



II CAIM 2010
Segundo Congreso Argentino
de Ingeniería Mecánica
San Juan - Noviembre 2010

SISTEMAS DE COMPENSACIÓN TÉRMICA PARA MEDICIONES DE DEFORMACIÓN EN ELEMENTOS ESTRUCTURALES SOMETIDOS A ESFUERZOS. Parte 2: Análisis Experimental

Gustavo G. Vignolo^{1,2}, José A. Vázquez³ y Axel J. Soto^{2,4}

¹ Facultad de Ingeniería, Universidad Nacional de la Patagonia San Juan Bosco
Ruta Prov. Nº 1, Km. 4, (9000) Comodoro Rivadavia, Argentina

² Planta Piloto de Ingeniería Química (PLAPIQUI) – Universidad Nacional del Sur – CONICET Camino La Carrindanga km. 7 – CC 717, (8000) Bahía Blanca, Argentina –
e-mail: gvignolo@plapiqui.edu.ar

³ Departamento de Desarrollo Técnico, Tecnología en Sistemas y Servicios S.R.L.
Álvarez Jonte 158, Km. 5, (9000) Comodoro Rivadavia, Argentina –

⁴ Dpto. de Ciencias e Ingeniería de la Computación, Universidad Nacional del Sur
Av. Alem 1253, (8000) Bahía Blanca, Argentina

RESUMEN

La medición de deformaciones en elementos estructurales es una tarea que requiere extremas precauciones tanto en el diseño y montaje del elemento de medición como en la interpretación de las lecturas. En general, en el cálculo resistente de estructuras se dimensionan los elementos que la conforman de modo que sean capaces de soportar las cargas aplicadas y que la deformación que éstos sufren no afecte su desempeño normal. Este concepto produce una complicación mayor al momento de medir las deformaciones provocadas por las cargas dado que, como premisa de diseño, tales deformaciones deben ser pequeñas. Como consecuencia, la magnitud de las deformaciones de interés son del mismo orden que las provocadas por factores externos como es el caso de la dilatación térmica.

En este trabajo se estudia la manera en que la dilatación térmica afecta las mediciones de deformación sobre una viga sometida a esfuerzos efectuadas mediante el uso de un dispositivo específico, y se presentan alternativas para compensar tales mediciones de modo que la lectura final sólo contenga la información deseada. El sistema de interés se compone de una viga de gran tamaño en la que se dispone un instrumento de medición de deformación en paralelo y un termómetro que determina la temperatura del ambiente. Las masas involucradas en cada uno de los elementos hacen que las variaciones en el tiempo de sus temperaturas sean muy distintas y, en consecuencia, también lo son las dilataciones térmicas asociadas. Para comprender y compensar este fenómeno, se presenta en la primer parte del trabajo el estudio del fenómeno físico que vincula el calor aportado al sistema y las masas y temperaturas de los elementos involucrados. En la segunda parte se analizan mediciones experimentales y se propone un modelo computacional basado en la optimización de redes neuronales artificiales. El mismo es formulado para predecir la variación en la lectura de la carga aplicada en función de la temperatura y de la variación de la temperatura y la carga en el tiempo.

Palabras Claves: Strain gage, deformación, dilatación térmica, redes neuronales.

1. INTRODUCCIÓN

Tanto el diseño de componentes para máquinas y estructuras que soportan carga como el monitoreo de su funcionamiento requieren información sobre la distribución de fuerzas dentro de los mismos. El diseño correcto de dispositivos mecánicos debe considerar la resistencia y deflexiones máximas permisibles [1]. El monitoreo de su funcionamiento debe contemplar que las cargas aplicadas no superen a las de diseño. La mecánica de materiales proporciona la base para predecir las características esenciales del diseño mecánico y suministra la comprensión fundamental del comportamiento de partes sometidas a esfuerzo [1,2]. De este modo, el seguimiento del trabajo de una máquina puede hacerse mediante mediciones específicas en aquellos elementos más comprometidos.

