

Diseño de un algoritmo para linealización y auto calibración de sensores mediante redes neuronales artificiales en sistemas de almacenamiento de papas

Design of an algorithm for linearization and auto-calibration of sensors using artificial neural networks in potato storage systems

Gilberto Bojorquez-Delgado¹, Jesús Bojorquez-Delgado¹, Manuel-Alfredo Flores-Rosales¹, Herbey-Daniel Payan-Suarez¹, Jesús Orlando Cazarez-Hernández¹

¹ Tecnológico Nacional de México – ITS Guasave, Sinaloa, México.

Recibido: 02-10-2021
Aceptado: 30-11-2021

Autor correspondal: gilberto.bd@guasave.tecnm.mx

Resumen

La aplicación de redes neuronales artificiales está cada vez más aceptada en la industria alimentaria para mejorar los procesos de producción y mejorar las técnicas de postcosecha, En el presente trabajo, se muestra el diseño de un módulo de adquisición de datos el cual implementa un algoritmo de auto calibración y linealización para sensores de temperatura en bodegas de papas. El módulo está basado en el microcontrolador ESP32 en el cual se implementó una red neuronal artificial perceptrón multicapa con 5 neuronas, y como algoritmo de entrenamiento se utilizó Backpropagation. Se generó un entrenamiento con datos obtenidos desde el sensor NTC10K y como referencia se utilizó el medidor de temperatura portátil CHT-BT601, se estableció un factor de aprendizaje $K = 0.5$, logrando una convergencia de 99.99 % en 100 épocas, lo cual ayuda a lograr calibraciones más rápidas y seguras para tener mayor certidumbre en las lecturas de temperatura y poder tener mejores condiciones en la conservación del tubérculo.

Palabras clave: Red neuronal, Almacenamiento de papa, ESP32.

Abstract

The application of artificial neural networks is increasingly accepted in the food industry to improve production processes and improve postharvest techniques. In this work, the design of a data acquisition module is shown which implements an algorithm of auto calibration and linearization for temperature sensors in potato warehouses. The module is based on the ESP32 microcontroller in which a multilayer perceptron artificial neural network with 5 neurons was implemented, and Backpropagation was used as a training algorithm. A training was generated with data obtained from the NTC10K sensor and the CHT-BT601 portable temperature meter was used as a reference, a learning factor $K = 0.5$ was established, achieving a convergence of 99.99% in 100 times, which helps to achieve faster and safer calibrations to have greater certainty in temperature readings and to have better conditions in the conservation of the tuber.

Keywords: Neural network, Potato storage, ESP32.

Introducción

La papa ocupa el quinto lugar en el mundo de cultivos con mayor producción, seguida del maíz, arroz, trigo y frijoles, se producen 385 millones de toneladas de papa en el mundo, siendo China el principal productor y luego India, Estados Unidos, Rusia y Alemania. México ocupa el puesto 31 en la producción mundial de este importante tubérculo, en nuestro país se cultivan alrededor de 68 mil hectáreas, de las cuales se extraen un total de 1.8 millones de toneladas con un valor de producción de 11,300 millones de pesos (Haro, 2019).

La papa es parte del sistema alimentario mundial y por eso la Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO) ha declarado 2008 Año Internacional de la Papa, considerándola el como base para futuro alimentario y un producto fundamental para la seguridad alimentaria en el mundo. (SISSAN, 2013).

Los tubérculos de papa son órganos de almacenamiento de plantas que generalmente contienen 80 % de líquido y 20% de masa. (Jerez, 2016).

Esta naturaleza rica en agua las hace muy susceptibles a daños durante la cosecha y el transporte, y la conservación tiene problemas diversos relacionados con los procesos biológicos y el entorno que la rodea, como la temperatura, la humedad, la ventilación y la iluminación. (Devaux, 2014).

