

Aplicación de una red neuronal artificial en el reconocimiento de figuras geométricas

Ivan Adrianzén Olano

<https://orcid.org/0000-0002-1910-2854>

ivan.adrianzen@untrm.edu.pe

Universidad Nacional Toribio Rodríguez de Mendoza
de Amazonas
Amazonas, Perú

Juan Elias Villegas Cubas

<https://orcid.org/0000-0001-7026-9767>

jvillegasc@unprg.edu.pe

Universidad Nacional Pedro Ruiz Gallo
Lambayeque, Perú

Hugo Vega Huertas

<https://orcid.org/0000-0002-4268-5808>

hvegah@unmsm.edu.pe

Universidad Nacional Federico Villarreal,
Lima, Perú.

Gisella Luisa Elena Maquen Niño

<https://orcid.org/0000-0002-9224-5456>

gluisamn@unprg.edu.pe

Universidad Nacional Pedro Ruiz Gallo
Lambayeque, Perú

Recibido (10/03/2022), Aceptado (09/05/2022)

Resumen.-El objetivo fue implementar una red neuronal artificial para mejorar el reconocimiento de figuras geométricas que permita posteriormente, hacer estimaciones sobre formas en un contexto real para crear planos virtuales. Se desarrolló un programa en Matlab para crear la red neuronal y se desarrolló dos bases de conocimiento que contienen quince figuras geométricas diferentes para la etapa de entrenamiento y para la etapa de reconocimiento. Los resultados de la fase de entrenamiento se realizaron en tres procesos obteniéndose porcentaje de 11.35%, 3.55% y 2% de margen error respectivamente, posteriormente vino la etapa de reconocimiento con tres procesos, obteniéndose 40%, 100% y 100% figuras reconocidas respectivamente. Se concluye que, la red neuronal implementada realizó el reconocimiento de quince figuras geométricas (100%) de forma acertada necesitando tres procesos de entrenamiento y tres procesos de reconocimiento para constatar su aprendizaje.

Palabras clave: Reconocimiento de imágenes, Aprendizaje Máquina, redes neuronales artificiales, inteligencia artificial

Application of an artificial neural network in the recognition of geometric figures

Abstract.- The objective was to implement an artificial neural network to improve the recognition of geometric figures that later allow making estimates about shapes in a real context to create virtual planes. A Matlab program was developed to create the neural network and two knowledge bases containing fifteen different geometric figures that were developed for the training stage and for the recognition stage. The results of the training phase were carried out in three processes, obtaining a percentage of 11.35%, 3.55% and 2% of error margin respectively, later came the recognition stage with three processes, obtaining 40%, 100% and 100% figures recognized respectively. It is concluded that the implemented neural network performed the recognition of fifteen geometric figures correctly (100%), requiring three training processes and three recognition processes to verify their learning.

Keywords: Image recognition, Machine learning, artificial neural networks, artificial intelligence.

I. Introducción.

La Red Neuronal Artificial es un programa informático que busca simular el funcionamiento de las neuronas biológicas utilizando funciones matemáticas que permita la inhibición o activación de estímulos a través del ingreso de valores de entrada [1].

La visión artificial es un campo de investigación de inteligencia artificial que hace uso de diferentes algoritmos, técnicas y métodos, logrando el procesamiento de la información contenida en imágenes digitales de objetos [2].

La red neuronal artificial y la visión artificial convergen para poder ayudar en el reconocimiento de imágenes de forma automatizada. Esto puede ser requerido para poder diseñar planos virtuales de forma automatizada en espacios físicos pertenecientes a una institución gubernamental, que ayudarían a mejorar la ubicación de los usuarios, localizando diversas oficinas y áreas. Pero para poder realizarlo se requiere primero desarrollar habilidades visomotoras que permitan el aprendizaje espacial dentro de un plano.

Existe entonces la necesidad de enseñar a estimar formas, tal y como se hace con un niño en los primeros años de edad escolar, que se comienza por la identificación de figuras geométricas, para posteriormente, calcular espacios y ayudarse en el desplazamiento.

Para el reconocimiento de figuras geométricas, y en general, de cualquier tipo de imágenes, se puede utilizar aprendizaje máquina, rama de la inteligencia artificial que hace uso de algoritmos para identificar patrones de un conjunto de datos. Dentro de los tipos de aprendizaje tenemos el aprendizaje supervisado, no supervisado y por refuerzo. El aprendizaje supervisado se caracteriza porque se tiene previamente conocimiento de un conjunto de etiquetas asociados a los datos, El aprendizaje no supervisado los datos no tienen etiquetas y el objetivo es encontrar patrones para organizar los datos, el aprendizaje por refuerzo busca que se aprenda de la experiencia con proceso de prueba error [3]. De estos tipos de aprendizaje para la presente investigación se realizará el aprendizaje supervisado con el uso de una red neuronal artificial que a través del proceso de entrenamiento logre el reconocimiento de figuras geométricas.

Esta razón despertó el interés para realizar la presente investigación y se planteó como propósito implementar una red neuronal artificial que permita la identificación de objetos simples como son figuras geométricas, lo cual sentará la base para futuras investigaciones donde se requiera a partir de una imagen poder desarrollar un plano virtual de ese espacio físico en forma automatizada.

II. Desarrollo

A. Concepto de Red Neuronal

Se debe definir el concepto de red neuronal artificial (RNA) como aquellos elementos software compuestas de nodos o unidades de proceso relacionadas a través de conexiones dirigidas. Además, cada conexión tiene un peso numérico asociado, que determina la fuerza y el signo de la conexión [4]. Las RNA tratan de imitar el comportamiento de sus pares biológicas, aunque de manera artificial, para ello, modelan matemáticamente dicho comportamiento, como lo hace el cerebro humano [5].