Si bien existen diversos métodos para determinar el estado de marcha de un equipo, resulta de interés en este trabajo la determinación de esfuerzos mediante la medición de deformación. En particular, el aspecto referente a la comprensión y compensación de deformaciones aparentes, que no existen en el elemento sensado, pero que son registradas por el medidor. Estas fuentes de error presentes en la instalación de indicadores de deformación pueden deberse a la variación de la temperatura, histéresis, creep, fatiga y/o humedad, entre otros [3]. De ellas, las variaciones térmicas son las más frecuentes y por ende son las de mayor interés. Ha sido probado que cambios normales de temperatura ambiente pueden llegar a inducir errores del orden de la medición que se desea determinar [3].

En el presente trabajo se desarrolla el estudio de la respuesta en la señal generada por un medidor de deformación ante estímulos térmicos externos. En particular, se estudia el comportamiento ante un salto escalón en el flujo de calor actuante sobre el sistema. Con el objetivo de ejemplificar el análisis, el estudio se centra sobre el comportamiento de un dispositivo medidor de deformación desarrollado previamente, y descrito en [4 y 5], aunque la metodología puede extenderse a otras configuraciones. En la primera parte del trabajo se ha descrito el fenómeno físico que produce la deriva de la señal. En esta segunda parte se analizan resultados experimentales y se propone un algoritmo basado en redes neuronales artificiales para compensar este fenómeno.

2. ENSAYOS EXPERIMENTALES

Un dispositivo como el analizado en la Parte 1 del presente trabajo, y detallado en [4 y 5], ha sido sometido a ensayos experimentales de campo. Para ello se montó el mismo sobre la viga principal de un Aparato Individual de Bombeo Mecánico de Petróleo (AIBM), como se muestra en la Fig. 1. Se registraron las señales de carga (deformación) y temperatura medida en el sistema de adquisición.




Figura 1: Montaje del dispositivo medidor de deformación analizado

3. MEDICIONES EXPERIMENTALES Y ANÁLISIS DE DATOS

En la Fig. 2 se muestran las señales registradas en un período de cuatro días, expresadas de manera adimensional. F_m representa la carga media adimensional registrada mientras que θ_c representa la temperatura del receptáculo, donde

$$F_m = \frac{\bar{F}}{\bar{F}_{MAX}}, \text{ y} \quad (1)$$

$$\theta_c = \frac{\theta}{\theta_{MAX}}$$

Pueden verse en la Fig. 2 dos períodos diferenciados por cada día de medición: uno en el cual la temperatura registrada crece y la señal del medidor disminuye, y otra en la que la temperatura decrece y la señal de éste se estabiliza. Estos períodos se corresponden con horas del día y de la noche, respectivamente. En el período nocturno, la señal del medidor se mantiene independientemente del valor que alcance la temperatura del recinto. Esta característica concuerda con lo esperado, según los resultados de las simulaciones mostradas en la Parte 1 del trabajo. En la noche el aporte de calor exterior q_{SOL} es nulo por lo que, a pesar de existir cambios en la temperatura de referencia (ambiente) T_a , la señal del medidor tiene tiempo suficiente para compensarse.

Durante el día, la señal es más compleja ya que se conjugan al menos dos fenómenos: el aporte de calor q_{SOL} no es constante; y la temperatura de referencia (ambiente) T_a cambia permanentemente. Esto produce que las señales (tanto de la temperatura como la del medidor) no logren estabilizarse ya que no llegan a alcanzar el régimen estacionario.




Figura 2: Datos experimentales de fuerza media y temperatura, en función del tiempo

Si se dividen los datos de la Fig. 2 según éstos se correspondan con datos “diurnos” o “nocturnos”, puede evaluarse la respuesta del sistema para tres días (d_1 , d_2 , y d_3) y cuatro noches (n_1 , n_2 , n_3 y n_4).