Por la importancia del manejo postcosecha de papa, se requiere un control adecuado de las variables de almacenamiento sobre todo la temperatura, ya que juega un papel crítico en la conservación del tubérculo (Jerez, 2012), para ello se utilizan sensores resistivos para la detección de temperatura (Comar, 2016; Cabrera, 2016), Sin embargo, un problema que se presenta mucho en los sistemas de almacenamiento de papas son la falta de uniformidad en las temperaturas (Jerez, 2015), por lo cual se requiere la instalación de diversos sensores de temperatura en una misma bodega a través de redes distribuidas (Ahmad, Roslan y Amira, 2017; Baroudi, Bin-Yahya, Alshammari y Yaqoub, 2019), este tipo de redes aunque resultan una gran alternativa, también presenta un problema en la calibración del sensor (Liao, Zhu, Tang, y Zhang, 2016), ya que cada sensor tiene una resistencia interna diferente a pesar de ser el mismo modelo (Mezghani y Abdellaoui, 2015) o si es diferente modelo más diferente será la curva característica (Nuñez, Benítez, Rodríguez, Díaz y Oliveira, 2019), una alternativa muy utilizada para ajustar curvas de entrada o salida en sensores son modelos matemáticos de linealización (Zhang, Mehmood, Shu, Huo, Zhang y Mukherjee, 2018), el

problema de estas técnicas es que no es muy exacto cuando la curva es muy pronunciada, por lo cual un modelo muy utilizado para linealizar curvas son la utilización de redes neuronales artificiales (Ramírez y Chacón, 2011), Este trabajo presenta la implementación de algoritmo de auto calibración y linealización basado en una red neuronal perceptrón multicapa de 5 neuronas en un microcontrolador ESP32 como base de un módulo de adquisición de datos para temperara de bodegas de papa.

Materiales y métodos

De acuerdo con la necesidad de tomar datos confiables en tiempo real respecto a los sensores de temperatura para el almacenamiento de papas, se diseñó un módulo de adquisición de datos con un sistema de auto calibración y linealización basado en redes neuronales artificiales

El sistema consta de una red de módulos de adquisición de datos, interconectados a una red MODBUS que se encarga de recolectar y llevar a un controlador principal para tomar decisiones en el manejo de sistemas de ventilación. (Figura 1).