B. Modelos de Red Neuronal

Existen múltiples modelos de redes neuronales, que han ido evolucionando a lo largo del tiempo, entre los ampliamente utilizados están el modelo perceptrón [6], que actúa como discriminador lineal, posteriormente apareció el sistema backpropagation [7] donde se busca ajustar los pesos de cada neurona con la finalidad de minimizar el error; el algoritmo de backpropagation ayuda a determinar la culpabilidad de error (mediante ponderación) de cada neurona de la última capa y lo va propagando hacia atrás determinando la culpabilidad de cada neurona de la red.

Actualmente encontramos modelos más avanzados como el modelo Hopfield que tiene un mecanismo de aprendizaje offline que el proceso de funcionamiento de la red inicializa cuando el proceso de aprendizaje ha concluido, evitándose así darse en forma paralela.

La red Hopfield se da en dos etapas: La primera es el entrenamiento, en donde se alimenta a la red neuronal con un conjunto de patrones que tiene que memorizar o almacenar y la segunda parte es el reconocimiento, que consiste en inicializar como entrada patrones diferentes a los del entrenamiento, y a partir de esas entradas la red neuronal deberá reconocer los nuevos patrones propagando la red hasta estabilizarse, en caso no encuentre coincidencias deberá devolver como salida la información más parecida de lo que se ha entrenado [8].

C. Antecedentes de la Investigación

Las redes neuronales se aplican en la identificación y selección de objetos o imágenes, como la identificación de patrones en un conjunto de datos. Están siendo utilizadas en diversos campos de la actividad humana en la agricultura para poder distinguir los tipos de plagas que presentan los sembríos a partir del color forma y aspecto de las hojas y tallos de las plantas, utilizando redes neuronales que permitan identificar patrones de las fotos de alta resolución tomadas a los sembríos.

También son utilizadas en la clasificación de productos tales como el café [9], que a través de imágenes tomadas con una cámara web, se procesan y se extraen sus características, que serán datos de entrada a una red neuronal que permita clasificar el café maduro o café verde, alcanzando una efectividad del 97% en la detección del grado de madurez del fruto del café, demostrando que la red neuronal es un método viable y poco invasivo en la clasificación del café.

Igualmente es utilizado para la clasificación de productos exportables como la manzana, mandarinas, dátiles, mangos y otros productos exportables en Perú. Teniendo como indicadores de clasificación, el color como principal característica de inspección. "En el caso de las manzanas, una investigación tomó tres indicadores de selección: el área no defectuosa, manchas como parches y manchas alargadas, dando como precisión de la clasificación el 96.6%" [10]. En otra investigación, relacionadas también a clasificación de manzanas de exportación, se diseñaron dos redes neuronales, "una considera el color sobre toda la superficie de la manzana y de acuerdo a eso la clasifica, y la otra identifica cualquier parte de la superficie de la manzana para obtener magulladuras y luego da la clasificación final" [11]. Otra investigación se refirió a la clasificación del mango de exportación, dentro de las dificultades encontradas, es que no solo se debía ceñir al color o magulladuras en la fruta, sino también la forma de la fruta ya que es una de las características a tomar en cuenta para ver que el producto sea exportable [12].

También es utilizado para el reconocimiento de personas, de rostros, de emociones reflejadas en el rostro. Actualmente muchos de los celulares, cámaras web, cámaras fotográficas tienen algoritmos de inteligencia artificial. Se puede implementar una red neuronal sobre una unidad de procesamiento gráfico (GPU) para resolver un problema de reconocimiento facial que consiste en decidir hacia donde apunta la cara de una persona en una imagen, alcanzando un nivel de acierto del 85% [14].

También se utilizan en la reconstrucción tridimensional de objetos, a través de imágenes o videos en alta definición, poder reconstruir el objeto real en tres dimensiones, encontrando como una gran dificultad el reconocimiento de las esquinas, utilizando los modelos de perceptrón multicapa (MLP) y redes de base radial (RBF) como los modelos más adecuados para poder implementarla, habiendo la necesidad de evaluar múltiples alternativas en los conjuntos de datos y las técnicas de entrenamiento, hasta encontrar el modelo correcto al problema a resolver [15].

D. Estructura de la Red Neuronal

Las neuronas se modelan mediante unidades de proceso, que se compone de una red de conexiones de entrada, una función de red (de propagación), encargada de computar la entrada total combinada de todas las conexiones, un núcleo central de proceso, encargado de aplicar la función de activación, y la salida, por dónde se transmite el valor de activación a otras unidades [16].

Independientemente del modelo, la estructura de una red neuronal consta de cuatro elementos básicos: Un conjunto de conexiones, establecidas por pesos. Estas conexiones pueden realizar la función excitadora (valores positivos) o inhibidora (valores negativos). Un sumador, que haya el promedio ponderado de las entradas multiplicadas por los pesos. Una función de activación que ayuda a limitar los valores de salida. Un umbral que es una constante encima de la cual la neurona se activa [17].

Según sea el modelo de red neuronal elegido, tendrá mayor número de componentes, múltiples conexiones, mayor número de capas, que permitan dar una respuesta adaptable al contexto en donde se desenvuelven.

Para la presente investigación se implementó la red neuronal con una capa de entrada con 225 neuronas que permite el ingreso de una figura geométrica desde un archivo txt representado una matriz de 15x15; una capa intermedia de 150 neuronas y una capa de salida con 4 neuronas que permite clasificar a la figura geométrica en cualquiera de las 3 clases (triángulo, cuadrado o rectángulo) y una de control para una clase no reconocida como se muestra en la Figura 1.

