

Force Profile Characterization for Thermostatic Bimetal using Extreme Learning Machine

Jose Martin Melchor-Leal and Jose Antonio Cantoral-Ceballos

Abstract—The force-displacement profile is a key parameter in manufacturing electric motor thermo-protectors, hence its accurate estimation helps preventing malfunctions due to overheating and/or short-circuits. In this research, we propose a novel force profile characterizer based on a Machine Learning algorithm (ML), the Extreme Learning Machine (ELM). Here, we combine the ELM with a Partial Average Test filter (PAT) to predict the behavior of thermostatic bimetallic strips. The computational efficiency inherent to ELMs allows the use of the algorithm (PAT-ELM) in real manufacturing environments, where computational resources tend to be limited and response time is of the utmost importance. The algorithm results were compared with actual measurements taken from production samples following ASTM B106-08, and the force-displacement profile of the thermostatic bimetallic strips measurements. The results show a correlation in excess of 86% including batches smaller than 50 samples. This result was constant even in cases where measurements were affected by noise present in industrial environments. The time required to obtain the strength profile was significantly lower than alternative methods, making this algorithm suitable for IoT systems.

Index Terms—Bimetallic Strip, Extreme Learning Machine, Characterization, Neural Network, Part Average Testing.

I. INTRODUCCIÓN

En la fabricación de protectores de motores eléctricos es de vital importancia conocer el perfil de fuerza en los bimetales termostáticos, el cual se obtiene mediante una caracterización de acuerdo con la norma ASTM B106-08. Los moto-protectores que utilizan como base el material bimetalico termostático se utilizan comúnmente para evitar daños debidos al sobrecalentamiento o cortocircuitos en motores eléctricos. Los bimetálicos termostáticos son un material compuesto, formado por dos o más capas metálicas con diferentes coeficientes de expansión térmica. Estas capas hacen que el material cambie su curvatura en respuesta a las variaciones de temperatura producida por el calentamiento o por una corriente eléctrica excesiva. La geometría ideal de un bimetalico termostático al ser expuesto a una temperatura definida T_c debe generar un movimiento rápido, casi instantáneo que desconecte el circuito eléctrico para proteger al motor de condiciones de funcionamiento anormales. Tradicionalmente, el proceso de ajuste inicial del formado de la curvatura del bimetalico termostático se lleva a cabo midiendo el tiempo de apertura y cierre al exponer el bimetalico a las temperaturas de prueba T_f y T_c inmediatamente después del curvado de la lámina termostática, así como la medición de la distancia de desplazamiento generado por el cambio de temperatura y la fuerza generada durante la transición. Esto es importante para fabricar un moto-protector funcional que sea duradero

y preciso. La medición en milisegundos de los tiempos de actuación a las temperaturas T_f y T_c se realizan mediante aplicación de aire caliente al material formado, y usando un micrófono muy sensible que detecta el momento de transición. Por ello, en esta investigación presentamos un algoritmo que mediante ML, estima el perfil de fuerza que produce una tira bimetalica termostática curvada al ser expuesta a las temperaturas T_f y T_c . Las siguientes secciones explican el funcionamiento del moto-protector basado en bimetalico termostático, el algoritmo PAT-ELM, así como su desarrollo a partir de la ELM básica, en combinación con el filtrado por prueba de promedios parciales PAT (por sus siglas en inglés). Finalmente, se explica cómo se genera el conjunto de datos de entrenamiento y la aplicación del PAT-ELM para determinar el perfil de fuerza para un conjunto de temperaturas T_f y T_c y características del bimetal dado. El algoritmo se comparó con las mediciones reales tomadas de unidades de producción siguiendo las recomendaciones de ASTM, incluso en los casos de información limitada o con ruido, típicos en los entornos de producción.

II. DEFINICIÓN DEL PROBLEMA

La motivación de esta investigación es proponer un caracterizador confiable que sea capaz de funcionar de forma estable en un ambiente de producción industrial y que pueda ser implementado utilizando solamente el perfil dinámico de desplazamiento-tiempo. Esto en tanto los sistemas de caracterización actuales son lentos y complejos, ya que requieren de muchas etapas de medición para confirmar que se cumplen los requisitos funcionales necesarios en moto protectores, además, estos bimetales usados en la caracterización son desechados, debido a que son expuestos a aceites u otros contaminantes durante las pruebas, adicionalmente la producción se ve interrumpida debido a los tiempos de espera usualmente largos mientras se realiza la caracterización, esto combinado con los bimetales desechados genera costos adicionales de producción [1], [2].

A. Moto-protector Térmico a Base de Bimetal Termostático

Los motores de inducción eléctrica son comunes en los escenarios industriales y domésticos, por ejemplo, en bombas, elevadores, grúas, compresores, ventiladores, trituradoras, molinos, y transportadores. Con una tasa de falla estimada del 3-5% y hasta el 12% en situaciones extremas, donde las estadísticas muestran que el sobrecalentamiento es uno de los principales responsables. Por lo tanto, el protector de motor juega un papel clave para minimizar este escenario de falla [3]. Por ejemplo, los motores de voltaje medio multifase

modernos (aunque en general son muy robustos y fiables) suelen funcionar muy cerca de sus límites térmicos, lo que hace que la protección térmica sea esencial [4]. La sobrecarga térmica debida a las variaciones de voltaje o de carga, los bloqueos del rotor o las fases en solitario son los principales responsables de las fallas del motor eléctrico, causando hasta el 44% de los casos de mal funcionamiento [5]. Los interruptores industriales estándar, activados por temperatura, se basan en tiras bimetalicas termostáticas que proporcionan la fuerza de disparo requerida para el accionamiento del protector [6].