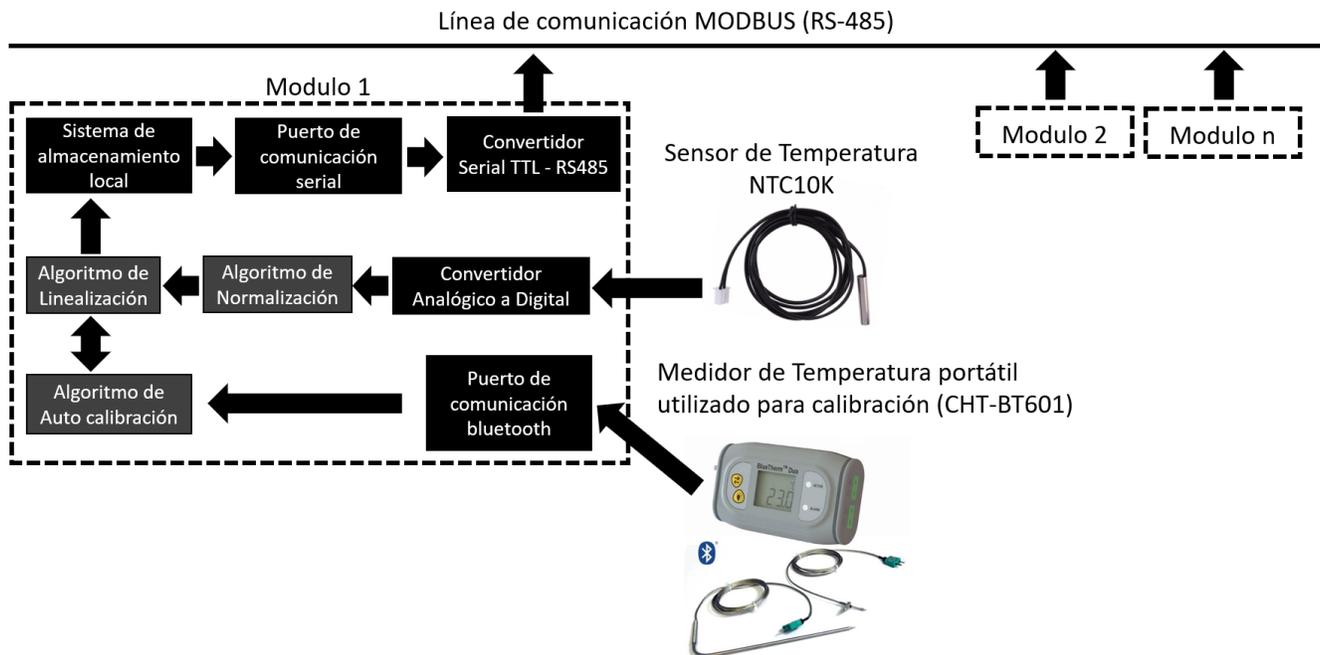


Figura 1. Sistema de red de módulos de adquisición de datos.

Hardware del módulo de adquisición de datos:

El hardware del módulo se basa en el microcontrolador ESP32, el nombre de una familia de chips SoC rentables y que consumen baja energía con tecnología WiFi y Bluetooth de modo dual integrado. El ESP32 utiliza un microprocesador Tensilica Xtensa LX6 en sus variantes de núcleo simple y doble, operando a 20 MHz y entregando hasta 600 DMIPS, e incluye interruptores de antena de alta frecuencia, amplificador de potencia, amplificador receptor de bajo ruido, filtros y módulos de administración de energía (Forero, 2020), puede observarse en la figura 2.

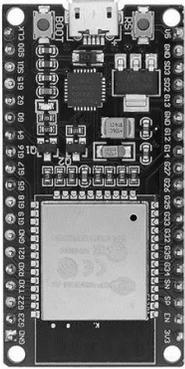


Figura 2. Microcontrolador ESP32.

Convertidor Analógico a Digital:

El microcontrolador ESP32 cuenta con un módulo de conversión Analógico a Digital que permite al Módulo de adquisición de datos obtener la señal proveniente del sensor de temperatura el cual cuantifica a una razón de 12-bit obteniendo 4096 niveles cuantificables en un buffer de datos de 1000 posiciones.

Puerto de Comunicación Bluetooth:

El módulo de adquisición de datos utiliza el puerto Bluetooth v4.2 BR/EDR y BLE que viene en el hardware del microcontrolador ESP32, por este medio se obtiene la temperatura del Medidor de Temperatura portátil (CHT-BT601), la cual es almacenada en un buffer intermedio que será utilizado para poder realizar la auto calibración.

Algoritmo de Normalización:

El algoritmo de normalización es utilizado para generar un segundo buffer a partir de la cuantización obtenida desde el convertidor Analógico a Digital, para obtener valores entre 0 y 1 y posteriormente poder alimentar el algoritmo de auto calibración.

El algoritmo consiste en recorrer y obtener el valor máximo del buffer de cuantización que es almacenado en la variable X_{max} , obtener el valor mínimo y almacenarlo en X_{min} y finalmente generar un segundo buffer normalizado donde se tomara cada dato del buffer de la cuantización y se aplicara el módulo matemático de las ecuación 1.

$$x = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Ecuación 1

Donde:

X = Tamaño de la muestra

X_{min} = Representa el valor mínimo en el vector de datos

X_{max} = Representa el valor máximo en el vector de datos

Algoritmo de Linealización y Autocalibración:

Se utilizó una red neuronal artificial multicapa como aproximación de funciones para ajustar la curva característica de calibración del sensor, es necesario conocer una muestra de datos para poder entrenar la red neuronal y a partir de un conjunto de entradas aportar la salida deseada, por eso es cómo se utilizan los datos de referencia obtenidos del termómetro a través de Bluetooth (Figueredo-Ávila, 2016). En lo figura 3 se presenta el diagrama de la estructura de la red neuronal artificial que cuenta con una capa oculta y una de salida, cada capa tendrá su propia matriz de pesos W , su propio vector de ganancias b , un vector de entradas X y un vector de salida Y . En esta red se toma como vector de entrada de la segunda capa al vector de salida de la primera.