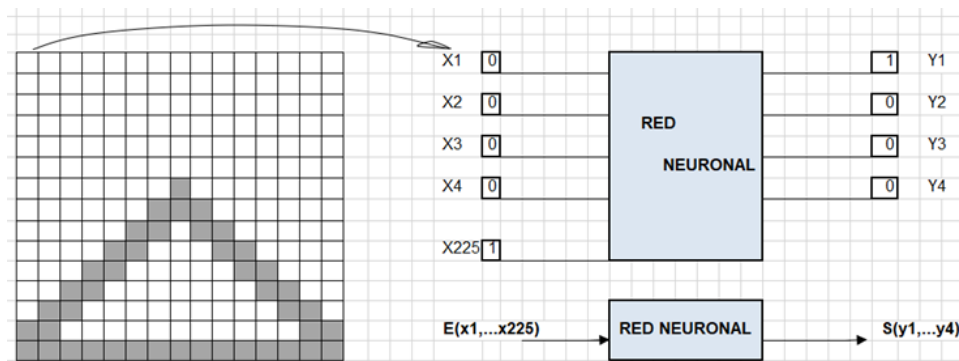


Fig. 1. Estructura de la red neuronal

III. Metodología

Se utilizó el método de simulación, mediante el uso de un software informático se simuló la actividad de una red neuronal para que pueda entrenarse y reconocer figuras geométricas.

La técnica fue la Observación experimental que posibilita confrontar el estudio teórico desarrollado con la práctica [18]. Los Materiales utilizados en la investigación son los registros de anotaciones donde se escriben los resultados obtenidos en cada proceso de entrenamiento, así como los valores de salida obtenidos por la red neuronal en cada proceso de reconocimiento.

También se hizo uso del software Matlab R2014 para codificar el programa informático de la red neuronal artificial siguiendo el ejemplo de red neuronal propuesto por Gilat [19].

La red Neuronal creada sigue el modelo Back propagation que es ampliamente utilizada en el reconocimiento de patrones e imágenes. [20].

El software ofimático Microsoft Excel fue usado para poder realizar la base de conocimiento de la etapa de entrenamiento y la base de conocimiento de la etapa de reconocimiento. También se utilizó para poder leer los valores de salida de la red neuronal y determinar si se realizó un acertado reconocimiento de las figuras geométricas. El procedimiento seguido para realizar las dos bases del conocimiento fue el siguiente:

Para poder alimentar a la red neuronal (ingresar datos de entrada) se diseñaron 5 figuras geométricas de cada tipo: triángulo, rectángulo y cuadrado, siendo 15 figuras en total. A cada figura geométrica se le hizo un mapeo de 15 x 15 pixeles (15 columnas y 15 filas), dando valores digitales (0 o 1), donde 0 indica que no es parte del borde, es decir la celda está sin sombrear y 1 indica que la celda es parte del borde, formándose cadenas de valores de 225 caracteres que serían los valores de entrada de la base de conocimiento.

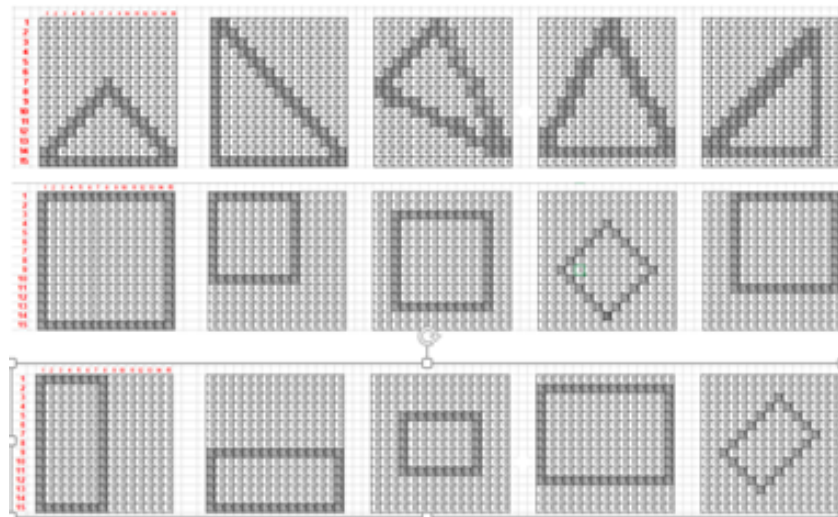


Fig. 2. Diseño de figuras geométricas para la etapa de entrenamiento

Posteriormente, se agregó a la base de conocimiento las columnas de los valores de salida, que como son 3 figuras geométricas, fueron 3 columnas adicionales, más una salida de control. Y se agregó una fila adicional para los valores de control en caso de que no coincida con ninguno de los patrones de datos de las figuras anteriores. De esa forma la base de conocimiento para la etapa de entrenamiento tuvo 229 columnas y 16 filas.

	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X225	Y1	Y2	Y3	Y4
Triángulo 1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0
Triángulo 2	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0
Triángulo 3	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	1	0	0	0
Triángulo 4	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	1	0	0	0
Triángulo 5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
Cuadrado 1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	0	0
Cuadrado 2	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	1	0	0
Cuadrado 3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
Cuadrado 4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
Cuadrado 5	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	0	0	1	0	0
Rectángulo 1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	1	0
Rectángulo 2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0
Rectángulo 3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
Rectángulo 4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
Rectángulo 5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
Control	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	1

Fig. 3. Extracto de la Base de Conocimientos para la etapa de entrenamiento de la red neuronal

La base de conocimiento de la etapa de reconocimiento fue diseñada de la misma manera la de la etapa anterior, se diseñaron 5 figuras geométricas de cada tipo: triángulo, rectángulo y cuadrado, siendo 15 figuras en total, diferentes a las figuras geométricas de la base de entrenamiento. A cada figura geométrica se le hizo un mapeo de 15 x 15 pixeles formándose cadenas de valores de 225 caracteres.