B. Estructura de Moto-protector Basado en Bimetálico Termostático

Un moto-protector consta de una placa de material bimetalico y otra placa de material conductor mono-metal, esta última sirve como contacto estacionario, mientras que el material bimetalico funciona como un contacto móvil [7]. Estas dos placas metálicas usualmente están encapsuladas, de forma que no estén en contacto con el exterior y una de las placas pueda moverse libremente. El material que soporta ambas placas es usualmente, un material no conductor. Todo el conjunto se ensambla de tal forma que la placa bimetalica sea sensible, por conducción o radiación, a la temperatura que está monitoreando. La figura 1 muestra el detalle de un interruptor de temperatura indicando la posición de la tira bimetalica y la posición de las terminales eléctricas.

C. Cálculo de Curvatura y Fuerza en Bimetálico

La curvatura depende de la temperatura [8], las características del material, así como la fuerza desarrollada por la tira bimetalica, la desviación es importante para determinar el tiempo necesario para liberar el pestillo de disparo cuando se produce la sobrecarga.

En este sentido, el modelo matemático de Timoshenko [9] [10] [11] se ha usado ampliamente para determinar la curvatura de la tira, la ecuación 1 muestra el modelo.

$$\rho = \frac{t \cdot \left[3 \cdot (1 + m)^2 + (1 + m \cdot n) \left(m^2 + \frac{1}{m \cdot n} \right) \right]}{6 \cdot (\alpha_2 - \alpha_1) \cdot (T_f - T_c) \cdot (1 + m)^2} \quad (1)$$

donde ρ es el radio de curvatura, $t = t_1 + t_2$ es el grosor total de la tira bimetalica, t_1, t_2 son los grosores individuales de cada metal que forman al bimetálico, $m = \frac{t_1}{t_2}$ es la proporción de cada metal, E_2, E_1 es el módulo lineal de los dos metales, $n = \frac{E_1}{E_2}$ es la proporción de los módulos de Young's, α_2 y α_1 son los coeficientes de expansión térmica de los metales. Donde α_2 se asume que es numéricamente mayor que α_1 , T_c y T_f son las temperaturas caliente y temperatura fría inicial.

La fuerza de la tira bimetalica termostática [12] se explica con la siguientes ecuaciones. La ecuación 2 representa en forma reducida la deflexión de la tira que a su vez produce la fuerza de origen mecánico producida por la tira bimetalica representada en la ecuación 3 y la ecuación 4 explica la fuerza adicional de origen térmico producida.




Fig. 1. La figura muestra dos condiciones de curvatura de tira bimetalica termostática al ser expuesta a temperaturas diferentes, la temperatura T_f es la temperatura ambiente y la temperatura T_c una temperatura elevada, L es la longitud de la tira, t es el grosor y D es la distancia de separación entre ambas temperaturas.

$$B = \frac{0.53F(T_2 - T_1)L^2}{t} \quad (2)$$

$$P = \frac{4EBwt^3}{L^3} \quad (3)$$

$$P = \frac{2.12EF(T_2 - T_1)wt^2}{L} \quad (4)$$

t es el grosor de la tira bimetalica termostática, w es el ancho, L es la longitud, B es la deflexión, E es el módulo de elasticidad, F es la Flexibilidad, P es la fuerza en libras y $(T_2 - T_1)$ es la temperatura de cambio.

D. Caracterización del Bimetálico Termostático

La caracterización de un bimetalico termostático compatible para la fabricación de moto-protectores consiste en medir las propiedades mostradas en la tabla I [13] [14] [15] [12]. Sin embargo, dos de los parámetros de mayor importancia en la operación del protector son el desplazamiento a la temperatura y la fuerza de empuje (no mostrados en la tabla). La medición del desplazamiento en mm es realizado mediante un Transformador Diferencial de Variación Lineal o LVDT y la medición de fuerza en miligramos se realiza usando un sensor piezo-eléctrico. El proceso de caracterización consiste en sumergir consecutivamente en dos tanques de aceite a las temperaturas T_f que es la temperatura cuando debe estar cerrado el moto-protector y T_c que es la temperatura cuando debe estar abierto o disparado. El LVDT y el piezo-eléctrico realizan las mediciones simultáneamente al entrar a uno u otro tanque.

E. Medición Acorde ASTM B106-08.

La medición basada en la norma ASTM B106-08 es un método de prueba que determina la flexibilidad de los metales termostáticos donde la flexibilidad (F) se define como una

TABLA I
CARACTERÍSTICAS NECESARIAS DE UN BIMETAL TERMOSTÁTICO PARA
APLICACIONES DE MOTO-PROTECTOR TÉRMICO.

Descripción	Variable	Unidades
Radio de curvatura de placa	ρ	mm
Grosor del metal	t, t_1, t_2	mm
Módulo de elasticidad de Young	E, E_1, E_2	kgf/mm ²
Coefficiente de expansión térmica	$\alpha_1, \alpha_2, \dots, \alpha_n$	-
Temperatura de estado frío	T_f	°C
Temperatura de estado caliente	T_c	°C
Grosor de la placa termostática	ω	mm
Grosor de la placa termostática	ν	mm
Flexibilidad (Flexivity) de la placa	v	mm
Fuerza producida por la placa a T_c	P	Kgf
Longitud activa de la placa	L	mm
Dureza de la placa	H	mm
Planicidad	L_f	mm
Curvatura transversal	C_c	mm

medida de la tasa de desviación térmica o la desviación característica a cierta temperatura [16] [17]. La medición de la flexibilidad es una característica importante en esta investigación ya que es el origen de la curva fuerza-desplazamiento.

F. Medición de Curvatura Geométrica X-Y del Bimetálico Termostático.

La geometría de un bimetal termostático puede ser como se muestra en la figura 2. Las curvaturas del bimetálico determina el comportamiento de deformación elástica instantánea (o *Snap* en inglés) que va a permitir dar la propiedad de desconexión para el moto-protector eléctrico.

Sin embargo, debido al gran número de variables involucradas y a las variaciones inherentes al proceso de fabricación, este método no sólo es lento, sino que en muchas ocasiones no es preciso y genera material de desperdicio durante la fase de ajuste inicial y durante la elaboración del lote de producción.




