

Modelamiento de Instrumentos de medición de temperatura utilizando una Red Neuronal Perceptron Multicapa

Modeling tools for measuring temperature using a Neural Network Multilayer Perceptron

Pedro Freddy Huamaní Navarrete¹

Resumen

Las termocuplas son instrumentos de medición utilizados para sensar temperatura en muchos procesos industriales, sin embargo poseen la desventaja de presentar una respuesta no lineal. Por ello, en este artículo, se presenta el uso de una red neuronal perceptron multicapa con tres capas de neuronas, para modelar el comportamiento de las termocuplas J y K, para un intervalo específico de temperatura. La obtención del modelo se consigue después de someter a la red neuronal a una etapa de entrenamiento, y posterior prueba en un intervalo de temperatura diferente y no utilizado en la etapa de entrenamiento. El aprendizaje de la red neuronal se realiza a través del algoritmo back propagation, que consiste en la propagación del error desde la tercera capa de neuronas, hacia la primera.

Palabras claves

Red multicapa, termocuplas, back propagation.

Abstract

Thermocouples are measuring instruments used to sensory temperature in many industrial processes, nevertheless have the disadvantage to display an answer nonlinear. For that reason, in this article, the use of a neuronal network appears multilayer perceptron with three layers of neurons, to model the behavior of thermocouples J and K, for a specific interval of temperature. The model is obtained after putting under the neuronal network to a training phase, and later test in an interval of temperature different and not used in the training phase. The learning of the neural network is made through the algorithm back propagation, which consists of the propagation of the error from the third layer of neurons, towards first.

Key words

Network multi layers, thermocouples, back propagation.

¹ Ingeniero electrónico. Magíster en Procesamiento de Señales y Control de Procesos. Docente URP.

Introducción

En muchos procesos industriales, la medida de temperatura constituye una de las mediciones más comunes e importantes. Tales mediciones pueden ser obtenidas por diversos fenómenos que son influidos por la temperatura. Entre ellos podemos citar: las variaciones en volumen, las variaciones de resistencia de un conductor, de un semiconductor, la intensidad de la radiación emitida por el cuerpo, y la f.e.m. creada al unir dos metales distintos. Precisamente este último fenómeno corresponde a las termocuplas o llamadas también termopares, que no vienen hacer otra cosa que instrumentos ciegos para medición de amplios rangos de temperatura. El principio básico de estos instrumentos radica en el efecto descubierto por Seebeck en 1821, donde la circulación de una corriente en un circuito formado por dos metales diferentes, y cuyas uniones se mantienen a distintas temperaturas, producen una f.e.m. en uno de los extremos.² Sin embargo, la variación de temperatura versus la f.e.m. creada (en milivoltios), no mantienen una relación lineal; lo que obliga a utilizar circuitos acondicionadores para linealizar dicha respuesta. Por lo tanto, en este artículo se presenta el uso de una red neuronal artificial perceptron multicapa, con la finalidad de modelar el comportamiento de las termocuplas J y K, para un intervalo específico de temperatura.

Aspectos Teóricos

Seguidamente se señalan algunos conceptos teóricos e importantes, que se relacionan con este artículo.

– Termocuplas J y K

La termocupla tipo J está hecha con un alambre de hierro y otro de la aleación de cobre-níquel, mientras que la termocupla tipo K está fabricada por las aleaciones níquel-cromo y níquel-aluminio. La primera tiene un rango de medición de -40°C a 750°C , en cuanto que la segunda de -40°C a 1200°C , aproximadamente;² es por ello que son muy utilizados en la industria del papel, del plástico, cerámica, petroquímica, entre otras.

Una de las características de las termocuplas, es la compensación de cero. Esto se debe a que en algún punto habrá que empalmar los cables de la termocupla con un conductor normal de cobre, formándose dos nuevas termocuplas con dicho cobre. Por lo tanto, este problema se soluciona, sumando la temperatura del ambiente (T_{ambiente}) a la medición dada por la propia termocupla.² En la figura 01 se observa la forma de conexión de la termocupla, y la influencia de la temperatura del ambiente.