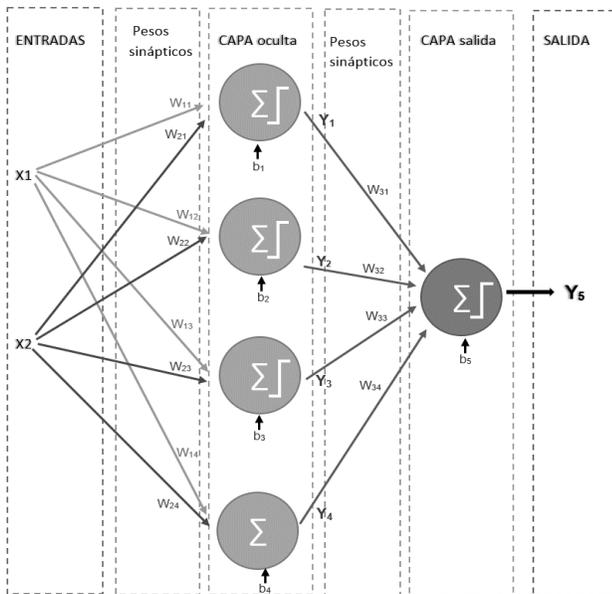


Figura 3. Arquitectura de la red neuronal artificial.

En lo figura 4 se muestra el diagrama de flujo del algoritmo que se diseñó, este proceso se explica más adelante con mayor detalle.

