

Deteccion de Fallos en Cables Blindados a través de Visión Artificial y Redes Neuronales

Detection of Faults in Armored Cables through Artificial Vision and Neural Networks

ARANDA, Manuel†*, MEDINA-MUÑOZ, Luis, RODRÍGUEZ-ESPINOZA, Indelfonso y LÓPEZ-VALENCIA, Gabriel

Instituto Tecnológico de Nogales. Departamento de Posgrado e Investigación

ID 1° Autor: *Manuel Aranda*/ORCID: 0000-0001-6719-1428, **Researcher ID Thomson:** H-4818-2018, **CVU CONACYT-ID:** 902669

ID 1° Coautor: *Luis Medina-Muñoz*/ORCID: 0000-0001-9598-1451, **Researcher ID Thomson:** H-4735-2018, **CVU CONACYT-ID:** 454558

ID 2° Coautor: *Indelfonso Rodríguez-Espinoza*/ORCID: 0000-0001-6405-9886, **Researcher ID Thomson:** I-1513-2018, **CVU CONACYT-ID:** 346230

ID 3° Coautor: *Gabriel López-Valencia*/ORCID: 0000-0001-9274-395X, **Researcher ID Thomson:** H-5383-2018, **CVU CONACYT-ID:** 883105

Recibido: 9 de Enero, 2018; Aceptado 22 de Marzo, 2018

Resumen

Este trabajo es realizado para atacar un problema de calidad en una industria de manufactura de antenas para la comunicación inalámbrica, debido a la complejidad de la inspección visual, y los altos costos de los sistemas modernos se propone un sistema económico para automatizar la inspección de cables blindados. Para hacer más fácil la inspección y la detección de cables que no cumplan los criterios de calidad se controlarán las variables de iluminación y se colocará un fondo verde para hacer la separación de los cables con el medio ambiente. El sistema se limita a un número de parte y de longitud de 10cm, en los cuales buscará que, el despoje de cubierta plástica, de blindaje, de dieléctrico y corte de conductor concéntrico, pero además de la longitud sea revisado de manera automática para detectar si hay algún tipo de daño por la máquina de corte.

Inspección, Red Neuronal, Escala de Grises

Abstract

This work is developed to resolve a quality issue in an industry of manufacturing antennas for wireless communication. Due to the complexity of the visual inspection, and the high costs of modern systems, an economical system is proposed to automate the inspection of shielded cables. To make it easier to inspect and detect cables that do not meet the quality requirements, the lighting variables were controlled and a green background was placed to separate the cables from the environment. The system is limited to one part number and length of 10cm, in which it will look for the stripping of the plastic cover, un-shielding, stripping of dielectric and concentric conductor cut, but in addition to the length of the above mentioned must any kind of damage by the cutting machine.

Inspection, Neural Network, Grayscale

Citación: ARANDA, Manuel, MEDINA-MUÑOZ, Luis, RODRÍGUEZ-ESPINOZA, Indelfonso y LÓPEZ-VALENCIA, Gabriel. Deteccion de Fallos en Cables Blindados a través de Visión Artificial y Redes Neuronales. Revista de Tecnología e Innovación 2018, 5-14: 30-34.

†Investigador contribuyendo como primerAutor.

1. Introducción

La Inspección Visual Automatizada es costosa; El costo de la una máquina de Inspección visual puede llegar hasta los 50K USD. Este precio dificulta a las pequeñas empresas comprarlos y optan por llevar a cabo la inspección visual mediante personas contratadas precisamente para llevar a cabo ese trabajo, sin embargo, esta elección compromete la calidad de los productos manufacturados, debido a las capacidades humanas, los criterios y el humor que pueden hacer variar la aceptación de los requisitos de calidad.

El trabajo consiste en la comparación de ANN. La implementación y simulación computacional se desarrolla en Matlab 2015b (Inc, 2017) con la ayuda de Simulink y la Caja de Herramientas de Red Neural, en la que es posible definir y estructurar diferentes redes neuronales, algoritmos de entrenamiento y funciones de activación y personalizar cada sección de la red neuronal Para lograr el error deseado (V. C. PATEL, 1998).

En las Industrias de manufactura la inspección es un paso importante para asegurar la calidad de los productos, en este proceso están siendo sustituidos los humanos por sistemas automatizados debido a que el desempeño de estos puede ser inadecuado y variable (Saravanan, 2013). Moganti, hace un estudio de una serie de algoritmos para la inspección automatizada de PCB's (Printed Board Circuits) en 2014, su calificación divide las técnicas en tres clases básicas, *Comparación por Referencias* en el cual la comparación se hace contra piezas maestras, *Verificación por diseño de reglas* en el cual son compradas en contra de reglas de calidad y *Técnicas híbridas* en la cual se combinan las dos anteriores (Madhav Mogantia, 1996).