² Creus, Antonio. 2005. Instrumentación Industrial.

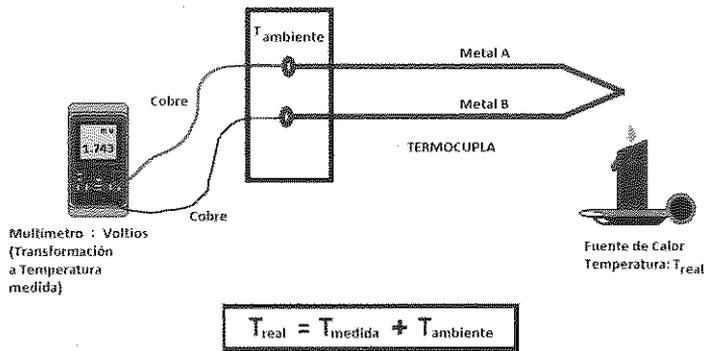


Figura 01. Compensación de cero en termocuplas.

– Red neuronal perceptron multicapa

Las redes neuronales artificiales se definen como sistemas altamente paralelos no lineales y densamente interconectados. Están basados en procesadores simples (modelo simplificado de la neurona biológica).³ De modo simple, están compuestas por entradas, salidas, capas de neuronas, pesos sinápticos y una función de activación o de transferencia en cada neurona. Hoy en día existen variedades de arquitecturas de redes neuronales, desde las más sencillas como el caso de perceptron de una capa (función de transferencia tipo escalón), hasta las más complejas (redes perceptron multicapas con funciones de transferencia no lineales). Una de las ventajas de las redes multicapa, es la aproximación de funciones no lineales, y para ello utiliza un tipo de regla de aprendizaje basado en la actualización de sus pesos sinápticos, desde la última capa hacia la primera y partiendo del error hallado en la salida total de la red. Por ello recibe el nombre de red neuronal con aprendizaje Back propagation. Asimismo, estas redes se caracterizan por poseer un entrenamiento del tipo supervisado, debido a que el error se obtiene a partir de la diferencia entre una salida deseada y una salida actual obtenida.⁴ La figura 02 muestra el ejemplo de una estructura de red perceptron multicapa con dos capas de neuronas.

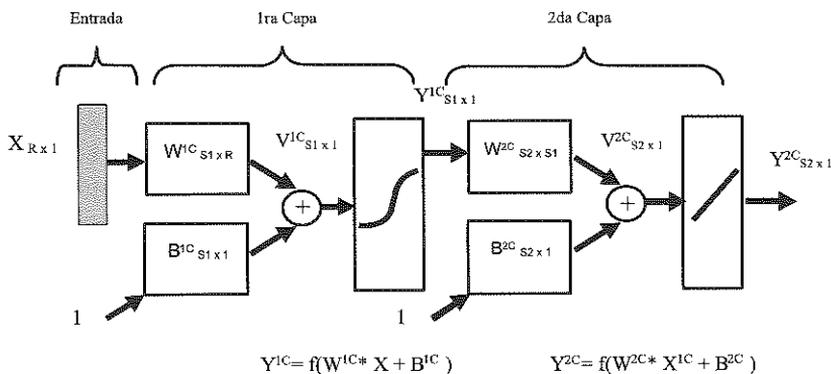


Figura 02. Estructura de una red neuronal con dos capas.

3 Haykin, Simon. 2008. Neural Networks A Comprehensive Foundation
4 Bonifacio, Martín del Brío. 2006. Redes Neuronales y Sistemas Borrosos

Donde:

- X: representa al vector de entrada a la red neuronal..
- W1C: representa la matriz de pesos de la primera capa.
- B1C: representa los bias de la primera capa.
- W2C: representa la matriz de pesos de la segunda capa.
- B2C: representa los bias de la segunda capa.
- Y1C: representa el vector de salida de la primera capa.
- Y2C: representa el vector de salida de la segunda capa.