Fig. 2. Se muestra un ejemplo de un bimetal termostático incluyendo el ensamble de los contactos eléctricos, esta es una de las muchas posibles geometrías y arreglo para su uso en moto protectores y es la forma en que típicamente debe realizarse la caracterización para aplicación industrial.

G. Caracterización del Perfil de Fuerza-desplazamiento a T_c .

Para generar un perfil de caracterización de fuerza-desplazamiento [14] a una temperatura fija usualmente es necesario utilizar un arreglo de varios equipos de medición [18]. Primero, para medir el desplazamiento del material termostático se utiliza un LVDT o un sensor medidor de

distancia láser y, para la medición de la fuerza generada se utiliza una galga extensiométrica. El espécimen de bimetálico a caracterizar se monta en un soporte que permite ambas mediciones simultáneamente y cuando el arreglo está completo se pone dentro de una cámara térmica a una temperatura específica T_c , también puede utilizarse un contenedor de aceite con agitador [19] [20]. Una vez que el espécimen está dentro de la cámara térmica (o en el contenedor) se gráfica tanto la fuerza como el desplazamiento que genera, asegurándose de cubrir la temperatura y desplazamiento del snap. Una vez disparado el bimetal, se necesita ser constante [MM: coregido se deja bimetalico 09-06-19] se pasa a una nueva cámara térmica a la temperatura de cierre T_f donde se continúa graficando hasta regresar a la posición inicial. La figura 3 da un ejemplo de una muestra caracterizada usando el método descrito en esta sección.

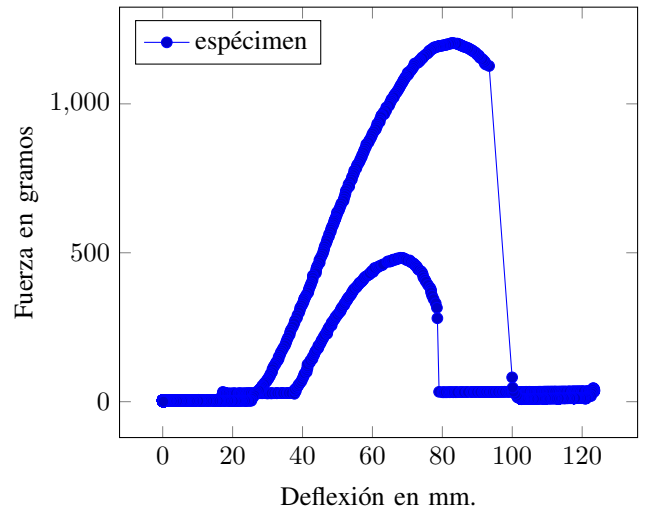


Fig. 3. Gráfica que muestra el perfil fuerza-distancia de un bimetal termostático, el eje de horizontal muestra la distancia y el eje vertical la fuerza generada al exponerse a la temperatura T_c iniciando en T_f .

III. SOLUCIÓN PROPUESTA

A. Algoritmo PAT-ELM

El propósito del algoritmo propuesto (PAT-ELM) es generar un modelo predictivo del comportamiento del perfil de fuerza usando datos del desplazamiento dinámico del bimetálico termostático, reduciendo así la necesidad de realizar mediciones adicionales para determinar si una placa bimetalica formada cumple los requisitos para poder usarse apropiadamente en un moto-protector. El algoritmo se genera al combinar el filtro dinámico PAT que elimina los datos anormales y permite al algoritmo ELM aprender solamente información relevante.

B. Filtrado de Datos Anormales Mediante Prueba de Promedios Parciales (PAT).

La Prueba de Promedios Parciales (PAT por sus siglas en inglés) es un método estadístico que permite eliminar mediciones anormales o valores atípicos utilizando lo que se conoce como la media robusta (ecuación 5) y la sigma robusta (ecuación 6 y ecuación 7) [21] [22]. Los límites PAT

dinámicos [23] [24] al inicio del lote de producción tienen el mismo valor que los límites estáticos, ejemplo de esto son los límites de tiempo de apertura y cierre de la tira bimetalica que son definidos por el diseño de la geometría del material termostático [25] [26]. A medida que se van midiendo más muestras del lote, se usan los datos para re-calcular el valor sigma (σ) a la sigma robusta, esto se aprovecha para reducir los límites a $\pm 3 \sigma$ del lote en proceso, que normalmente son más pequeños que los límites del diseño. Cualquier dato que está por encima o por debajo de los nuevos límites es descartado, esto permite descartar las mediciones atípicas que podrían sesgar el aprendizaje de la red neuronal. La ventaja de utilizar este tipo de filtrado es su facilidad de implementación y que se puede aplicar a cada una de las variables de entrada del sistema a controlar. El filtro se reinicia con cada lote de producción, por lo que solamente se detectan partes anormales por lote de producción.

$$\bar{x}_{robusta} = Q_{1,3} - \frac{IQR}{2} \quad (5)$$

$$PAT_{limiteinferior} = Q_1 - \frac{(x_i - 0.675)}{1.35}(Q_3 - Q_1) \quad (6)$$

$$PAT_{limitesuperior} = Q_3 + \frac{(x_i - 0.675)}{1.35}(Q_3 - Q_1) \quad (7)$$

La ecuación 5 muestra la media robusta y las ecuaciones 6 y 7 los límites superior e inferior, aplicando la sigma robusta.

$$x_{PAT} = \begin{cases} \rho = x_\alpha < Q_1 - \frac{(x_i - 0.675)}{1.35}(Q_3 - Q_1) \rightarrow \text{Borrar} \\ \vartheta = X_\alpha > Q_3 + \frac{(x_i - 0.675)}{1.35}(Q_3 - Q_1) \rightarrow \text{Borrar} \\ \rho < x_\alpha < \vartheta \rightarrow x_{filterado} = x_\alpha \end{cases}$$

La ecuación 8 muestra la salida de los intervalos válidos en donde se eliminan los datos atípicos y solo deja pasar los datos filtrados.

$$x_{PAT} = x_{filterado} - \rho - \vartheta \quad (8)$$

La figura 4 muestra cómo se van adaptando los límites superior e inferior en el filtrado PAT [28] [30] que se van limitando de acuerdo a la variación natural de las mediciones conforme se van generando. El límite inferior en color café no tiene ninguna medición que lo sobrepase, sin embargo, en el límite superior en color rojo hay una medición que sobrepasa su límite, por lo que representa una anomalía que está fuera de la variación natural de ese lote de producción.