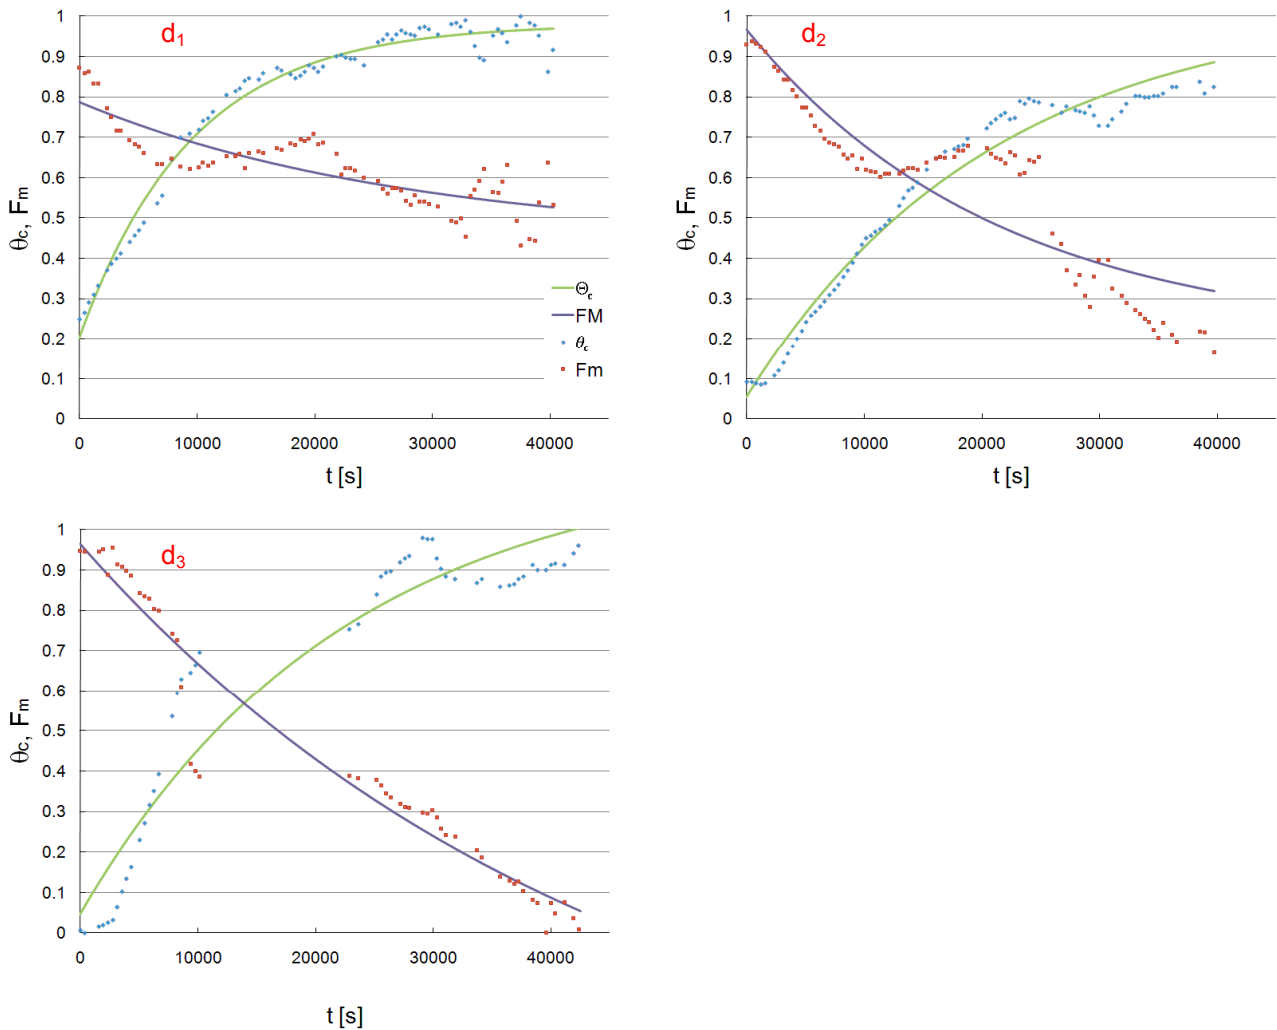


Figura 3: Datos “diurnos” extraídos de la Fig. 2 y ajuste exponencial para cada señal

En las Figs. 3 se aprecia la respuesta de la señal del medidor y la temperatura del recinto para tres períodos diurnos distintos. En las Figs. 4 se aprecia la respuesta para los cuatro períodos nocturnos correspondientes. El ajuste de los datos experimentales, para las dos señales, se corresponde con un ajuste exponencial de la forma

$$\begin{aligned} F_M &= A_F e^{(-B_F t)} + C_F, \text{ y} \\ \Theta_c &= A_T e^{(-B_T t)} + C_T \end{aligned} \quad (2)$$

Puede verse que las señales son representadas correctamente por un ajuste exponencial, lo que induce a pensar que los lineamientos de los modelos presentados en la Parte 1 son adecuados.