Implementación Del Modelo

Para el desarrollo de este trabajo, se seleccionó una red multicapa con tres capas de neuronas. La primera capa compuesta por 6 neuronas, la segunda por 4 neuronas, y la última capa con 2 neuronas. La elección de esta arquitectura está basada en la técnica de ensayo y error, debido a que no existe un procedimiento en cuanto a la elección de la cantidad de capas y/o neuronas para una red neuronal. Por tal razón, la arquitectura elegida otorgó una mejor respuesta en cuanto a precisión y tiempo de entrenamiento. A continuación, en la figura 03, se muestra un diagrama de bloques que representa el modelo implementado, donde también es posible apreciar la red neuronal utilizada.

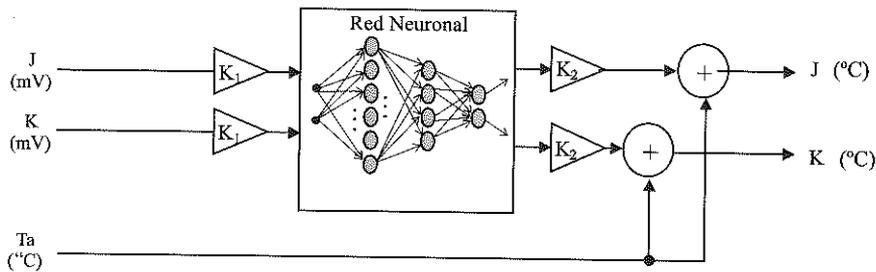


Figura 03. Diagrama de bloques del modelo implementado.

La primera y segunda entrada (medidas en mili-voltios (mV), para ambas termocuplas), ingresan a la red neuronal pero a través de un factor reductor "K1". La finalidad de dicho factor es la necesidad de utilizar los datos de entrada a la red neuronal, en el rango de 0 a 1. Ello se debe al uso de una función de transferencia tipo sigmoid, en cada neurona de la primera y segunda capa, y que a su vez restringe la salida de cada neurona al rango de 0 a 1. Para el caso de la tercera capa se optó por elegir una función de transferencia lineal, para hacer que el vector de salida tome cualquier rango sin obligarlo a situarse solamente en el rango de 0 a 1. En cuanto al vector de salida deseada, se eligió un vector con valores correspondientes a la conversión de temperatura pero en forma normalizada.

Seguidamente, las ecuaciones 3.1, 3.2, 3.3, 3.4, 3.5 y 3.6, muestran el procedimiento para el cálculo de la salida total de la red neuronal.

$$V^{1C} = W^{1C} * X + B^{1C} \quad (3.1)$$

$$Y^{1C} = \frac{1}{1 + e^{-V^{1C}}} \quad (3.2)$$

$$V^{2C} = W^{2C} * X^{1C} + B^{2C} \quad (3.3)$$

$$Y^{2C} = \frac{1}{1 + e^{-V^{2C}}} \quad (3.4)$$

$$V^{3C} = W^{3C} * X^{2C} + B^{3C} \quad (3.5)$$

$$Y^{2C} = V^{3C} \quad (3.6)$$

Donde:

- X: vector de entrada a la red neuronal (2x1)
- W1C: matriz de pesos sinápticos de la primera capa (6x2)
- B1C: vector de bias de la primera capa (6x1)
- Y1C: salida de la 1ra capa y a su vez entrada a la 2da capa (6x1)
- W2C: matriz de pesos sinápticos de la segunda capa (4x6)
- B2C: vector de bias de la segunda capa (4x1)
- Y2C: salida de la 2da capa y a su vez entrada a la 3ra capa (4x1)
- W3C: matriz de pesos sinápticos de la tercera capa (2x4)
- B3C: vector de bias de la tercera capa (2x1)

Para la etapa de entrenamiento de la red neuronal, se eligió el valor de 27.3880 para el factor K1, de tal forma que el valor máximo en mili voltios (mV) entregado, por la termocupla J o K, en todo su campo de medida, se sitúe en el rango de 0 a 1.

Por otro lado, la tercera entrada corresponde a la temperatura del ambiente ("C), y se utiliza para realizar la compensación a cero de ambas termocuplas. De esta manera, se hace necesario utilizar un segundo factor: "K2", en cada neurona de salida de la red. El valor elegido para el factor K2 fue de 499, y la finalidad de utilizarlo en el entrenamiento, fue para recuperar la amplitud de los datos de salidas en temperatura, y con ello lograr realizar una suma de temperaturas (compensación a cero) para cada instrumento.