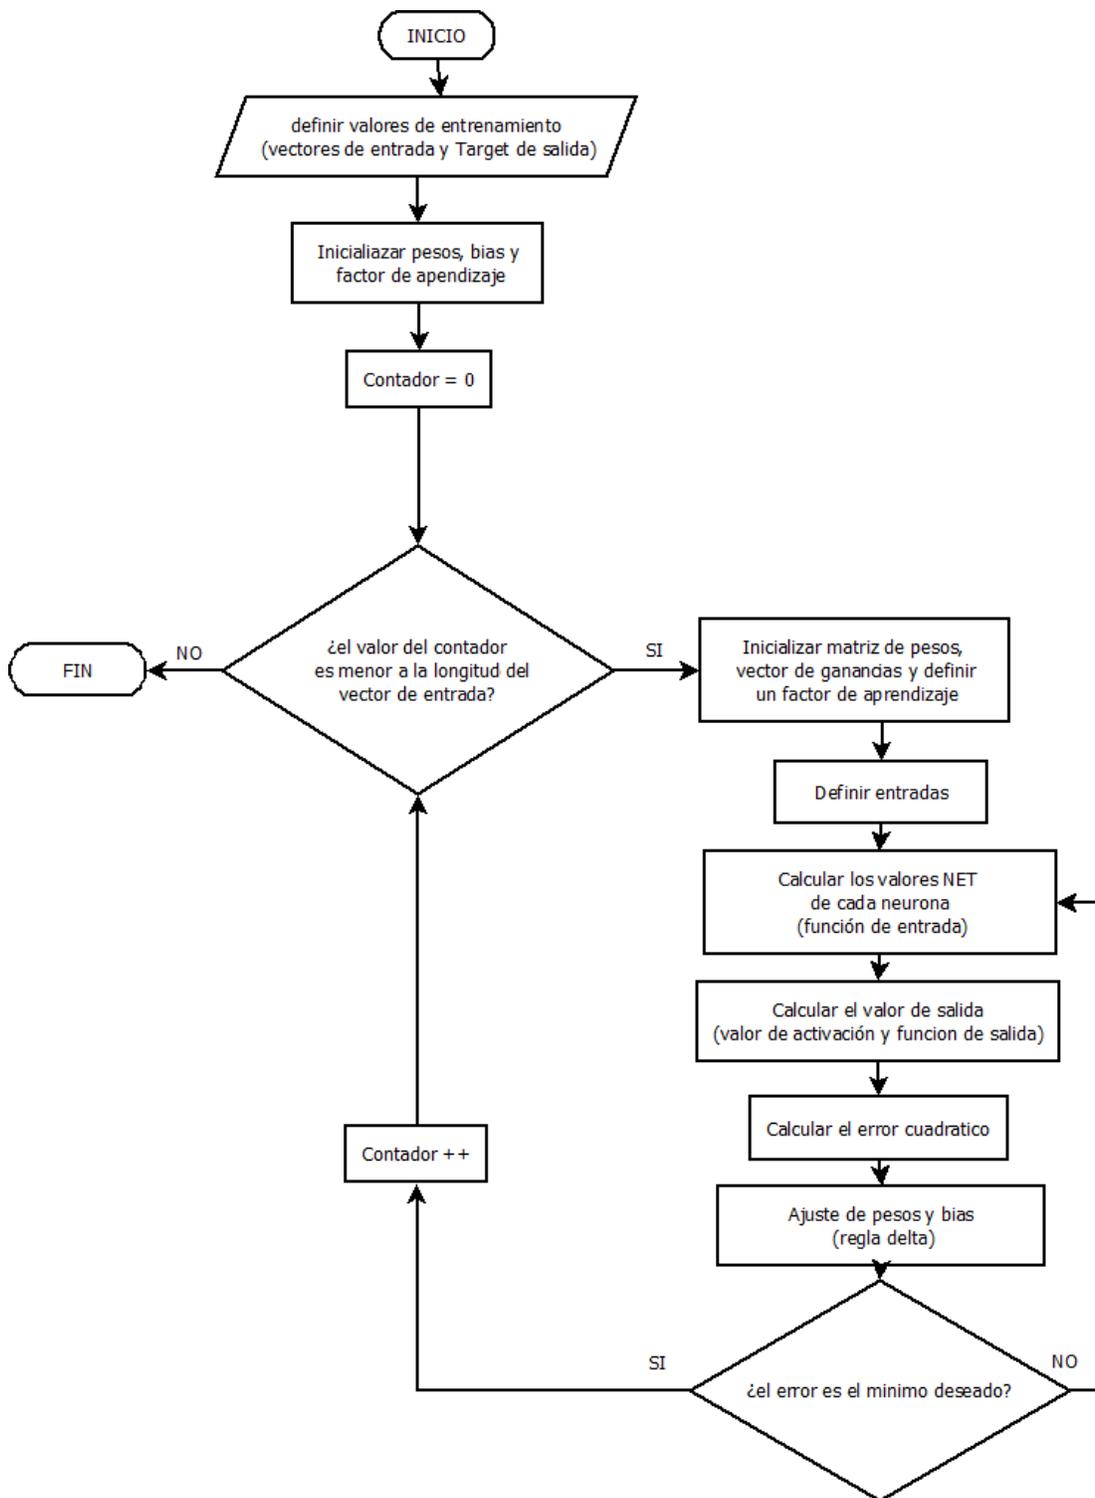


Figura 4. Algoritmo para linealización y auto calibración de sensores mediante redes neuronales artificiales.

En los sistemas neuronales, se hace una distinción entre dos fases operativas: la fase de aprendizaje o entrenamiento y la fase de recuperación o ejecución. El entrenamiento es una característica fundamental de las RNA, son sistemas entrenables que son capaces de

realizar un determinado tipo de procesamiento o cálculo y aprenderlo a partir de una serie de patrones de aprendizaje o ejemplos. Para llevar a cabo el entrenamiento debemos tener definido los valores de entrenamiento que son los vectores de entrada X_1 y X_2 , así como el vector salida esperada que se debe generar (targets) al que llamaremos Y_t . Se debe inicializar la matriz de pesos, el vector de ganancias y definir un factor de aprendizaje K , se recomienda inicializar el vector de ganancias con valores de 1 y la matriz de pesos con valores recomendados entre -1 y 1.