La inspección en los procesos de manufactura puede ser llevada a cabo usando diferentes métodos, como dispositivos no escalados llamados "Pasa-No Pasa", Instrumentos de medición, o dispositivos avanzados que no tocan las piezas. Ahmed en 2011 diseño un sistema económico para la inspección de productos maquinados de 2 dimensiones, en el cual extraía las características geométricas y utilizó una red neuronal para decidir si las piezas inspeccionadas son conformes con las tolerancias pre-especificadas (Safaa L Diab, 2011).

2. Deteccion De Fallos

2.1. Preparación de Imágenes

La colección de cables aceptables fue de 200 a las cuales se le tomó una fotografía a cada una de ellas en un ambiente de iluminación controlado, además el cable fue colocado en un fondo verde para controlar el fondo de la imagen y eliminar ruidos por diferentes colores

La colección de cables defectuosos fue de 32, a los cuales se le tomaron 2 fotos a cada uno de manera no inmediata, esto es, se tomaron primero, foto a cada uno de ellos y después se les tomó otra fotografía esto para obtener diferente ángulo y aumentar el tamaño de la muestra de piezas defectuosas.

2.2. Preparación de la imagen

Una vez que se tenía la colección de imágenes esta fue procesada para reducir el tamaño de la imagen, esto es la imagen tenía el tamaño de 2,907 X 5,168 Píxeles (Ver figura 1), así que se desarrolló un método de detectar el cable y reducir la imagen a 600 X 5,168 Píxeles.



Figura 1 Muestra de Imagen Original

Una vez recortada la imagen se eliminó el fondo verde a través de un filtro, esto redujo el tamaño de la foto de 1.6M a 178K (ver figura 2), a esta imagen se le aplicó la escala de grises y se sacó el histograma, se guardó en un archivo, dando como resultado un archivo con 256 columnas (escala de grises), a esta se le agregó otra columna, la cual para la piezas aceptables se le dio el valor de "1" y para la piezas defectuosas el valor de "0".



Figura 2 Muestra de Imagen Recortada

2.3. Entrenamiento de Redes Neuronales

Para el entrenamiento de las Redes Neuronales de hizo con los datos de histograma de 190 cables aceptables y con 54 histogramas de cables defectuosos, dejando 10 cables aceptables fuera del entrenamiento, así como 10 cables defectuosos (David Hunter, 2012).

Se hizo entrenamiento con tres tipos de Redes Neuronales, la FeedForward, Pattern Recognition, y Fit (R Hernández Grijalva, 2015). Para las 3 topografías se utilizo entrenamiento tipo Levenberg- Marquard (*ver figura 3*), además se hizo una comparación de numero de capas ocultas, de entre 1 y 30, esto para encontrar donde se obtienen los mejores resultados.

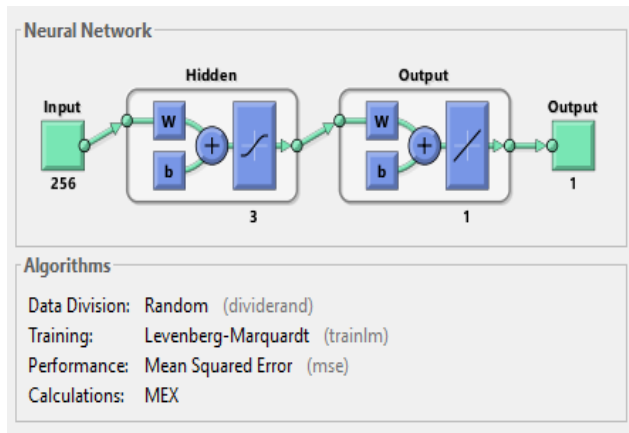


Figura 3 Topology Fit Neural Network.

3 Resultados

3.1 Red Neuronal Fit

En esta Red Neuronal se obtuvo la mejor detección de cables defectuosos con 11 capas, con 100% detección de cables defectuosos en cada uno de los entrenamientos, para la detección de cables Aceptables se obtuvo el 86% a tres capas, y el mejor resultados se obtuvo con tres capas. Ver Tabla 1.