Para la actualización de los pesos sinápticos por cada capa, se utilizaron las expresiones mostradas en las ecuaciones 3.7, 3.8 y 3.9:

$$\Delta w_{ij}^{c-1} = (tr) * (x_j) * (\delta_i^{c-1}) \quad (3.7)$$

$$\Delta b_i^{c-1} = (tr) * (\delta_i^{c-1}) \quad (3.8)$$

$$\delta_i^{c-1} = \begin{cases} \varphi' (v_i^{c-1}) * (D_i - Y_i), & c = M \\ \varphi' (v_i^{c-1}) * \sum_k (w_{ki} * \delta_k^c), & 1 \leq c < M \end{cases} \quad (3.9)$$

Donde:

- η : Tasa de Aprendizaje e igual a 0.041.
- M : Última capa o layer de salida.
- D_i : Vector de salida deseada.
- Y_i : Vector de salida actual.
- $w_{i,j}^{c-1}$: Matriz de pesos de la capa "c-1". Con número de entradas igual a "j", y número de salidas igual a "i".
- δ_i^{c-1} : Variable interpretada como error propagado de la capa "c-1".

$$\varphi(v) = \frac{1}{1+e^{-v}} \quad : \text{ Función de transferencia o de activación.}$$

$$\varphi'(v) = \frac{\partial \varphi(v)}{\partial v} = \varphi(v)(1 - \varphi(v)) \quad : \text{ Derivada de la función de transferencia.}$$

Finalmente, la etapa de entrenamiento de la red neuronal, se llevó a cabo con ayuda del Toolbox Neural Networks del Software Matlab.⁵ Para ello, se utilizó como vector de salida deseada, los datos proporcionados por el texto de Antonio Creus, en las páginas 246-247 y 249,⁶ pero normalizados. Tales datos corresponden a las conversiones de mediciones de mV a valores de temperatura, para cada termocupla.

Los datos de entrada y utilizados para la etapa de entrenamiento cubrió los rangos mostrados a continuación, y pueden ser observados en la figura 04.

- Termocupla J : 0.050 mV a 27.388 mV (equivalencia de 1 °C a 499 °C)
- Termocupla K : 0.039 mV a 20.640 mV (equivalencia de 1 °C a 499 °C)

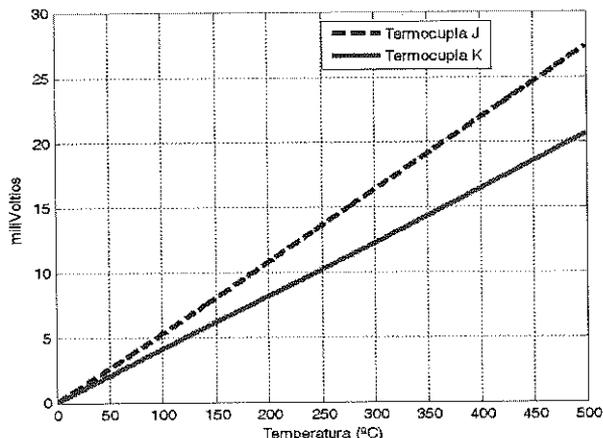


Figura 04. Gráficas de las termocuplas J y K para el intervalo de 0 a 499 °C

5 Neural Network Toolbox.

6 Creus, Antonio. 2005. Instrumentación Industrial.

Por otro lado, los datos de salida deseada para la misma etapa de entrenamiento correspondieron al siguiente rango:

Termocupla J : 0 a 1 (equivalencia de 1 °C a 499 °C dividido por el factor K2)
Termocupla K : 0 a 1 (equivalencia de 1 °C a 499 °C dividido por el factor K2)

Resultados

Para el entrenamiento de la red neuronal se necesitaron un total de 3152 iteraciones, logrando alcanzar un error medio cuadrático igual a 3.19992×10^{-11} . Para agilizar la etapa de entrenamiento, se optó por utilizar el algoritmo de optimización Levenberg-Marquardt5. Este algoritmo, forma parte de uno de las funciones del software Matlab para el entrenamiento de un red perceptron multicapa (digitar en el Matlab: >>help trainlm). A continuación, en la figura 05, se muestra el descenso de la curva de error para el número total de iteraciones realizadas.