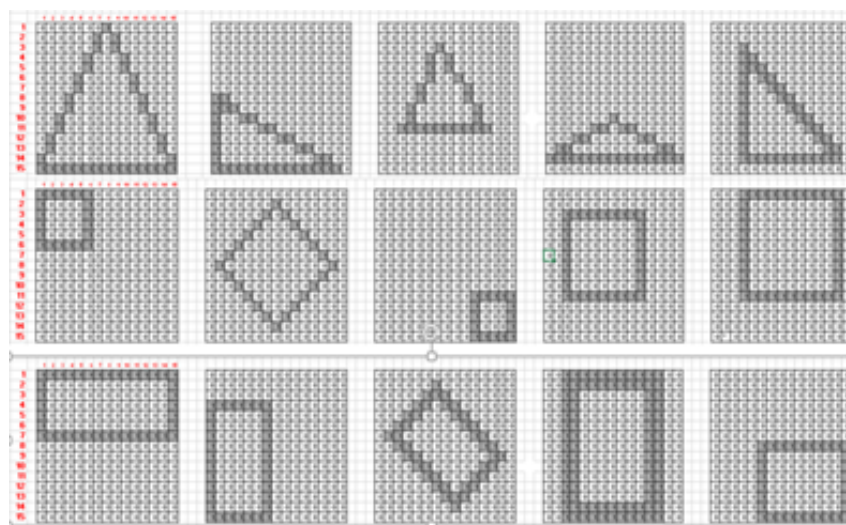


Fig. 4. Diseño de figuras geométricas para la etapa de reconocimiento

Posteriormente, se agregó a la base de conocimiento las cuatro columnas de los valores de salida tres de las figuras geométricas más una salida de control. Y se agregó una fila adicional para los valores de control. De esa forma la base de conocimiento para la etapa de reconocimiento tuvo 229 columnas y 16 filas.

	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X225	Y1	Y2	Y3	Y4
Triángulo 1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1	1	1	1	1
Triángulo 2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
Triángulo 3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
Triángulo 4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
Triángulo 5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
Cuadrado 1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	1	1	1	1
Cuadrado 2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
Cuadrado 3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1
Cuadrado 4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
Cuadrado 5	0	0	0	1	1	1	1	1	1	1	1	1	1	1	0	0	1	1	1	1
Rectángulo 1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1
Rectángulo 2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
Rectángulo 3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
Rectángulo 4	0	0	1	1	1	1	1	1	1	1	1	1	1	0	0	0	1	1	1	1
Rectángulo 5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1

Fig. 5. Extracto de la Base de Conocimientos para la etapa de reconocimiento de la red neuronal

Cuando terminó la fase de reconocimiento, se obtuvieron valores de salida de la red neuronal, los cuales fueron copiados a Microsoft Excel para su análisis y así poder determinar si se realizó un acertado reconocimiento de las figuras geométricas.

IV. Resultados

En la etapa de entrenamiento de la red neuronal se realizó tres procesos de entrenamiento.

En el primer proceso de entrenamiento se le introdujo como máximo porcentaje de error 15% y 200 repeticiones (iteraciones). Los datos de entrada que se dio a la red neuronal en el primer proceso de entrenamiento son:

Introducir nombre de archivo con data: CONOCI.txt

Número de entradas: 225

Número de salidas: 4

Número de paquetes de datos entrada-salida: 16

Introducir neuronas en capa intermedia: 150

Considera Neurona bias: Si

Introducir ratio de aprendizaje: 0.01

Introducir el valor máximo del error (%): 15

Introducir el máximo de iteraciones de aprendizaje: 200

Introducir nombre del archivo donde se guardará información de la red: figuras1.prn

Después de haber ejecutado el programa, se obtuvo la curva de aprendizaje, donde se puede observar que el proceso de entrenamiento alcanzó el objetivo esperado de tener un margen de error del 15%, ya que en la iteración 20 el porcentaje de error alcanzó el 11.35%.