Cap	Det Defectuosas						Det Aceptables						RC
	T1	T2	T3	T4	T5	RDNA	T1	T2	T3	T4	T5	RDA	
1	8	4	10	9	3	68%	9	9	0	9	10	74%	71%
2	10	3	6	0	5	48%	0	10	10	10	9	78%	63%
3	10	7	8	6	10	82%	9	9	7	10	10	90%	86%
4	5	4	8	9	7	66%	9	10	7	8	7	82%	74%
5	10	9	10	9	10	96%	3	9	8	8	4	64%	80%
6	7	10	5	4	8	68%	9	4	9	8	9	78%	73%
7	7	7	6	10	3	66%	9	10	9	9	10	94%	80%
8	7	7	10	9	9	84%	8	8	10	7	8	82%	83%
9	8	8	4	8	9	74%	9	5	10	7	10	82%	78%
10	10	10	8	8	9	90%	7	5	4	7	7	60%	75%
11	10	10	10	10	10	100%	4	4	3	4	6	42%	71%
12	7	9	8	7	8	78%	7	9	8	8	6	76%	77%
13	6	10	10	10	10	92%	8	4	3	6	4	50%	71%
14	10	9	9	1	9	76%	8	5	8	10	9	80%	78%
15	10	9	9	1	10	78%	4	6	7	8	6	62%	70%
16	9	9	10	10	9	94%	7	4	1	8	5	50%	72%
17	10	9	10	9	9	94%	6	6	6	7	8	66%	80%
18	9	10	6	10	10	90%	5	7	6	4	6	56%	73%
19	10	9	10	8	10	94%	6	6	7	8	7	68%	81%
20	7	10	9	9	10	90%	9	7	6	9	1	64%	77%
21	6	8	9	9	10	84%	8	5	10	6	7	72%	78%
22	9	7	10	8	7	82%	6	6	7	6	9	68%	75%
23	6	9	9	8	9	82%	10	8	8	8	4	76%	79%
24	7	10	10	10	10	94%	7	5	6	10	7	70%	82%
25	9	10	10	7	7	86%	8	6	7	8	10	78%	82%
26	9	9	9	10	6	86%	5	7	7	5	8	64%	75%
27	8	9	10	8	10	90%	5	6	3	3	7	48%	69%
28	9	7	9	10	10	90%	6	7	4	1	6	48%	69%
29	9	10	8	8	10	90%	8	6	8	5	6	66%	78%
30	9	8	10	7	10	88%	7	9	5	8	4	66%	77%

Tabla 1 Matiz de resultados con Red Fit

Red Neuronal Pattern Recognition

En esta Red Neuronal se obtuvo la mejor detección de cables Aceptables con 21 y 27 capas, con 100% detección de cables Aceptables en cada uno de los entrenamientos, para la detección de cables Defectuosos se obtuvo el 86% en 7 y 17 capas, y mejor resultados se obtuvo con 7 y 27 capas alcanzando el 90%. Ver Tabla 2.

Cap	Det Defectuosas						Det Aceptables						RC
	T1	T2	T3	T4	T5	RDNA	T1	T2	T3	T4	T5	RDA	
1	6	9	8	9	3	70%	9	10	10	9	10	96%	83%
2	9	10	9	5	9	84%	5	7	6	10	10	76%	80%
3	7	6	5	7	5	60%	10	10	10	9	10	98%	79%
4	6	6	10	7	8	74%	8	10	6	10	10	88%	81%
5	4	9	8	3	7	62%	10	8	9	10	6	86%	74%
6	6	8	1	3	4	44%	9	10	10	10	10	98%	71%
7	10	9	9	8	7	86%	10	8	10	9	10	94%	90%
8	1	9	5	6	10	62%	8	0	10	10	0	56%	59%
9	10	7	8	7	8	80%	7	10	9	10	10	92%	86%
10	7	9	9	7	10	84%	10	10	9	10	7	92%	88%
11	9	6	5	6	7	66%	10	10	10	9	9	96%	81%
12	10	10	9	1	9	78%	8	9	10	10	7	88%	83%
13	7	0	4	6	7	48%	10	9	10	9	10	96%	72%
14	6	7	5	6	10	68%	10	10	10	9	1	80%	74%
15	5	9	8	8	6	72%	10	7	9	10	10	92%	82%
16	6	9	7	8	9	78%	10	9	9	10	9	94%	86%
17	8	9	9	8	9	86%	6	10	3	10	9	76%	81%
18	6	9	5	7	8	70%	9	9	9	10	10	94%	82%
19	7	7	6	10	6	72%	7	10	10	7	10	88%	80%
20	9	6	8	10	6	78%	10	8	6	6	10	80%	79%
21	9	6	7	8	3	66%	10	10	10	10	10	100%	83%
22	7	8	7	9	5	72%	8	9	10	6	8	82%	77%
23	7	7	7	5	8	68%	10	10	9	10	10	98%	83%
24	8	8	8	8	7	78%	7	9	10	10	9	90%	84%
25	5	8	6	7	8	68%	6	0	10	9	2	54%	61%
26	9	7	7	8	7	76%	9	7	10	10	10	92%	84%
27	7	9	9	6	9	80%	10	10	10	10	10	100%	90%
28	7	6	6	9	9	74%	8	10	10	10	6	88%	81%
29	8	5	7	9	10	78%	10	9	10	10	7	92%	85%
30	7	4	8	7	10	72%	10	9	10	10	9	96%	84%

Tabla 2 Matriz de resultados con Red Pattern Recognition

3.3 Red Neuronal Feed Forward

En esta Red Neuronal se obtuvo la mejor detección de cables Aceptables con 1 y 4 capaz, Obteniendo un 94% detección de cables Aceptables en cada uno de los entrenamientos, para la detección de cables Defectuosos se obtuvo el 98% en 10 y 14 capas, y el mejor resultados se obtuvo con 10 capaz alcanzando el 85%. Ver tabla 3.

