

Uso de redes neuronales para reducir la dispersión de cálculos empíricos

Elisa Zambrano Gómez^A, Luis Torres Treviño^B,
Gina María Idárraga Ospina^B, Carlos Gaytán Cavazos^A,
Juan José Saldívar Hinojosa^A

^A Prolec GE, Apodaca, NL

^B FIME UANL

ezambranog@gmail.com

RESUMEN

Los modelos empíricos se generan normalmente con una muestra finita de valores, pero cuando los datos de entrada se encuentran en un rango diferente a aquella muestra, el modelo puede tener cierta dispersión. En algunos casos esa dispersión es marginal, sin embargo en cálculos de pérdidas de fierro en un transformador, esta diferencia puede representar sumas importantes de dinero. Por lo tanto en este trabajo se utiliza exitosamente un modelo de redes neuronales para reducir dicha dispersión, considerando como datos de entrada el histórico de los resultados del cálculo para poder estimar de manera más precisa el valor real.

PALABRAS CLAVE

Redes Neuronales, Modelos Empíricos, Dispersión en Cálculos, Pérdidas sin Carga

ABSTRACT

Empiric Models are generated based on a finite number of sample values. Nonetheless, when you are introducing data to the model that differs from the data range the model was generated from, the results may vary. In most cases this variation is marginal and it can still be consider useful, but in some cases such as predicting losses in a transformer, a small variation can sum up a large additional cost. Based on this, during this study a neural network is used to estimate in a more accurate fashion, core losses, using a year's worth database from transformer testing.

KEYWORDS

Neural Network, Empirical Model, Dispersion on Numerical Models, No load losses

INTRODUCCIÓN

Las pérdidas más importantes de un transformador son las pérdidas con carga y pérdidas sin carga. Las pérdidas con carga son aquellas derivadas de la bobina, mientras que las pérdidas sin carga son generadas por el núcleo del transformador. Ambas son determinantes en el diseño de cualquier tipo de transformador y

por lo tanto en el costo del mismo. Aunque las pérdidas sin carga se presentan en menor magnitud, su relevancia es alta debido a que no importa el consumo del usuario, siempre se incurre el mismo valor de ellas.

Con las recientes regulaciones como la DOE-2016 en Estados Unidos y la NOM-SEDE-002-2014 en México, donde las eficiencias mínimas para el diseño de un transformador cada vez son más agresivas, la exactitud del cálculo para predecir dichas pérdidas se vuelve más relevante.

El modelo actual de pérdidas sin carga en Prolec GE se desarrolló empíricamente, tomando en cuenta la curva de saturación de una población de aparatos determinada, según su línea de producto.

Sin embargo, se ha encontrado una dispersión en el cálculo, donde en algunas ocasiones se presenta una subestimación de pérdidas de fierro y en otras una sobreestimación.

La figura 1 muestra una dispersión en el R/D (valor real obtenido en pruebas/ valor calculado) de las medias poblacionales en 5 aparatos seleccionados de forma aleatoria de la categoría monofásicos tipo poste.

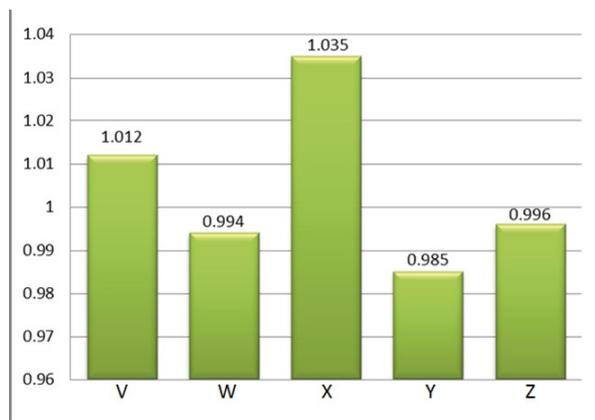


Fig. 1. R/D de pérdidas sin carga para diferentes poblaciones de diseños.

Se decidió seleccionar este tipo de aparatos ya que representan el mayor volumen de ventas para la empresa y por lo tanto el mayor impacto.