Asimismo, en la figura 06 se muestran las matrices de pesos y bias obtenidos después de lograr el entrenamiento de la red MLP.

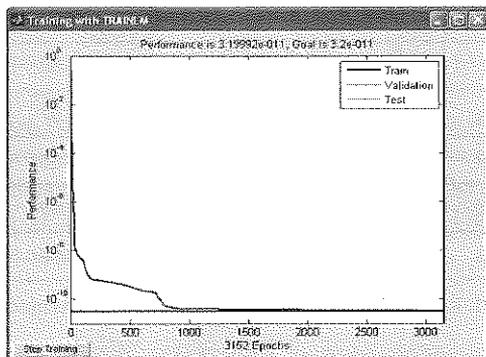


Figura 05. Curva de error para las 3152 iteraciones

$$W^{1C} = \begin{vmatrix} 7.7122 & 10.2115 \\ 13.1543 & -2.6973 \\ 2.4960 & -12.3593 \\ -1.9336 & -3.7336 \\ -8.2751 & -8.1577 \\ 6.1708 & -12.2589 \end{vmatrix} \quad B^{1C} = \begin{vmatrix} -16.7766 \\ -8.3047 \\ 7.4127 \\ 0.6190 \\ 5.5235 \\ 9.8371 \end{vmatrix}$$

$$W^{2C} = \begin{vmatrix} -0.6640 & 0.7814 & -2.1877 & 3.6435 & 1.9762 & 5.2900 \\ 0.8434 & 5.0073 & -0.1046 & -3.4438 & 0.7494 & -6.0677 \\ 0.6421 & 0.5099 & -2.4171 & -3.2017 & -0.1887 & 1.0432 \\ 3.4235 & 6.0926 & 2.4193 & -4.5002 & 1.2032 & 0.9422 \end{vmatrix} \quad B^{2C} = \begin{vmatrix} 3.7630 \\ -3.5488 \\ 1.7274 \\ 1.2814 \end{vmatrix}$$

$$W^{3C} = \begin{vmatrix} -0.0092 & 5.4394 & 1.0310 & 3.0803 \\ -0.0092 & 5.4394 & 1.0310 & 3.0803 \end{vmatrix} \quad B^{3C} = \begin{vmatrix} -3.0011 \\ -3.0011 \end{vmatrix}$$

Figura 06. Matrices de pesos y bias al término del entrenamiento de la red MLP

Tanto el entrenamiento y el desempeño (prueba) de la red neuronal, se realizaron con grupos de datos diferentes.

El primer grupo, contiene a los datos que participaron en el entrenamiento de la red. Este se encuentra conformado por 499 valores en mili voltios, correspondientes al rango de 1 °C hasta 499 °C, para ambas termocuplas.

Por otro lado, el segundo grupo, contiene a los 100 datos que no participaron en el entrenamiento, y por lo tanto comprende el rango de temperatura de 500 °C a 599 °C. De esta manera, en la tabla 01 y 02, se muestran algunos resultados después de la verificación de la red con ambos grupos de datos, así como también el error por cada caso diferente.

	Grupo de Entrenamiento (°C)		Error (%)	Grupo de Prueba (°C)		Error (%)
	Vector de Salida deseada	Salida de Red Neuronal (k, yk ₂)		Vector de Salida deseada	Salida de Red Neuronal (con k, yk ₂ y compensación)	
1	11	11	0	501	501.01	0.002
2	98	98	0	516	516.03	0.006
3	123	123	0	535	534.97	0.006
4	269	269	0	576	576.05	0.009
5	387	387	0	589	588.93	0.012
6	410	410	0	599	598.92	0.030

Tabla 01. Resultado para ambos grupos de datos (termocupla J).