4.0 Conclusiones

La Red que mejor se adaptó a las necesidades de diagnóstico fue la feed Forward, ya que es la que mejor adaptación tuvo para encontrar los cables defectuosos, recordemos que en la industria es mejor rechazar piezas aceptables, ya que ellas pasarán a re trabajo y/o re inspección, que las piezas defectuosas sean catalogadas como aceptables, ya que al final los clientes de las industrias son los que recibirán las piezas defectuosas.

Cap	Det Defectuosas						Det Aceptables						RC
	T1	T2	T3	T4	T5	RDNA	T1	T2	T3	T4	T5	RDA	
1	8	5	3	9	8	66%	9	10	9	10	9	94%	80%
2	7	10	8	10	10	90%	9	3	10	0	0	44%	67%
3	5	8	5	8	8	68%	10	10	7	10	8	90%	79%
4	10	7	2	4	9	64%	8	10	10	9	10	94%	79%
5	6	9	6	9	5	70%	9	9	8	1	10	74%	72%
6	10	1	9	8	6	68%	8	10	8	10	8	88%	78%
7	10	10	10	7	9	92%	10	2	9	8	6	70%	81%
8	6	5	9	4	10	68%	8	9	10	10	9	92%	80%
9	8	9	10	7	8	84%	8	9	9	10	7	86%	85%
10	9	10	10	10	10	98%	6	5	8	10	7	72%	85%
11	8	7	10	10	9	88%	6	9	0	5	7	54%	71%
12	10	9	10	1	9	78%	5	7	5	9	5	62%	70%
13	7	9	6	10	7	78%	10	7	9	5	9	80%	79%
14	10	9	10	10	10	98%	7	9	5	8	6	70%	84%
15	6	8	6	10	9	78%	6	8	8	5	8	70%	74%
16	10	9	9	10	10	96%	6	5	3	7	5	52%	74%
17	10	9	9	5	8	82%	6	6	5	8	5	60%	71%
18	10	9	8	10	9	92%	9	3	5	8	5	60%	76%
19	7	10	9	10	9	90%	9	1	8	3	6	54%	72%
20	10	8	10	8	4	80%	5	10	8	8	9	80%	80%
21	10	10	10	8	10	96%	7	9	6	8	5	70%	83%
22	9	9	9	10	10	94%	8	8	6	1	8	62%	78%
23	9	7	9	6	7	76%	9	6	4	7	8	68%	72%
24	8	7	7	8	5	70%	10	9	8	4	10	82%	76%
25	6	10	10	9	10	90%	10	2	6	7	7	64%	77%
26	7	10	6	9	10	84%	7	7	10	6	6	72%	78%
27	10	8	7	9	8	84%	3	5	10	8	8	68%	76%
28	9	10	9	8	8	88%	7	3	6	6	8	60%	74%
29	7	10	10	10	8	90%	7	5	3	8	7	60%	75%
30	7	10	10	8	10	90%	4	4	4	8	3	46%	68%

Tabla 3 Matriz de resultados con Red Patterns

Referencias

David Hunter, H. Y. (2012). Selection of proper neural network sizes and architectures. *Transactions on Industrial Informatics*, 228-224.

Inc, T. m. (10 de 10 de 2017). Matlab user guide R2016B.

Madhav Mogantia, F. E. (1996). Automatic PCB Inspection algorithms: A Survey. *Computer Vision and Image Understanding*, 287-313.

R Hernández Grijalva, L. M. (2015). Red neuronal artificial para detección de partes por color con visión artificial en industria médica local. *ImasD*, 10.

Safaa L Diab, A. B. (2011). Designing a Visual Inspection System for Quality Characteristics Dimensions. *chanical Engineering Resear*, 12-23.

Saravanan, A. (2013). Artificial Neural Intelligent Visual Inspection for Process Improvement. *International Journal of Innovative Research & Development*, 768-778.

V. C. PATEL, R. W. (1998). Color Computer Vision and Artificial Neural Networks for Detection of Defects in Poultry Eggs. *Artificial Intelligence Review*, 163-176.

Agradecimientos

A la Delegación Sindical D-V-99 del ITN por el apoyo económico y de gestión para la publicación de este artículo; así como también a OOMAPAS de Nogales, Sonora, por complementar el monto requerido.