El objetivo de este proyecto es el de reducir la dispersión en el cálculo de las pérdidas sin carga en la línea de transformadores monofásicos tipo poste; logrando una mayor precisión en el mismo, y con ello obteniendo una reducción en costos de materiales.

METODOLOGÍA

Para abordar esta problemática, se recurrió a un modelo de redes neuronales, el cual pudiera relacionar las variables A, B, C y D de entrada de cada diseño con su salida de R/D. Las variables A, B, C y D fueron características del núcleo que según autores como Chapman¹ y Kulkarni² podían influir en el comportamiento de sus pérdidas.

Se utilizó una base de datos de más de 1200 diseños de transformadores tipo poste monofásico, cada uno con más de 100 aparatos fabricados. De cada uno de estas poblaciones se obtuvo el valor R/D promedio.

Con esta información se generó un modelo de predicción de pérdidas utilizando una red neuronal del tipo Perceptron Multicapas. El modelo se corrió en un software Scilab 5.5.

Las redes neuronales de este tipo, permiten resolver problemas que no son linealmente separables. Estas poseen la característica de tener capas que no son visibles ni al input ni al output, como se muestra en la figura 2. Tienen la capacidad de separar inputs en múltiples funciones lineales y detectar patrones más complejos que la red de una función lineal.

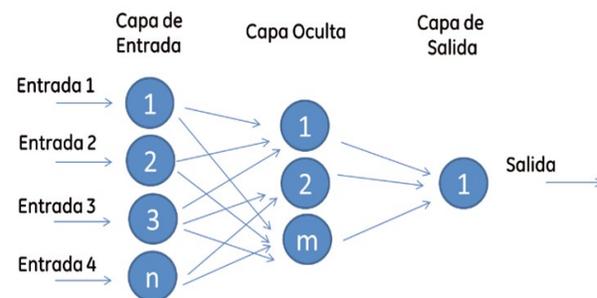


Fig. 2. Funcionamiento de una red neuronal del tipo multicapas.

EXPERIMENTACIÓN

En el software Scilab 5.5 se estuvieron corriendo múltiples pruebas con el modelo de la red neuronal. El objetivo era el de encontrar por medio de los parámetros principales: número de épocas, coeficiente alfa y la variable de aprendizaje eta, un modelo que presentara un error menor a 0.01.

Con un valor de 2 mil épocas, un alfa de 0.12 y una eta de 0.25 se logró generar un modelo con un valor de error de 0.0046, por lo cual el modelo se reconoció como exitoso.

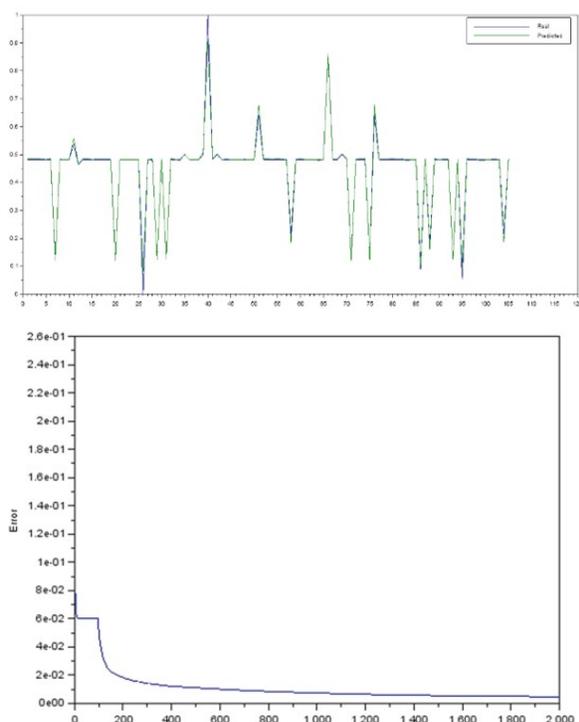


Fig. 3. a) Desempeño del modelo de la red neuronal b) error obtenido en el modelo.

En la figura 3a y 3b se puede observar el comportamiento de la red.

RESULTADOS

Una vez establecido el modelo, este se utilizó el de forma retroactiva para comprobar su validez. Se introdujeron como datos de entrada al modelo la información de un diseño cuyo valor de R/D era conocido para comprobar efectividad. Los resultados se muestran en la tabla I.