En todos los casos, el tiempo se expresa en segundos y se ha re-escalado de modo que todos los gráficos comienzan en $t=0$. La escala vertical es la misma que la de la Fig. 2. El objetivo del cambio de escala temporal es el de ofrecer una mejor apreciación en la comparación cualitativa de estas figuras con la Fig. 5. En esta última se aprecia la señal del dispositivo y la temperatura del receptáculo simuladas con los modelos presentados, para $q_{SOL}=1000 \text{ J/m}^2\text{s}$ (escalados entre cero y la unidad) en el caso diurno (d_i), y $q_{SOL}=0 \text{ J/m}^2\text{s}$ para el caso nocturno (n_i). En este último caso, la temperatura inicial del sistema es la temperatura de estado estacionario del modelo diurno.

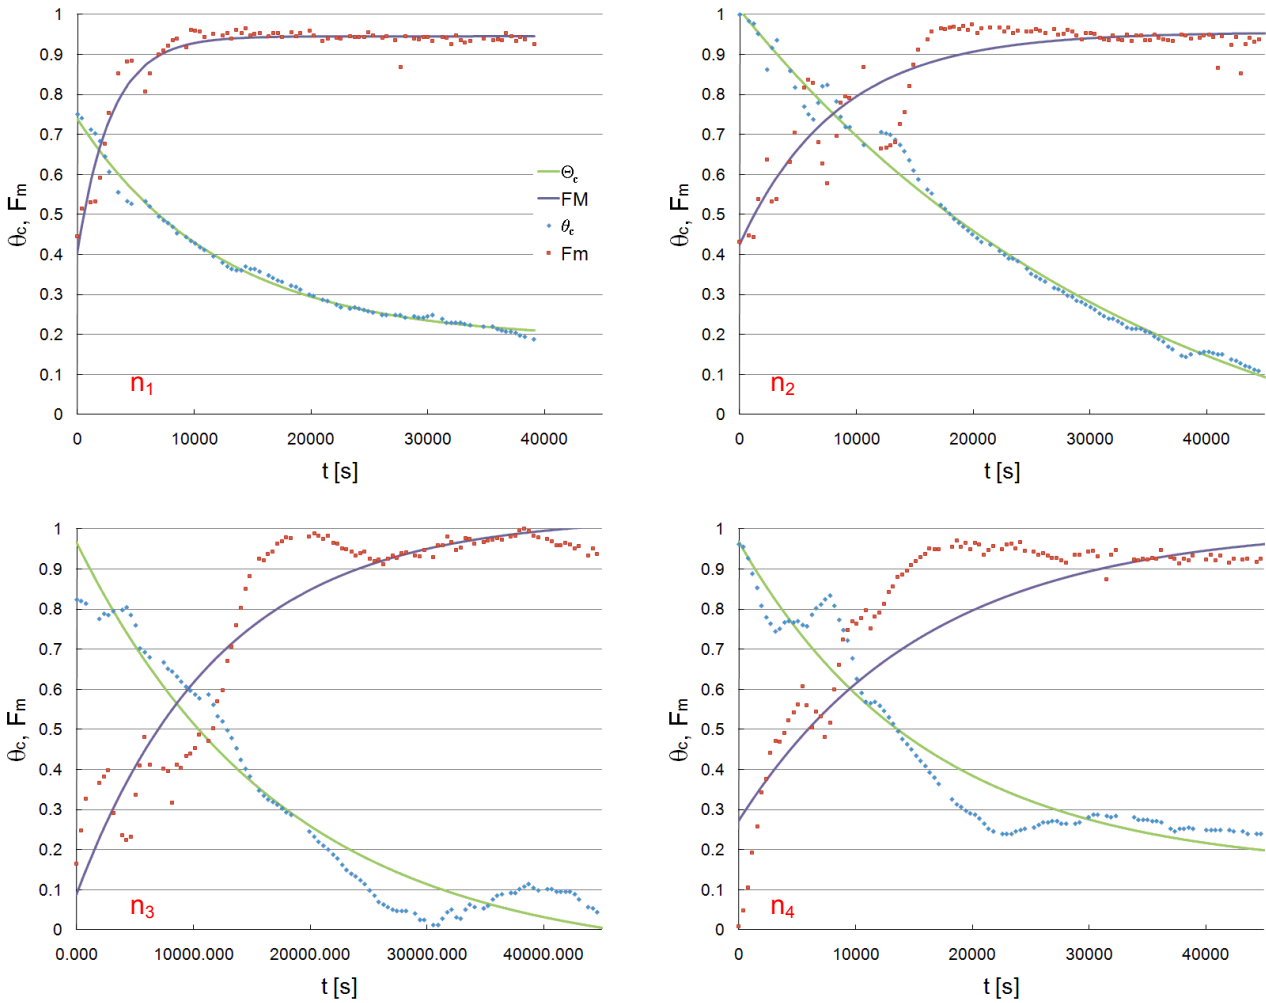


Figura 4: Datos “nocturnos” extraídos de la Fig. 2 y ajuste exponencial para cada señal




Figura 5: Simulaciones de la respuesta del medidor de deformación y de la temperatura medida: izq. “diurno”, der. “nocturno”

De la comparación de las Figs. 3 a 5 se aprecia que, si bien en las señales simuladas existe un transitorio rápido (debido a la respuesta de las ramas del dispositivo de medición) seguido de otro más lento (debido a la viga), la respuesta a tiempos “largos” es cualitativamente similar a las mediciones. Cabe destacar una vez más que todas las simulaciones se han efectuado a la misma temperatura ambiente T_a , y con aportes de calor q_{SOL} tipo escalón.

Estas condiciones no son exactamente iguales a las presentes en los ensayos experimentales ya que, en la realidad, tanto la temperatura ambiente como el aporte de calor proveniente del Sol cambian en el transcurrir del día. Además, debe sumarse el hecho de que el coeficiente convectivo h también es una función de las condiciones climáticas reinantes (viento, humedad, etc). No obstante el modelo presentado en la Parte 1 captura el comportamiento físico del sistema de una forma cualitativamente aceptable.