C. Extreme Learning Machine

Las redes neuronales artificiales se utilizan de forma habitual en diversos campos debido a su capacidad para aproximar funciones no lineales y modelar fenómenos complejos en los que es complicado aplicar otras técnicas tradicionales [27]. El teorema de aproximación universal establece que una red

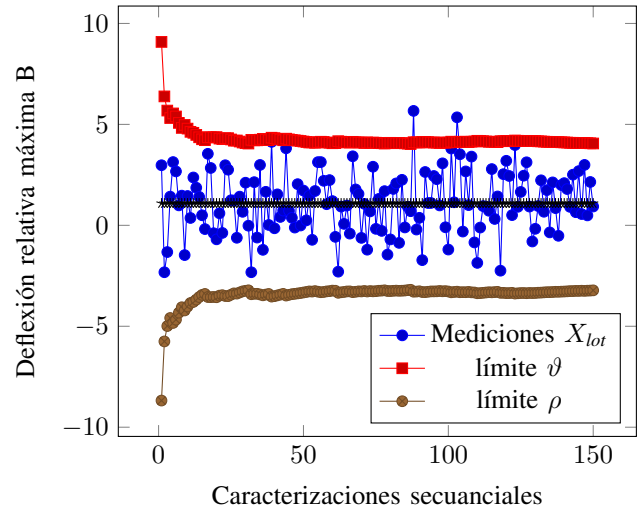


Fig. 4. Ejemplo de datos de caracterización al pasar por la primera etapa del algoritmo usando la técnica de *part average testing* (PAT), las mediciones que están fuera de las líneas de límite ϑ o ρ son descartados ya que son datos anormales.

neuronal de una sola capa oculta y un número finito de nodos pueden aproximar cualquier función continua con una exactitud arbitraria [28] [29]. En este sentido, se necesita ajustar todos los parámetros del modelo neuronal y existe una relación entre los parámetros de las diferentes capas, donde la mayor parte de los algoritmos destinados a optimizar dichos parámetros están basados en métodos iterativos, principalmente en técnicas de descenso por gradiente. Aunque estos métodos ofrecen buenos resultados, el tiempo requerido para calcular los parámetros óptimos suele ser elevado [30], [31].

$$f_L(x) = \sum_{i=1}^L \beta_i G(a_i, b_i, x) \quad (9)$$

$$\beta = H^\dagger T \quad (10)$$

$$\sum_{i=1}^L \beta_i g_i(x_j) = \sum_{i=1}^L \beta_i G(a_i, b_i, x_j) = O_j \quad j = 1, 2, \dots, N \quad (11)$$

Las máquinas de aprendizaje extremo, son redes neuronales del tipo SLFN (Single Layer Feed Forward Network) cuyos parámetros se han determinado mediante el algoritmo ELM. Dicho algoritmo, propuesto por Huang et al [32] [33], se caracteriza por calcular los parámetros de forma analítica. Huang demostró que se pueden asignar aleatoriamente los pesos y sesgos de la capa oculta, sin afectar la capacidad de la red de aprender las distintas observaciones. Esto implica que no es necesario ajustar todos los parámetros de la red. El algoritmo ELM se basa en este principio para ajustar únicamente los parámetros de la capa de salida. Dado un conjunto D de N observaciones, el objetivo del algoritmo ELM es encontrar una relación entre las variables independientes X_i y las dependientes O_i . Dada la naturaleza del problema que

estudiamos, en esta investigación nos centramos en el caso de aproximar funciones con una única salida, por lo tanto $d2 = 1$. La salida de una red SLFN con M nodos ocultos viene dado por la ecuación 12.

$$\sum_{i=1}^L \beta_i G(a_i, b_i, x_j) = t_j \quad j = 1, 2, \dots, N \quad (12)$$

$$f_L(x) = \sum_{i=1}^L \beta_i G(a_i, b_i, x) = t_j \quad (13)$$

$$H\beta = T \quad (14)$$

donde:

$$H = \begin{pmatrix} G(a_1, b_1, x_1) & \cdots & G(a_L, b_L, x_1) \\ G(a_1, b_1, x_2) & \cdots & G(a_L, b_L, x_2) \\ \vdots & \ddots & \vdots \\ G(a_1, b_1, x_N) & \cdots & G(a_L, b_L, x_N) \end{pmatrix}_{N \times L} \quad (15)$$

$$\beta = \begin{pmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_L^T \end{pmatrix}_{L \times M} \quad (16)$$

$$T = \begin{pmatrix} T_1^T \\ T_2^T \\ \vdots \\ T_L^T \end{pmatrix}_{N \times M} \quad (17)$$

H es llamada matriz de salida de la capa oculta.

Las tres fases del entrenamiento de las capas ocultas se muestran a continuación:

- Generación aleatoria de los pesos y los sesgos de la capa oculta.
- Cálculo de la matriz H .
- Cálculo de los pesos de la matriz de salida β :

$$\beta = H^\dagger T \quad (18)$$

Donde H^\dagger es la matriz Inversa de Moore-Penrose.

El algoritmo ELM puede ser utilizado en actividades de predicción en tiempo real o cuando no existe una gran cantidad de datos de entrenamiento, esto por su rápida velocidad de aprendizaje al realizarse de forma analítica, así como su alta adaptabilidad, por lo que se usa como algoritmo base para el simulador [33] [34] [35].

