: Signal processing techniques and computer-aided detection systems for diagnosis of breast cancer: A review paper. *Indian Journal of Science & Technology*, vol. 10, no. 3, pp. 1–6 (2017) doi: 10.17485/ijst/2017/v10i3/110640
2. Malkoff, D. B.: A framework for real-time fault detection and diagnosis using temporal data. *Artificial Intelligence in Engineering*, vol. 2, no. 2, pp. 97–111 (1987) doi: 10.1016/0954-1810(87)90144-0