4. MODELOS BASADOS EN REDES NEURONALES ARTIFICIALES

Dentro de las ciencias de la computación, el aprendizaje automático o “machine learning” [6] es una disciplina que se basa en la capacidad de modelado de sistemas a partir de la observación de un número de casos del mismo. Los datos usados para generar el modelo se los denomina de entrenamiento. Una vez que el modelo fue generado (o entrenado) con los datos del entrenamiento, el mismo está listo para ser usado con nuevos datos, a los que se le da el nombre de datos de testeo. La capacidad predictiva o de generalización del modelo estará sujeta al error obtenido sobre este conjunto de testeo.

Las redes neuronales artificiales, o simplemente redes neuronales [7] son una familia de técnicas de modelado no lineal cuyas numerosas contribuciones en problemas científicos e industriales, las convierten en uno de los métodos de aprendizaje automático más usados [8]. La configuración y funcionamiento de estos modelos matemáticos guardan una analogía con el funcionamiento de las neuronas en el cerebro humano.

Cada neurona o nodo es representado por una función de activación que ante la presentación de una entrada emite una salida. A su vez, cada neurona se encuentra conectada con otras, mediante enlaces unidireccionales. Cada uno de estos enlaces tiene una incidencia sobre el nodo al que conecta determinado por un valor real denominado peso. La configuración de estos nodos o neuronas en múltiples capas permite el modelado de cualquier función no lineal. La Fig. 6 muestra una representación gráfica de una red neuronal de dos capas. Cada cuadrado corresponde a una de las variables de entrada del problema y los círculos se corresponden con los nodos o neuronas.