Algorithm 1 Algoritmo propuesto para simulador PAT-ELM

Required: Carga la base de datos $x_{PAT}(N.x, N.y)$

- 1: Calcula la variación natural basada en t muestras.
- 2: Elimina los datos anormales de fuera de $\pm 3 \sigma$.
- 3: Genera la matriz filtrada $x_{PAT}(N.x, N.y)$.
- 4: Inicializa nodos, capa oculta L , y activación $g(x)$.
- 5: Lee $N = \{x_i, t_i \mid x_i \in R^n, t_i \in R^m, i = 1, \dots, N\}$
- 6: Define si es una regresión o una categorización.
- 7: Asigna pesos w_i y sesgos b_i aleatoriamente.
- 8: Calcula matriz capa oculta H basada en función $g(x)$.
- 9: Calcula los pesos de salida $\beta : \beta = H^\dagger$ donde H^\dagger es la matriz inversa generalizada de Moore-Penrose H .

D. Algoritmo PAT-ELM Propuesto

El algoritmo propuesto está usando un ELM para obtener un simulador que logre trabajar con una cantidad mínima de datos de entrenamiento.

La primera sección del algoritmo elimina los valores atípicos en el conjunto de datos para minimizar el ruido inducido por el equipo de medición y la variación debida a la variabilidad en el entorno de fabricación.

E. Aplicación del PAT-ELM para Caracterización

Un algoritmo selector utiliza el vector de datos de entrada como la información geométrica y características del material termostático mencionadas en la tabla I, y selecciona la red PAT-ELM para el bimetal a analizar. La siguiente fase es la etapa de entrenamiento, que utiliza una matriz que representa el perfil de desplazamiento dinámico y lo relaciona con la salida en la caracterización del perfil fuerza. Este paso es la fase inicial de entrenamiento del algoritmo, que una vez concluido, puede usarse para predecir el perfil de fuerza resultante de este tipo de configuración de bimetal termostático.

F. Dispositivo Medición Gradiente de Desplazamiento a T_c

El dispositivo utilizado para la medición del gradiente de desplazamiento a temperatura fija se muestra en la figura 5, el cuál se basa en una celda de fuerza o sensor extensiométrico que mide la fuerza que produce el bimetal durante la exposición a la temperatura fija T_c , y, simultáneamente un sensor LVDT determina el desplazamiento que experimenta. Para lograr la medición de fuerza, la galga extensiométrica es pre-cargada con un 50% de la fuerza teórica esperada $F_{precarga}$, mientras que la fuerza que se produce durante el desplazamiento es la delta de la fuerza de pre-carga y la medición $F_{real} = F_{medida} - F_{precarga}$.

G. Preparación de Datos y Condiciones Experimentales

Se seleccionan muestras aleatorias de diferentes grupos de bimetales termostáticos y se colocan en la cámara térmica a una temperatura de 135 °C y se genera la matriz de tiempo-desplazamiento hasta que se realiza la acción de snap. Posteriormente, la cámara térmica cambia a 25 °C y se repite el proceso. A continuación, cada una de las muestras son




Fig. 5. Prototipo de caracterizador para la medición dinámica del desplazamiento de la tira bimetálica curvado a T_c . Se basa en un medidor de distancia mediante un LVDT.




Fig. 6. Familia de curvas de la fuerza generada por la tira termostática al exponerla a T_c iniciando a temperatura T_f , el eje vertical es el tiempo y el eje vertical es la fuerza.

caracterizadas con el método B 106-08 en donde se determina el perfil de fuerza-desplazamiento. Se agregan los datos característicos del bimetálico como espesores, coeficiente de expansión térmica, entre otros, creando un vector de identificación por cada muestra. Todos estos datos son alimentados durante el proceso de aprendizaje del algoritmo PAT-ELM. Los parámetros usados en el algoritmo se establecen como nodos ocultos $L = 30$ y 100 muestras.

H. Salida Pronosticada por Algoritmo PAT-ELM

La salida del algoritmo es un perfil de fuerza que representa el comportamiento real del bimetal termostático al exponerse a dos temperaturas T_f y T_c . En una matriz de 2×350 la cual puede ser utilizada posteriormente para determinar la curvatura óptima para un interruptor termoelectrónico basado en el bimetálico. la figura 7 muestra el perfil dinámico de desplazamiento que se alimenta a la red neuronal PAT-ELM y la figura 6 muestra el perfil de fuerza de pronostico, ambas gráficas son gráficas de área donde se ve en superposición deferentes resultados del algoritmo PAT-ELM.

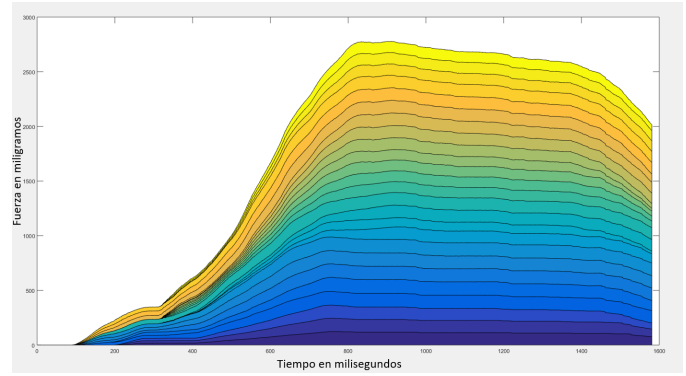


Fig. 7. Familia de curvas de la desplazamiento generado por la tira termostática al exponerla a T_c iniciando desde la temperatura a T_f .

I. Indicadores de Desempeño

El desempeño del modelo es evaluado usando los siguientes indicadores: coeficiente de correlación R que proporciona una medida de la variabilidad de los pronósticos producidos por el modelo; el error absoluto promedio MAE y la raíz cuadrada del error medio $RMSE$ que mide los errores residuales. Estos indicadores en conjunto proporcionan una idea global de las diferencias entre las observaciones y el algoritmo.

$$R^2 = 1 - \frac{F}{F_0}; F = \sum (Y_i - \hat{Y}_i)^2; F_0 = \sum (Y_i - \bar{Y}_i)^2 \quad (19)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y}_i)^2 \quad (20)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y}_i)^2} \quad (21)$$

Donde n es el número de muestras, Y_i y \bar{Y}_i son observaciones así como Y_i y \bar{Y}_i son los resultados de los modelos.