Posteriormente se define los valores de la red, cada neurona artificial recibe un vector de entrada que corresponde a todos los pesos sinápticos que llegan a ella, entonces cada uno se multiplica por el peso que tiene asociado, esos pesos representan la intensidad de la conexión de una sinapsis con una neurona como lo haría una neurona biológica, para ello utilizamos función de entrada como se muestra a en la ecuación 2.

$$Net(i) = \sum_{j=1}^n X_j W_{ij} + b_i \quad \text{Ecuación 2}$$

Una vez que el net de cada neurona es calculado se transforman en el valor de activación y se aplica la función de salida que se encarga de convertir el valor de entrada del net en el valor de salida de la neurona para ello utilizamos la función sigmoide cuya ecuación y su implementación se puede observar en la ecuación 3.

$$F(X) = \frac{1}{1 + e^{-net}} \quad \text{Ecuación 3}$$

Posteriormente se calcula el error cuadrático donde se calcula la diferencia entre la salida deseada y la salida real como se muestra en la ecuación 4

$$E = \frac{1}{2} (targe * sigmoidet)^2 \quad \text{Ecuación 4}$$

Para minimizar el error se aplica la regla delta una función de error que se basa en dicha diferencia y busca realizar un ajuste en los pesos de conexión inversamente proporcional a la derivada del error, la ecuación se muestra.

$$\Delta W_{ij} = W_{ij} * y_i * E * K * net_i \quad \text{Ecuación 5}$$

Finalmente se repite lo anterior a partir de la función de entrada tantas veces como sea necesario para que el entrenamiento este completo y en ese momento el recuerdo también lo estará.

Una vez que la red neuronal ha sido entrenada se puede aplicar por separado el algoritmo de Linealización, este proviene de la salida de la red neuronal desarrollada para el algoritmo de auto calibración, como se muestra en la ecuación 6

$$y = \frac{1}{1 + e^{-(y1*w31+y2*w32+y3*w33+y4*w34+b5)}} \quad \text{Ecuación 6}$$

Puerto de comunicación serial:

Se utiliza para la comunicación entre el Microcontrolador ESP32 y la interface RS-485, configurado para trabajar a 19200 bits por segundo (baudios) con paridad par.

Convertidor Serial TTL - RS485:

Es una interfaz estándar de la capa de comunicación física, un método de transmisión de señales, la primera capa del modelo de interconexión de sistemas abiertos (OSI). El protocolo RS485 se creó para ampliar las capacidades físicas de la interfaz RS232 y es el medio de comunicación para transportar la información del módulo de adquisición de datos al sistema central de control, Con este módulo la longitud máxima del cable utilizado en las comunicaciones es de 1200 metros, En la figura 5 se muestra el módulo max485.



Figura 5. Max485, Convertidor Serial TTL - RS485

Sistema de almacenamiento local:

Es una función desarrollada para almacenar información en la SRAM de 520 KB integrada en el ESP32 y su estructura de almacenamiento está organizada en archivo JSON para alimentar a los datos que serán transportados por medio del canal RS485 basado en el protocolo MODBUS.

Resultados y discusión

Los resultados obtenidos de la implementación de la red neuronal en el algoritmo de auto calibración y linealización pueden observarse en la figura 6, en ella se muestran la gráfica con los datos que fueron proporcionados a la red neuronal de forma inicial o datos previamente almacenados en entrenamientos pasados, En la tabla 1 se puede observar los datos de entrada par la red neuronal (X_1 y X_2) y los valores para el entrenamiento Y_t , donde:

X_1 = Valor normalizado de los datos obtenidos de la resistencia eléctrica del sensor resistivo de temperatura.

X_2 = Valor normalizado de la corriente eléctrica de la salida del sensor de temperatura.

Y_t = Valor deseado (target), obtenido desde el medidor de temperatura portátil mediante bluetooth.

Tabla 1. Etapas de integración

X_1	X_2	Y_t
0.00	0.00	0.00
0.23	0.34	0.23
0.50	0.75	0.50
0.76	0.99	0.76
1.00	1.00	1.00

Fuente: los Autores.