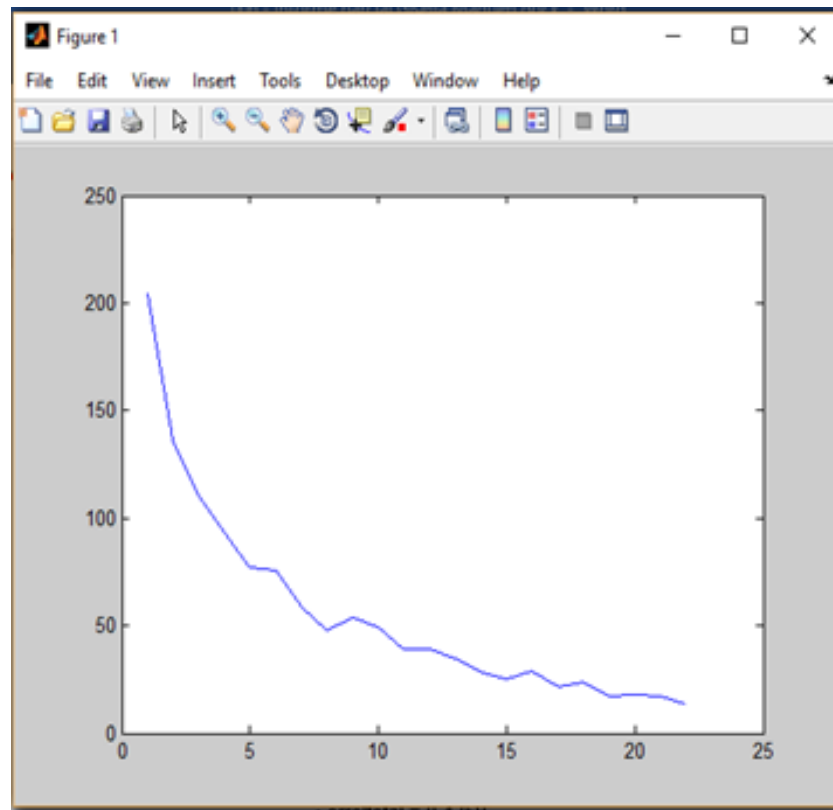


Fig. 6. Evolución del margen de error de la red neuronal en el primer proceso de entrenamiento

En el segundo entrenamiento se le introdujo como máximo porcentaje de error 5% y 200 repeticiones (iteraciones). Los datos de entrada que se dio a la red neuronal en el segundo proceso de entrenamiento son:
Introducir nombre de archivo con data: CONOCI.txt

Numero de entradas : 225

Numero de salidas : 4

Numero de paquetes de datos entrada-salida: 16

Introducir nombre de archivo con información de la red: figuras1.prn

Numero de neuronas en capa intermedia : 150

Neurona bias en capa de entrada (1:SI) (0:NO) : 1

Introducir ratio de aprendizaje : 0.005

Introducir el valor máximo del error (%) : 5

Introducir el máximo número de iteraciones de aprendizaje : 200

Introducir nombre del archivo donde se guardará información de la red:figuras2.prn

Después de haber ejecutado el programa, se obtuvo la curva de aprendizaje, donde se puede observar que el proceso de entrenamiento alcanzó el objetivo esperado de tener un margen de error del 5%, ya que aproximadamente a la tercera iteración alcanzó el porcentaje de 3.55%.

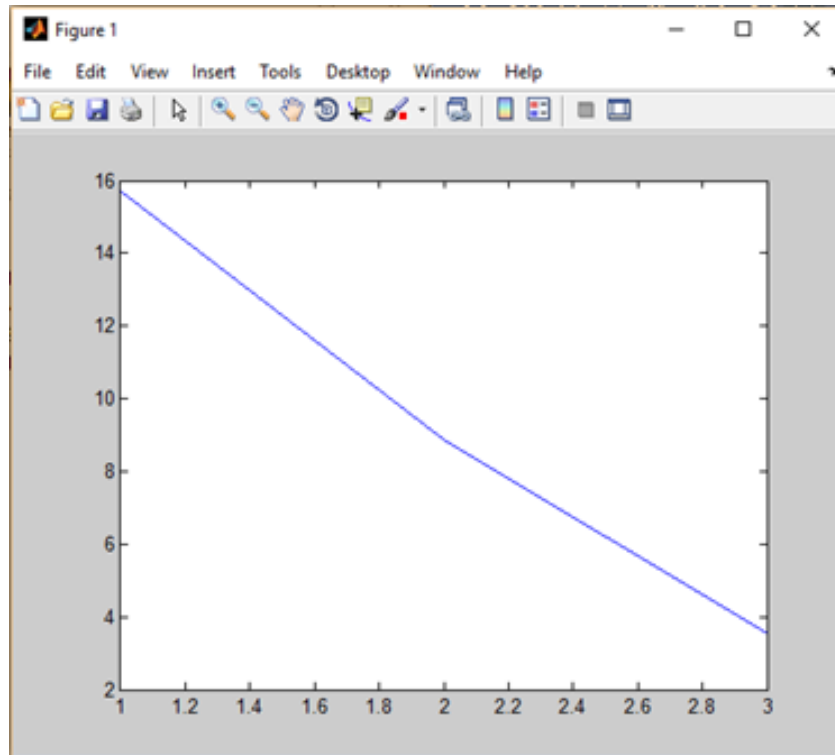


Fig. 7. Evolución del margen de error de la red neuronal en el segundo proceso de entrenamiento

En el tercer y último entrenamiento se le introdujo como máximo porcentaje de error 2% y 200 repeticiones (iteraciones). Los datos de entrada que se dio a la red neuronal en el segundo proceso de entrenamiento son:
Introducir nombre de archivo con data: CONOCI.txt

Número de entradas : 225

Numero de salidas: 4

Numero de paquetes de datos entrada-salida: 16

Introducir nombre de archivo con información de la red: figuras2.prn

Numero de neuronas en capa intermedia : 150

Neurona bias en capa de entrada (1:SI) (0:NO) : 1

Introducir ratio de aprendizaje : 0.0005

Introducir el valor máximo del error (%) : 2

Introducir el máximo número de etapas de aprendizaje : 200

Introducir nombre del archivo donde se guardará información de la red:figuras3.prn

Después de haber ejecutado el programa, se obtuvo la curva de aprendizaje, donde se puede observar que el proceso de entrenamiento alcanzó el objetivo esperado de tener un margen de error del 2%, ya que aproximadamente en la iteración 70 alcanzó el porcentaje.