Dados estos resultados, fue evidente que el modelo no estaba funcionando de la manera esperada. En este

Tabla. I Resultados de R/D arrojados por la red neuronal.

Diseño	Valor Real	Resultado Red Neuronal	% de Diferencia
A	1.03912	0.9655	-7.1%
B	1.00718	1.0779	7.0%
C	1.01615	1.0725	5.5%
D	0.951234	1.0573	11.2%
E	0.971376	1.06177	9.3%
F	0.96995	1.07162	10.5%
G	1.03982	0.95877	-7.8%

momento se recurrió a la literatura^{3,4,5} para analizar si las variables de entrada que se habían considerado eran las correctas o eran suficientes para poder mejorar la predicción de las pérdidas sin carga.

Se estuvieron corriendo modelos de la red neuronal con diferentes variables de entrada y repitiendo al análisis retroactivo para ver su relevancia con respecto al modelo.

Finalmente se seleccionaron las variables E, F, H e I como las que mejores resultados arrojaban al modelo.

Los resultados del comportamiento de la red neuronal bajo este segundo juego de variables se encuentran en la tabla II.

Tabla. II Resultados de R/D arrojados por la red neuronal con el segundo juego de variables.

Diseño	Valor Real	Resultado Red Neuronal	% de Diferencia
A	0.9704	0.98726	1.7%
B	1.00718	1.03977	3.2%
C	1.03534	1.03977	0.4%
D	0.97137	0.98727	1.6%
E	1.00772	0.9872	-2.0%
F	0.99663	0.9872	-0.9%
G	1.04182	1.03976	-0.2%

Basados en esta muestra de diseños aleatorios con los cuales se realizó la validación del modelo, se pudo comprobar que el modelo propuesto era superior al modelo actual de la empresa para la predicción de las pérdidas sin carga.

CONCLUSIONES

Se desarrolló un modelo multivariable para la predicción de las pérdidas sin carga en transformadores monofásicos tipo poste utilizando una red neuronal multicapas en el software Scilab 5.5.

El modelo se consideró exitoso al presentar una desviación promedio del 0.6% con respecto a los valores previamente conocidos durante un ejercicio retroactivo.

Para reducir aún más la dispersión se pudiera buscar un sistema de cómputo más avanzado con la capacidad de refinar aún más el modelo. Sin embargo la aplicación de este nuevo modelo de pérdidas sin

carga en el diseño de los transformadores de tipo poste monofásico ya presenta una ventaja sustancial contra el modelo que actualmente se utiliza en la compañía.

AGRADECIMIENTOS

A Prolec GE por el financiamiento de la beca para la Maestría Eléctrica y la disponibilidad de tiempo que nos brindó.

Al equipo de Desarrollo Tecnológico de Prolec GE por su constante apoyo.

Al Dr. Luis Torres por apoyo en la realización de este proyecto.

REFERENCIAS

1. Chapman, S. *Electric machinery fundamentals* (4th ed.). New York, NY: McGraw-Hill Higher Education, 2005.
2. Kulkarni, S., & Khaparde, S. *Transformer engineering: Design and practice*. New York: Marcel Dekker, 2004.
3. Hsu, C., & Lee, C. Effects of magnetostriction and magnetic reluctances on magnetic properties of distribution transformers. *Journal of Applied Physics*, 2014, vol. 115 página 17.
4. Liangxian, Z.. Algorithm for calculating no-load losses of single-phase transformer core with step-lap joints. *Journal of Xi'an Jiaotong University*, 2014, vol.48 página 4.
5. Hernandez, I.. Core loss and excitation current model for wound core distribution transformers. *International Transactions on Electrical Energy Systems*, 2014, vol.24 página 1.
6. Souza, K.. Prediction of core losses on a three-phase transformer using neural networks. *IEEE International Symposium on Circuits and Systems*, 2011.
7. Wang, X. Calculation and validation of iron loss in laminated core of power and distribution transformers. *The International Journal for Computation and Mathematics in Electrical and Electronic*, 2014, vol. 33 página 1.

Ingenierías en línea

A TEXTO COMPLETO
DESDE EL NÚMERO 1

<http://ingenierias.uanl.mx>