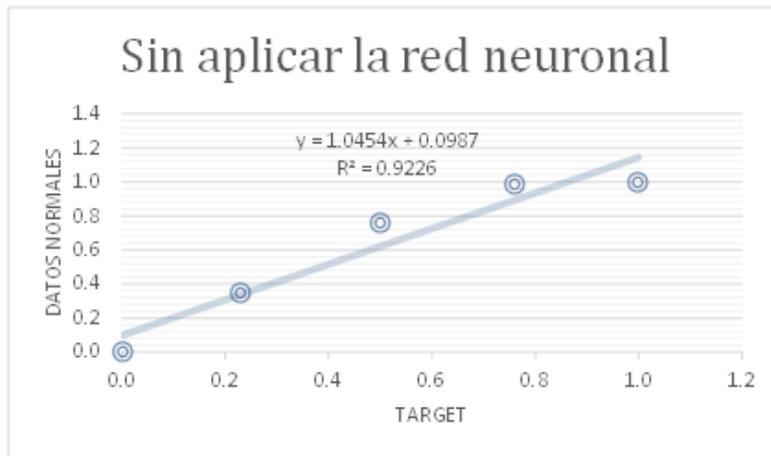


Figura 6. Datos sin linealizar

Cuando la red neuronal de algoritmo es ejecutada realiza la modificación de los pesos sinápticos ajustándolos hasta concluir la linealización y finalmente obtenemos los pesos sinápticos de la red neuronal para obtener datos linealizados, como se muestra en la figura 7.

El factor de aprendizaje elegido fue de $K = 0.5$, el cual logro que el algoritmo convergiera en 99.99 % en 100 épocas.

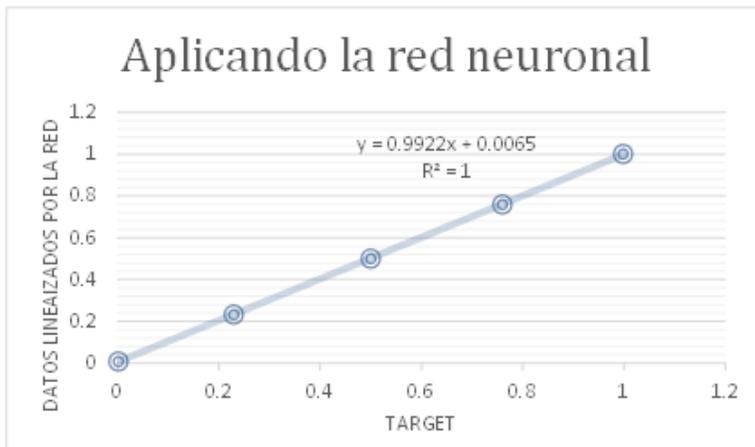


Figura 7. Datos linealizados por la red neuronal artificial.

Al comparar las figuras 6 y la figura 7, se podrá observar una línea recta que representa la línea deseada de salida en la linealización de los datos, los puntos son las neuronas artificiales, En la figura 7 los puntos coinciden con la línea recta, debido a que los pesos sinápticos de la red fueron entrenados para ajustarse al valor deseado.

Conclusiones

El desarrollo del sistema de auto calibración y linealización del sistema de adquisición de datos presenta una ventaja considerable en cuanto al tiempo y facilidad de calibrar los datos obtenidos desde los sensores de temperatura, ya que con solo censar la temperatura con un medidor portátil y enviarla por bluetooth al módulo o módulos de adquisición de datos interconectados a la red MODBUS, podrá cada módulo ajustarse mediante el entrenamiento de la red neuronal sin importar la no linealidad del sensor y los diferentes sensores resistivos conectados.

La red neuronal incrustada en el módulo de adquisición de datos ayudara a mejorar el desempeño en la linealización de los datos y facilitar el ajuste en la autocalibración sin la necesidad de desconectar el sensor de temperatura.