	Grupo de Entrenamiento (°C)		Error (%)	Grupo de Prueba (°C)		Error (%)
	Vector de Salida deseada	Salida de Red Neuronal (k, yk ₂)		Vector de Salida deseada	Salida de Red Neuronal (con k, yk ₂ y compensación)	
1	14	14	0	511	511.02	0.004
2	101	101	0	526	526.04	0.008
3	145	145	0	531	530.76	0.045
4	219	219	0	556	556.50	0.090
5	377	377	0	577	577.57	0.099
6	433	433	0	590	589.44	0.095

Tabla 02. Resultado para ambos grupos de datos (termocupla K).

Para la etapa de entrenamiento de la red neuronal MLP, se eligieron los siguientes parámetros:

Vector de Entrada:	2 x 1
Vector de Salida:	2 x 1
Error mínimo cuadrático:	3.2 x 10 ⁻¹¹
Error global:	3.2 x 10 ⁻¹¹
Tasa de aprendizaje:	0.01
Número inicial de iteraciones:	100000
Número final de iteraciones:	3152
Número de capas:	3 capas
Número de neuronas 1ra capa:	6 neuronas
Número de neuronas 2da capa:	4 neuronas
Número de neuronas 3ra capa:	2 neuronas
Función de transferencia 1ra capa:	No Lineal
Función de transferencia 2da capa:	No Lineal
Función de transferencia 3ra capa:	Lineal

Discusión

Son muchas las topologías de redes neuronales que en la actualidad existen, de las más simples y un número reducido de neuronas, hasta las más complejas, con un elevado tiempo de entrenamiento y aprendizaje. Por tal motivo, el modelamiento de las termocuplas J y K, también puede someterse a otros tipos de redes neuronales; y aún más, ampliar el número de elementos en el vector de entrada. Esto conllevaría, quizás, a un número mayor de iteraciones, y quien sabe a una cantidad de neuronas y capas superior al utilizado en este trabajo, logrando así un error medio cuadrático más pequeño del obtenido.

CONCLUSIONES

Entre las conclusiones más resaltantes de este trabajo, nombramos las siguientes:

- El aumento del número de neuronas y capas en la red neuronal, podría mejorar el desempeño de la red neuronal, pero en consecuencia incrementaría el tiempo computacional para el cálculo de los pesos sinápticos.
- Las redes perceptron multicapa, con aprendizaje back propagation, poseen un tipo de entrenamiento supervisado; por ello, se utiliza como valores deseados la temperatura correspondiente a cada medición en mili voltios.
- Se utilizó el algoritmo de aprendizaje back propagation Levenberg-Marquardt, con la finalidad de agilizar el tiempo de actualización de los pesos y bias sinápticos.

- El desempeño de la red perceptron multicapa fue óptima para el grupo de datos que participó en la etapa de entrenamiento; sin embargo, para el grupo de datos ajenos al entrenamiento, hubo presencia de cierto error.
- Por la naturaleza de las funciones de transferencia no lineales de la primera y segunda capa de la red neuronal utilizada, se optó por normalizar los datos de entrada expresados en mili voltios. De esta forma, se logró situar tales cantidades en el rango de 0 a 1.

REFERENCIAS BIBLIOGRÁFICAS

- HAYKIN, SIMON. 2008. "Neural Networks A Comprehensive Foundation". 3ra edición. Prentice Hall.
- WASSERMAN, PHILIP D. 1989. "Neural Computing: Theory and Practice". Van Nostrand Preinhold.
- BONIFACIO, MARTÍN DEL BRIO. 2006. "Redes Neuronales y Sistemas Borrosos". 3ra edición. Editorial Ra-Ma.
- NEURAL NETWORK TOOLBOX. Versión 5.1. Agosto 2007. The MathWorks Inc.
- CREUS, ANTONIO. 2005. "Instrumentación Industrial". 7ma edición. Editorial Marcombo.
- HUAMANÍ, PEDRO. 2008. Cuaderno de Ingeniería: Simulación de Redes Neuronales con Matlab. Taller de Impresiones de la Universidad Ricardo Palma.