J. Análisis de Desempeño Algoritmo PAT-ELM

Comparando los indicadores de desempeño que se muestran en la tabla II podemos analizar el desempeño del algoritmo, los indicadores son: Fuerza máxima alcanzada para la apertura medida en equipo de caracterización original F_{Medida} , Fuerza máxima pronosticada por modelo PAT-ELM para la apertura del bimetal $F_{PAT-ELM}$, Tiempo de apertura a temperatura de disparo T_c $T_{apertura}$, Tiempo de cierre a temperatura baja (T_f) T_{cierre} , Correlación R^2 entre perfil de fuerza medido vs perfil de fuerza pronosticado.

IV. RESULTADOS

Durante la experimentación se analizaron siete grupos de tiras bimetálicas, cada grupo se compuso de 50 muestras. El tamaño de muestra fue seleccionado porque representa un número típico de piezas que se pueden obtener al iniciar la

TABLA II
ANÁLISIS DE CORRELACIÓN ENTRE EL MODELO Y LAS MEDICIONES DE
VARIOS GRUPOS DE PRUEBA.

Grupo	F_M	$F_{PAT-ELM}$	T_a	T_c	R^2
28.6 x 12.7 A	1117	1100	0.13	0.21	0.82
21.1 x 9.4 A	897	860	0.12	0.22	0.87
16.2 x 7.8 A	937	926	0.12	0.21	0.85
28.6 x 12.7 B	1085	1050	0.12	0.23	0.71
21.1 x 9.4 B	1149	1078	0.14	0.24	0.72
16.2 x 7.8 A	906	1004	0.16	0.21	0.92

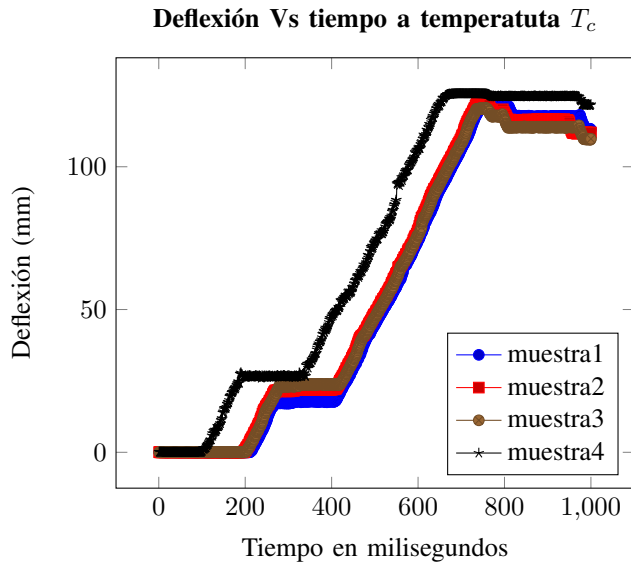


Fig. 8. Perfil de desplazamiento de varias tiras bimetalicas al exponerlas en el tester a la temperatura de prueba T_c , el eje horizontal muestra el tiempo en mili-segundos en que ocurre el desplazamiento y el eje vertical representa el desplazamiento de la tira desde posición a temperatura T_f hasta posición final cuando alcanza la temperatura T_c .

producción de un moto-protector, un número mayor no es normalmente justificable por el costo de los materiales. El objetivo de analizar los siete grupos es determinar si es posible confiar en los resultados de pronóstico del simulador, comparándolos con los resultados medidos de los mismos grupos. Para realizar la comparación se utilizan los índices estadísticos correlación, MAE y RMSE. Podemos interpretar que el índice estadístico de correlación indica si existe una relación entre dos variables, en este caso el perfil de fuerza medida y el perfil de fuerza pronosticada, donde esperamos ver que los valores del pronóstico del simulador varíen sistemáticamente con los valores de las mediciones realizadas. Para interpretar el resultado de correlación, un valor de 1 significa que tanto la medición como el pronóstico varían en la misma dirección y en la misma proporción, por lo que se consideran iguales. Resultados de 0 ó cercanos a éste significan que no son iguales. Los índices estadísticos MAE y RMSE representan el error que existe entre la medición y el pronóstico de la red neuronal y qué tanta dispersión existe entre ambos. Por lo tanto, se puede interpretar que entre más pequeños sean ambos índices estadísticos existe menos error y menos variación en el pronóstico de la red neuronal. La tabla II indica los grupos experimentales, la fuerza medida promedio del grupo F_m , la

fuerza pronosticada por la red neuronal PAT-ELM, el tiempo de apertura del bimet al exponerse a la temperatura de snap, el tiempo para volver a la posición original al exponerse a la temperatura baja T_c , y por último el índice estadístico de correlación entre la medición de la fuerza que produce la tira bimetalica y el pronóstico generado por la red neuronal PAT-ELM.