Fig. 8. Evolución del margen de error de la red neuronal en el tercer proceso de entrenamiento

Posteriormente se realizó la etapa de reconocimiento de la red neuronal con 5 imágenes diferentes para cada tipo de figuras geométricas: triángulo, cuadrado y rectángulo, creándose otra base de conocimiento llamada RECO.txt con 229 columnas y 16 filas que tenía los valores digitales de las nuevas figuras geométricas a reconocer. Se realizaron tres procesos de reconocimiento, siendo el primero desfavorable, el segundo de reentrenamiento y el tercer proceso favorable.

En el primer proceso de reconocimiento se le pidió a la red neuronal que reconociera las figuras geométricas diseñadas en la base de reconocimiento RECO.txt utilizando el aprendizaje realizado en la etapa de entrenamiento cuyos parámetros se encontraban en el archivo figuras3.prn, pidiéndole a la red neuronal que tuviera como máximo porcentaje de error 5%.

Los datos de entrada que se le introdujeron a la red neuronal en el primer proceso de reconocimiento son:

Introducir nombre de archivo con data: RECO.txt

Número de entradas : 225

Numero de salidas : 4

Numero de paquetes de datos entrada-salida: 16

Introducir nombre de archivo con información de la red: figuras3.prn

Numero de neuronas en capa intermedia : 150

Neurona bias en capa de entrada (1:SI) (0:NO) : 1

Introducir el valor máximo del error (%) : 5

Introducir el máximo número de iteraciones de aprendizaje : 100

Introducir nombre del archivo donde se guardará información de la red: pruebarec.prn

Al finalizar el reconocimiento, se analizaron los valores de salida a través del comando output de Matlab, y al ser analizados en Excel se pudo comprobar que solo reconocía a 6 figuras geométricas de las 15 que se le había pedido que reconociera, no llegando a alcanzar el objetivo propuesto.

Entrada	1	2	3	4	Salida
Triangulo	0	0	0	-1	4
Triangulo	1	-1	2	0	1
Triangulo	-1	-1	1	-1	3
Triangulo	0	-1	1	1	3
Triangulo	1	-1	0	0	1
Cuadrado	-1	-1	1	-1	3
Cuadrado	-1	0	0	0	4
Cuadrado	0	-1	0	0	4
Cuadrado	0	1	-2	-2	2
Cuadrado	-1	0	2	-2	4
Rectángulo	-1	-1	-1	0	4
Rectángulo	-1	-2	1	-1	3
Rectángulo	-1	0	1	-1	3
Rectángulo	0	0	2	-1	4
Rectángulo	0	0	1	-1	3
	0	0	0	1	4

Fig. 9. Análisis de los valores de salida de la red neuronal en el primer proceso de reconocimiento

Al verificar que el resultado no era el óptimo, se agregó al final del primer archivo de entrenamiento (CONOCI.txt) los patrones no reconocidos de la base del conocimiento para la etapa de reconocimiento (RECO.txt), creando una nueva base de conocimiento que contenía 229 columnas con 31 filas (RECO2.txt), que era el resultado de unir las dos bases del conocimiento anteriormente mencionadas para volver a entrenar a la red neuronal, buscando obtener una red más entrenada que luego pudiera reconocer con facilidad los patrones no reconocidos actuales.

En el segundo proceso de reconocimiento se le pidió a la red neuronal que volviera a entrenar con la base de conocimiento RECO2.txt utilizando el aprendizaje realizado en el primer proceso de reconocimiento cuyos parámetros se encontraban en el archivo prueba-rec.prn, pidiéndole a la red neuronal que tuviera como máximo porcentaje de error 3%.

Los datos de entrada que se le introdujeron a la red neuronal en el segundo proceso de reconocimiento son:

Introducir nombre de archivo con data: RECO2.txt

Número de entradas : 225

Número de salidas: 4

Numero de paquetes de datos entrada-salida: 31

Introducir nombre de archivo con información de la red: prueba-rec.prn

Numero de neuronas en capa intermedia : 150

Neurona bias en capa de entrada (1:SI) (0:NO) : 1

Introducir ratio de aprendizaje : 0.02

Introducir el valor máximo del error (%) : 3

Introducir el máximo número de iteraciones de aprendizaje : 70

Introducir nombre del archivo donde se guardará información de la red: pruebarec2.prn

En el segundo proceso de reconocimiento la red neuronal llegó a alcanzar un porcentaje de error de 2.75% al finalizar el reconocimiento mucho menor que el propuesto que fue de 3%, valor que indicaba que la red había reconocido las figuras geométricas propuestas. En este proceso se realizó la identificación de las quince figuras geométricas, sin embargo, fue con una nueva base del conocimiento que salió de unir la del entrenamiento con la de reconocimiento. Habría que constatar si con la base de conocimiento original del reconocimiento, se obtiene los mismos resultados para constatar que la red neuronal aprendió de su experiencia.