Referencias bibliográficas

- Ahmad, A., Roslan, M. F., y Amira, A., (2017). Throughput, latency and cost comparisons of microcontroller-based implementations of wireless sensor network (WSN) in high jump sports. In AIP Conference Proceedings (Vol. 1883, No. 1, p. 020010). AIP Publishing. <https://doi.org/10.1063/1.5002028>
- Baroudi, U., Bin-Yahya, M., Alshammari, M., Yaqoub, U., (2019). Ticket- based QoS routing optimization using genetic algorithm for WSN applications in smart grid. Journal of Ambient Intelligence and Humanized Computing, 10(4), 1325-1338. <https://doi.org/10.1007/s12652-018-0906-0>
- Cabrera, B. L; Christian Fournier, Tsu-Wei Chen, Nicolas Brichet, Benoît Suard, Claude Welcker, François Tardieu. (2016). High-throughput estimation of incident light, light interception and radiation-use efficiency of thousands of plants in a phenotyping platform. An International Plant Phenotyping Symposium. CIMMYT. Book of abstracts. December, 2016. Mexico City, Mexico.
- Comar, A. F; Baret, G. Collombeau, M. Hemmerlé, B. de Solan, D. Dutartre, M. Weiss, S. Madec, F. Toromanoff. (2016). A multispectral camera dedicated to field phenotyping from drone observations. An International Plant Phenotyping Symposium. CIMMYT. Book of abstracts. December, 2016. Mexico City, Mexico.
- Devaux, A. (2014). Potatoes for Sustainable Global Food Security. Potato Research. 2014;57(3–4):185–99. doi:10.1007/s11540-014-9265-1

- Figueredo-Ávila, G. A. (2016). Fruit ripeness identification with artificial neural networks - A review. *Ciencia y Agricultura*, 13(1), 117–132. <https://doi.org/10.19053/01228420.4811>
- Forero, H.H. (2020). Desarrollo de una red punto a punto con tecnología LoRa y servidor web [Tesis de pregrado, Universidad Cooperativa de Colombia]. Repositorio Institucional UCC. <http://hdl.handle.net/20.500.12494/20540>
- Haro, L.F. (2019). Importancia de la producción de Papa en México. *elsoldemexico*. <https://www.elsoldemexico.com.mx/analisis/importancia-de-la-produccion-de-papa-en-mexico-3433659.html>
- Ramírez, M., A, J., y Chacón, M. (2011). Redes neuronales artificiales para el procesamiento de imágenes
- Jerez, E.I. (2016). Análisis clásico del crecimiento en tres variedades de papa (*Solanum tuberosum* L.). *Cultivos Tropicales*. 2016;37(2):79–87. doi:10.13140/RG.2.1.4860.0568
- Jerez, M.E. (2012). Comportamiento del crecimiento y el rendimiento de la variedad de papa (*Solanum tuberosum* L.) Spunta. *Cultivos Tropicales*. 2012;33(4):53–8.
- Jerez, M.E. (2015). Comportamiento de la acumulación y distribución de masa seca en tres variedades de papa (*Solanum tuberosum* L.). *Cultivos Tropicales*. 2015;36(4):70–6.
- Liao, C., Zhu, K., Tang, J., Zhang, S., (2016). Wireless Sensor Network Performance Research for LEACH Based on Multi-Agent Simulation. *IEEE International Conference on Agents (ICA)* 98-99. IEEE. <https://doi.org/10.1109/ICA.2016.031>
- Mezghani, M., Abdellaoui, P., (2015). WSN intelligent communication based on Khalimsky theory using multi-agent systems. In *2015 SAI Intelligent Systems Conference (IntelliSys)* (pp. 871-876). IEEE. <https://doi.org/10.1109/IntelliSys.2015.7361245>
- Núñez, J. R., Benítez, I.F., Rodríguez, A., Díaz, S., Oliveira, D. (2019). Tools for the implementation of a SCADA system in a desalination process. *IEEE Latin America Transactions*, 17(11), 1858-1864. <https://doi.org/10.1109/TLA.2019.8986424>
- SISSAN (2013). Sistema de Indicadores de Soberanía y Seguridad Alimentaria y Nutricional SISSAN. Recuperado el 25 de Junio de 2017, de SISSAN Web Site: http://www.siise.gob.ec/siiseweb/PageWebs/SISSAN/macsan_conbas.htm
- Zhang, Z., Mehmood, A., Shu, L., Huo, Z., Zhang, Y., & Mukherjee, M., (2018). A survey on fault diagnosis in wireless sensor networks. *IEEE Access*, 6, 11349-11364. <https://doi.org/10.1109/ACCESS.2018.2794519>