A. Índices Estadísticos

La tabla II muestra resultados de correlación que van desde 0.71 a 0.92, lo que implica que el pronóstico de la red neuronal PAT-ELM tiene similitud a las mediciones tomadas a los mismos grupos. Normalmente para este tipo de modelos, correlaciones menores a 0.5 son descartadas, pero en este caso, todos los índices de correlación de cada uno de los grupos están por encima de este criterio de aceptación. Esto significa que con 50 muestras muchos de estos modelos pueden utilizarse en un ambiente de producción industrial, ya que el material que se utilice para el entrenamiento no tendrá un alto impacto económico. Otros dos métricos utilizados para analizar los resultados de la red neuronal PAT-ELM fueron el análisis de precisión y generalización también conocidos como *training error* y *test error*, este análisis nos permite evaluar la capacidad de generalización del modelo en otros lotes de producción del mismo tipo de bimet al y geometría. La tabla III muestra los indicadores de desempeño donde podemos observar que la correlación R en el caso de precisión, es decir, la capacidad de predecir el perfil de fuerza del lote de producción de donde se obtuvieron las piezas de entrenamiento es de 0.86492, lo que significa que tiene una buena capacidad de predecir el perfil de fuerza con respecto a las mediciones reales. La correlación con respecto a generalización es 0.83217, 3.3% menor con respecto a la precisión, la cual sigue siendo adecuada para predecir el perfil de fuerza aún cuando las muestras no sean del mismo lote de producción que se está evaluando en la red neuronal. El índice estadístico de promedio de error absoluto MAE en el caso del lote de producción donde se obtuvieron las piezas es 0.199776 que, aunque relativamente alto, puede ser mejorado significativamente si se incrementa el número de muestras de entrenamiento. Este error absoluto permite determinar si el lote de producción puede utilizarse o no para la fabricación de los moto protectores. En el caso del índice MAE para generalización, éste se incrementa a 0.23663, el cual sigue siendo adecuado para su utilización en los moto protectores. Es importante notar que éste puede reducirse si se incrementa el tamaño de muestra. Por último, el índice estadístico RMSE tanto 0.25798 como 0.30129 indican una variabilidad normal asociada a este tipo de predicción, la cual se considera dentro de los límites normales.

El impacto del simulador de red neuronal PAT-ELM tomando en cuenta los resultados de las tablas II y III indica que puede ser utilizado para predecir el perfil de fuerza de una tira bimetalica termostática reduciendo significativamente el material de desperdicio que se produce al estar caracterizando estos materiales.

TABLA III
INDICADORES DEL DESEMPEÑO DEL ALGORITMO PAT-ELM DESPUÉS DE ENTRENAMIENTO.

Indicador	Precisión	Generalización
R^2	0.86492	0.83217
MAE	0.19976	0.23663
$RMSE$	0.25798	0.30129

V. CONCLUSIONES

En esta investigación proponemos un novedoso sistema de caracterización que puede ser utilizado en aplicaciones industriales, en especial para la fabricación de moto-protectores térmicos. Está basado en un algoritmo de máquina de aprendizaje extremo ELM y el filtrado dinámico por prueba de promedios parciales PAT. Los resultados obtenidos muestran una variación de 3% entre las mediciones realizadas siguiendo el estándar ASTM y las predicciones arrojadas por nuestro algoritmo. Este resultado es relevante debido a que esta variabilidad es aceptable para los estándares industriales seguidos en la fabricación de moto-protectores. Por esto, el algoritmo propuesto puede reducir el desperdicio de material termostático usado en el arranque y control del formado de las tiras bimetalicas que puede llegar a 10% de la producción, mientras que la cantidad de horas hombre dedicadas a los procesos de caracterización se reducirán en un 40%. El impacto de desperdicio representa ahorros de hasta un 20% en proceso de producción ya que no solamente se evita tirar las piezas de prueba, sino que ayuda a evitar que entre a la línea de producción material que no cumpla los requisitos para la fabricación de moto protectores eléctricos. Este algoritmo puede ser adaptado otros procesos industriales, por lo que se seguirá evaluando en nuevas aplicaciones.

AGRADECIMIENTOS

Los autores desean agradecer al Centro de Tecnología Avanzada (CIATEQ A.C.) por su apoyo durante esta investigación. Del mismo modo, JMML desea expresar su agradecimiento al Consejo Nacional de Ciencia y Tecnología (CONACYT) por su apoyo financiero para realizar estudios de doctorado.