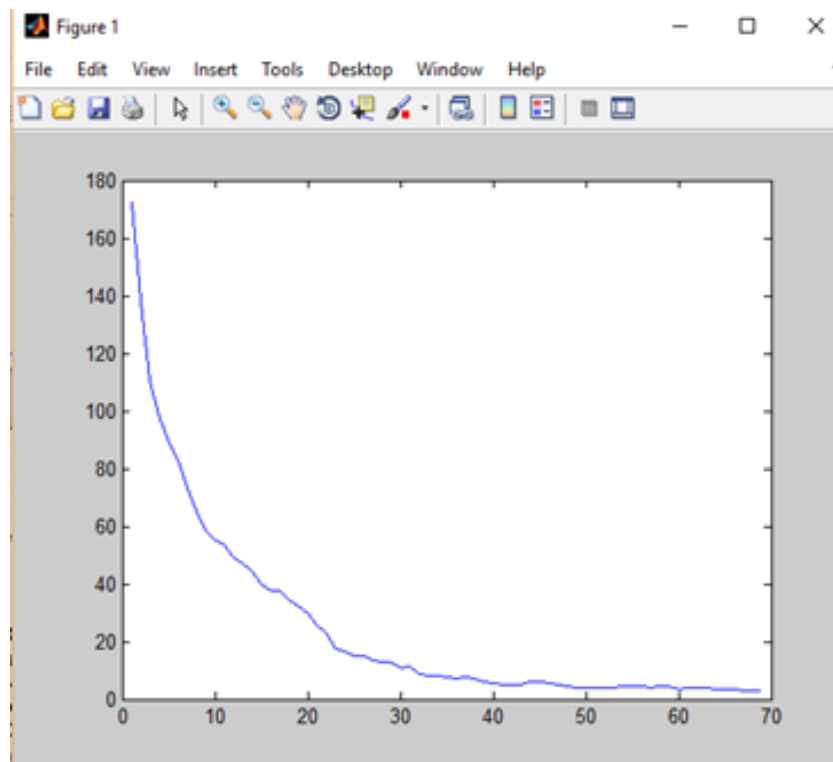


Fig. 10. Evolución del margen de error de la red neuronal en el segundo proceso de reconocimiento

En el tercer y último proceso de reconocimiento, se le pidió a la red neuronal que reconociera las figuras geométricas diseñadas en la base de reconocimiento original RECO.txt utilizando el aprendizaje realizado en el segundo proceso de reconocimiento cuyos parámetros se encontraban en el archivo pruebarec2.prn, pidiéndole a la red neuronal que tuviera como máximo porcentaje de error 0% con solo dos iteraciones.

Los datos de entrada que se le introdujeron a la red neuronal en el tercer proceso de reconocimiento son:
Introducir nombre de archivo con data:RECO.txt

Número de entradas : 225

Número de salidas : 4

Numero de paquetes de datos entrada-salida: 16

Introducir nombre de archivo con información de la red: pruebarec2.prn

Numero de neuronas en capa intermedia : 150

Neurona bias en capa de entrada (1:SI) (0:NO) : 1

Introducir ratio de aprendizaje : 0.02

Introducir el máximo número de iteraciones de aprendizaje : 2

Introducir nombre del archivo donde se guardará información de la red: -pruebarec3.prn

Al finalizar el reconocimiento, se analizaron los valores de salida a través del comando output de Matlab, y al ser analizados en Excel se pudo comprobar que reconoció a las 15 figuras geométricas, es decir se cumplió el objetivo al 100%.

Entrada	1	2	3	4	Salida
Triangulo	1	0	0	0	1
Triangulo	1	0	0	0	1
Triangulo	1	0	0	0	1
Triangulo	1	0	0	0	1
Triangulo	1	0	0	0	1
Cuadrado	0	1	0	0	2
Cuadrado	0	1	0	0	2
Cuadrado	0	1	0	0	2
Cuadrado	0	1	0	0	2
Cuadrado	0	1	0	0	2
Rectángulo	0	0	1	0	3
Rectángulo	0	0	1	0	3
Rectángulo	0	0	1	0	3
Rectángulo	0	0	1	0	3
Rectángulo	0	0	1	0	3
	0	0	0	1	4

Fig.11. Análisis de los valores de salida de la red neuronal del tercer proceso de reconocimiento

Conclusiones

Se necesitaron tres procesos de entrenamiento con 200 iteraciones cada uno, obteniéndose en el primer proceso un margen de error de 11.35%, en el segundo proceso se obtuvo 3.55% y el último proceso se obtuvo un margen de error de 2% respectivamente.

Posteriormente se realizaron tres procesos de reconocimiento, obteniendo en el primer proceso el reconocimiento de 6 figuras (40%), en el segundo 15 figuras (100%) y en el tercero 15 figuras (100%) respectivamente, siendo necesario realizar el tercer proceso de reconocimiento con su base de conocimiento original. Es por tanto necesario realizar varias etapas de reconocimiento para constatar que la red neuronal ha aprendido de sus errores y aciertos, utilizando su base de conocimiento original en su etapa de reconocimiento.

Se concluye que, la red neuronal implementada realizó el reconocimiento de quince figuras geométricas de forma acertada lo que constituye el 100% de las figuras geométricas propuestas.

Recomendaciones

Se deben buscar nuevos algoritmos que permitan automatizar el mapeo de las imágenes que configuran los valores de entrada de la red neuronal para que sean homogéneos, en la presente investigación, que las figuras geométricas tengan el mismo borde.