REFERENCES

- [1] A. Nahar, K. M. Butler, J. M. Carulli, and C. Weinberger, "Quality improvement and cost reduction using statistical outlier methods," in *2009 IEEE International Conference on Computer Design*, pp. 64–69, 2009.
- [2] S. Tammali, "Industrial practices of test cost reduction: Perspective, current design practices," in *2010 28th VLSI Test Symposium (VTS)*, pp. 124–124, 2010.
- [3] A. Gedzurs, "Temperature protection methods of induction motor," vol. volume 1, pp. 258–263.
- [4] Akshay S. Kulkarni1 and Sunita P. Ugale2, "Advanced Thermal Overload Protection for High Tension Motors Using Digital Protection Relays," in *IEEE International Conference on Computer, Communication and Control (IC4-2015)*, 2015.
- [5] J. Narhare, H. Patil, S. Patil, and M. Patted, "Protection Schemes for Three Phase Induction Motor," *International Research Journal of Engineering and Technology (IRJET)*, vol. 04, no. 03, p. 3, 2017.
- [6] John R. D'Entremont,, "An Improved Method for Selecting Thermal Overloads to Provide Half Voltage Protection," p. Paper 169., Purdue University, 1976.
- [7] R. a. A.-C. E. American Society of Heating, Inc., "Refrigerant control devices," in *2014 ASHRAE Handbook - Refrigeration (I-P Edition)*, p. 11.2, American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc., 2014.
- [8] J. Zang and F. Liu, "Modified Timoshenko formula for bending of ultrathin strained bilayer films," *Applied Physics Letters*, vol. 92, p. 021905, Jan. 2008.
- [9] G. D. Angel and G. Haritos, "An Immediate Formula for the Radius of Curvature of A Bimetallic Strip," *International Journal of Engineering Research*, vol. 2, no. 12, p. 8, 2013.
- [10] M. Zelenka, "Calculation and measurement of thermostatic bimetal deflection in molded case circuit breaker," p. 467, 2016.
- [11] Amol Madhav Khatkhate, Manno Paul Singh, P T Mirchandani, and Rizvi College of Engineering, "A Parametric Approximation for the Radius of Curvature of a Bimetallic Strip," *International Journal of Engineering Research and*, vol. V6, June 2017.
- [12] Wickeder Group, "Thermostatic Bimetal Designer's Guide," 2016.
- [13] G. D. Angel, *Optimization and characterization of a curved bimetallic blade and its performance within a thermal motor*. PhD thesis, University of Hertfordshire School of Engineering and Technology, 2014.
- [14] A. Caliskan and A. Onat, "The characterization of bimetal disks used for thermostatic control and over-temperature protection," *The Online Journal of Science and Technology*, vol. 7, no. 4, p. 8, 2017.
- [15] I. R. Sinclair, *Sensors and transducers*. Oxford [England] ; Boston: Elsevier, 3rd ed ed., 2001.
- [16] B02 Committee, "Test Methods for Flexivity of Thermostat Metals ASTM B106-08," tech. rep., ASTM International, 2013.
- [17] "Middlesex Statistical Process Tools," 2016.
- [18] Kanthal AB, a Sandvik brand, *Kanthal Thermostatic bimetal handbook*. 2008.
- [19] Shivalik, "Shivalik thermostatic bimetal handbook," 2012.
- [20] "Hitachi Bimetals," 2008.
- [21] Tim Haifey and Frank McNally, *Guidelines for part average testing AEC - Q001 Rev-D*. Component Technical Commite, automotive electronics council ed.
- [22] H. Felding, *Implications on ASIC production tests for Fingerprint Cards AB - new requirements and yield consequences*. PhD thesis, Department of electrical and information technology, Lund University, Sweden, 2017.
- [23] M. Ray, "Dynamic Parts Average Testing in Real-time," June 2005.
- [24] E. Marinissen, A. Singh, D. Glotter, M. Esposito, J. M. Carulli Jr, A. Nahar, K. Butler, D. Appello, and C. Portelli, "Adapting to adaptive testing," (Dresden, Germany), ResearchGate, Mar. 2010.
- [25] N. Patterson, "A Robust, Non-Parametric Method to Identify Outliers and Improve Final Yield and Quality," (Boston, Massachusetts, USA), p. 3, Apr. 2012.
- [26] D. Pihlaja, "Real Time Dynamic Application of Part Average Testing (PAT) at Final Test," (New Orleans, Louisiana, USA), pp. 165 – 168, May 2013.
- [27] P. V. d. C. Souza, "Pruning method in the architecture of extreme learning machines based on partial least squares regression," *IEEE Latin America Transactions*, vol. 16, no. 12, pp. 2864–2871, 2018.
- [28] G.-B. Huang, "An Insight into Extreme Learning Machines: Random Neurons, Random Features and Kernels," *Cognitive Computation*, vol. 6, pp. 376–390, Sept. 2014.
- [29] L. L. C. Kasun, Y. Yang, G.-B. Huang, and Z. Zhang, "Dimension Reduction With Extreme Learning Machine," *IEEE Transactions on Image Processing*, vol. 25, pp. 3906–3918, Aug. 2016.
- [30] D. P. Mesquita, J. Gomes, L. R. Rodrigues, and R. K. Galvao, "Pruning Extreme Learning Machines Using the Successive Projections Algorithm," *IEEE Latin America Transactions*, vol. 13, no. 12, pp. 3974–3979, 2015.
- [31] L. L. C. Kasun, H. Zhou, G.-B. Huang, and C. M. Vong, "Representational Learning with Extreme Learning Machine for Big Data," p. 4, 2013.
- [32] G.-B. Huang, "What are Extreme Learning Machines? Filling the Gap Between Frank Rosenblatt's Dream and John von Neumann's Puzzle," *Cognitive Computation*, vol. 7, pp. 263–278, June 2015.
- [33] S. Xu and J. Wang, "A fast incremental extreme learning machine algorithm for data streams classification," *Expert Systems with Applications*, vol. 65, pp. 332–344, Dec. 2016.
- [34] Yin JC, Li GS, and Hu JQ, "A Modular Prediction Mechanism Based on Sequential Extreme Learning Machine with Application to Real-Time Tidal Prediction.," *Extreme Learning Machines 2013: Algorithms and Applications. Adaptation, Learning, and Optimization*, vol. vol 16, 2014.

- [35] T. Hussain, S. M. Siniscalchi, C.-C. Lee, S.-S. Wang, Y. Tsao, and W.-H. Liao, "Experimental Study on Extreme Learning Machine Applications for Speech Enhancement," *IEEE Access*, vol. 5, pp. 25542–25554, 2017.



José Martín Melchor-Leal (M.Sc.) received the M.Sc. in Advanced Manufacturing by the Advanced Technology Center CIATEQ, Mexico in 2014. He earned the B.Sc. degree in Electronics from the Aguascalientes Institute of Technology, Mexico, in 1993. In 1998, he joined Texas Instrument, now, Sensata Technologies Inc. working on the design and manufacturing of a variety of automotive sensors and motor-protectors. Currently, he is pursuing the Ph.D. degree in Advanced Manufacturing at the CIATEQ, with a focus on the use of machine

learning methods on advanced manufacturing applications. His research interests include machine learning, robotics, sensing, embedded systems, expert systems, intelligent automation, and adaptive control systems. josemartinmelchor@ciateq.edu.mx



Jose A. Cantoral-Ceballos (Ph.D., M.Sc., MIEEE) received the B.Sc. (Excellence Hons.) degree in electronic and communications engineering from the Tec de Monterrey, Queretaro, Mexico, in 2005, and the M.Sc. (Distinction) and Ph.D. degrees from the University of Manchester, Manchester, U.K., in 2009 and 2013, respectively, with a focus on algorithms for tomography imaging in embedded systems. During 2013-2014 he was a Post-Doctoral Research Associate at the University of Manchester where he worked on the design and development of

a tomography data acquisition system, as well as imaging algorithms from limited views. From 2015 to 2020 he was at the Advanced Technology Center (CIATEQ A.C.), Mexico, where his research efforts focused on the study of novel Deep Learning methods to solve Digital Signal Processing and Energy problems. Currently, he is a Professor-Researcher at the Tec de Monterrey, Queretaro, in the department of Computer Science, where he continues his research on Deep Learning solutions to different problems, in particular to the study of neurological signals. Dr. Cantoral-Ceballos was the recipient of the National Instruments Prize for his M.Sc. dissertation in 2009 and the Best Technical Presentation Award at the Seventh World Congress of Industrial Process Tomography (WCIPT), Krakow, in 2013. joseantonio.cantoral@tec.mx