Referencias

- [1] R. Flórez y J. Fernández., *Las Redes Neuronales Artificiales: Fundamentos Teóricos y Aplicaciones Prácticas*, España: Netbiblo, 2006.
- [2] J. L. Ramirez Arias, A. Rubiano Fonseca y R. Jimenez Moreno, «Object Recognition Through Artificial Intelligence Techniques,» *Revista Facultad de Ingeniería*, 2020.
- [3] L. Sandoval, «ALGORITMOS DE APRENDIZAJE AUTOMÁTICO PARA ANÁLISIS Y PREDICCIÓN DE DATOS,» *ITCA-FEPADE*, vol. 11, nº 36-40, 2018.
- [4] S. J. Russell y P. Norvig, *Inteligencia artificial: un enfoque moderno*, 2da Ed. ed., Nueva York: Pearson Education, 2004, p. 1212.
- [5] G. Cheng y X. Dong, «From Chaos to Order: Methodologies, Perspectives, and Applications,» World Scientific, 1198.
- [6] F. Rosenblatt y C. Laboratory, *The perptron: a theory of statistical separability in cognitive systems (Project Para)*. Cornell Aeronautical Laboratory, 1958.
- [7] P. Werbos, «The Roots of Backpropagation: From Ordered Derivatives to Neural Networks and Political Forecasting,» 1994.
- [8] I. A. Ruge Ruge y J. D. Alvarado, «Sistema basado en FPGA para la evaluación de redes neuronales orientadas al reconocimiento de imágenes,» *Tecnura*, vol. 17, nº 36, 2013.
- [9] J. C. Herrera Perez, S. M. Medina Ortiz, G. E. Martinez LLanos, K. d. J. Beleño Saenz y J. S. Berrio Perez, «Clasificación de los frutos de café según su estado de maduración y detección de la broca mediante técnicas de procesamiento de imágenes,» *Prospectiva*, pp. 15-22, 2016.
- [10] Q. Yang, «Classification of apple surface features using machine vision and neural networks,» *Computers and Electronics in Agriculture*, vol. 1, nº 9, pp. 1-12, 1993.
- [11] K. Nakano, «Application of neural networks to the color grading of apples,» *Computers and Electronics in Agriculture*, vol. 3, nº 18, pp. 105-116, 1997.
- [12] H. F. Vega Huertas, «Redes neuronales para el reconocimiento de la calidad morfológica de mangos exportables para la empresa Biofruit del Perú S.A.C.,» Lima, 2011.
- [13] H. P. Chan, S. C. B. Lo, B. Sahiner, K. Lam y M. Helvie, «Computer-aided detection of mammographic microcalcifications: Pattern recognition with an artificial neural network,» *Med. Phys.*, nº 22, pp. 1555-1567, 1995.
- [14] J. P. Balarini, S. Nesmachnow y M. Rodríguez, «Recognition Using Neural Networks over GPU,» *CLEI Electronic Journal*, vol. 15, nº 3, 2012.
- [15] H. d. J. Mesa Yepes, J. W. Brancha Bedoya y C. Lopez Amaya, «Sistema de detección de esquinas en imágenes digitales en tonos de gris, basado en redes neuronales artificiales,» *Revista Avances en Sistemas e Informática*, pp. 195-200, 2008.
- [16] R. Pino, A. Gómez y N. Abajo, *Introducción a la Inteligencia Artificial: Sistemas Expertos, Redes Neuronales Artificiales y Computación Evolutiva*, España: Universidad de Oviedo, 2001.
- [17] G. A. Figueredo Avila y J. A. Ballesteros Ricaurte, «Identificación del estado de madurez de las frutas con redes neuronales artificiales, una revisión,» *Revista Ciencia y Agricultura (Rev Cien Agri)*, vol. 13, nº 1, pp. 117-132, 2016.
- [18] R. Hernandez Sampieri, C. Fernández Collado y P. Baptista Lucio, «Metodología de la Investigación,» McGraw-Hill (4ta Ed.), México, 2008.
- [19] A. Gilat, *Matlab. Una introducción con ejemplos prácticos*, Barcelona: Revertè S.A., 2005.
- [20] J. González, J. Lez, M. Coaut y V. Hernando, *Redes neuronales artificiales: Fundamentos, modelos y aplicaciones,* Addison-Wesley Iberoamericana, , 1995.
- [21] E. Cabello Pardos, «Técnicas de reconocimiento facial,» 2012.
- [22] J. Carrasco Ochoa y J. Martinez Trinidad, «Reconocimiento de patrones,» *Komputer Sapiens*, pp. 5-9, 2011.
- [23] T. Morimoto y Y. Hashimoto, «An intelligent control for greenhouse automation, oriented by the concepts of SPA and SFA - an application to a post-harvest process,» *Computers and Electronics in Agriculture*, pp. 179-194, 2000.

Los autores



Ivan Adrianzen Olano

Maestro en Ciencias de la Educación con mención en Docencia y Gestión Universitaria. Estudios de Maestría en Ingeniería de Sistemas con mención en Sistemas de Información-Universidad Antenor Orrego, Trujillo. Filiación: Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas – Perú. E-mail: ivan.adrianzen@untrm.edu.pe, ORCID: <https://orcid.org/0000-0002-1910-2854>



Juan Elias Villegas Cubas

Ingeniero de Sistemas, Magister en Ingeniería de Sistemas, Doctor en Ciencias de la Computación y Sistemas. Docente nombrado en la Universidad Nacional Pedro Ruiz Gallo de Lambayeque – Perú, adscrito al Departamento Académico de Ingeniería de Sistema. E-mail: jvillegasc@unprg.edu.pe, ORCID: <https://orcid.org/0000-0001-7026-9767>



Hugo Vega Huertas

Doctor en Ingeniería de Sistemas y Magister en Administración, Catedrático en la Universidad Nacional Mayor de San Marcos - Lima - Perú. E-mail: hvegah@unmsm.edu.pe, ORCID: <https://orcid.org/0000-0002-4268-5808>



Gisella Luisa Elena Maquen Niño

Doctora en Ciencias de la Educación con mención en Administración de la Educación. Estudios de doctorado en Ciencias de la Computación y Sistemas, Universidad Señor de Sipán. Ingeniero en Computación e Informática, Universidad Pedro Ruiz Gallo. Filiación: Universidad Pedro Ruiz Gallo – Perú. E-mail: gmaquenn@unprg.edu.pe, ORCID: <https://orcid.org/0000-0002-9224-5456>.