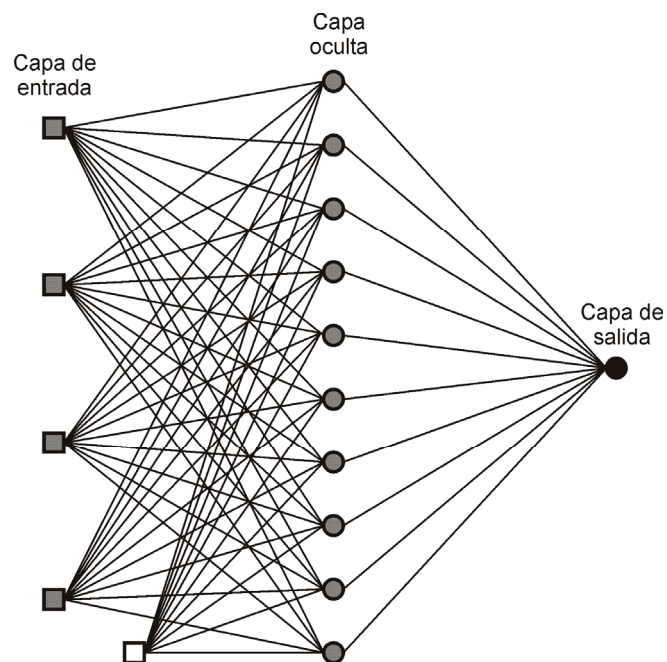


Figura 6: Red neuronal de dos capas

El funcionamiento básico de una red neuronal de dos capas puede describirse a partir de la Ec. (3), donde f es la función a modelar con la red a partir del vector de entrada x y una serie de matrices $W^{(k)}$ (con $k = 2$ si la red tiene dos capas). Las funciones g_j y G son las funciones de activación de las neuronas correspondientes a nodos de la capa oculta y de salida respectivamente. Las matrices $W^{(1)}$ y $W^{(2)}$ corresponden a las matrices de pesos que vinculan los nodos de cada capa.

$$f(x, W) = G\left(\sum_j W_{1,j}^{(2)} g_j\left(\sum_{i=1}^n W_{j,i}^{(1)} x_i + w_{j,0}^{(1)}\right) + W_{1,0}^{(2)}\right) \quad (3)$$

La potencialidad de las redes neuronales no está en la capacidad de modelado en sí, sino que la principal ventaja es la capacidad de “aprender” el modelo en forma automática. El primer algoritmo de aprendizaje para las redes neuronales es el de retro-propagación (“back-propagation”) [9]. Básicamente, el aprendizaje consiste en la optimización de los pesos que vinculan a las neuronas, a partir de la presentación de casos de entrada-salida del sistema real.

5. MODELO DE DEFORMACIÓN TÉRMICA REALIZADO CON REDES NEURONALES

Se ha mencionado que las redes neuronales son capaces de inferir una función $y = f(\bar{x})$ a partir de un conjunto de entrenamiento $R = ((\bar{x}_1, y_1), \dots, (\bar{x}_m, y_m))$, donde cada par (\bar{x}_i, y_i) es una observación de entrada-salida. De los 620 datos observados disponibles, se tomó el 80% para construir el modelo (496 casos de entrenamiento), mientras que los 124 casos restantes se usaron para testear la capacidad de modelado de la red en forma independiente. Este procedimiento de separación, entrenamiento y validación fue repetido 50 veces para asegurar la confiabilidad estadística de los resultados obtenidos, y eliminar el sesgo que pudiera ocasionar la separación aleatoria de los datos.

La arquitectura de la red utilizada corresponde a una de dos capas, con 5 nodos en la capa oculta. La misma es entrenada haciendo uso de una regularización bayesiana [10], lo que permite no sobreentrenar la optimización de los pesos [11].

Se aplicaron dos modelos diferenciados dependiendo de cuáles fueron las variables consideradas en la entrada \bar{x} . En el primero de ellos se contemplaron solamente la temperatura y una aproximación de la derivada de la temperatura en el tiempo. En el segundo modelo, a las dos variables anteriores se le añadió la derivada de la señal de deformación con respecto al tiempo. En ambos casos, la variable de salida y , variable que se desea modelar, es la lectura de la deformación según el dispositivo medidor de deformación.

6. RESULTADOS

La Fig. 7 muestra los resultados de predicción obtenidos con la red neuronal sobre el conjunto de testeo. En el eje de las abscisas se tiene el valor y observado, mientras que en el eje de las ordenadas, se tiene la predicción obtenida con la red. La distancia vertical a la función identidad indica el error absoluto obtenido en cada predicción.

El cálculo de las métricas habituales para evaluar la calidad de la predicción, indican que el primer modelo posee un error relativo (basado en las 50 réplicas) de 7,92%, mientras que para el segundo es de 7,68%. El coeficiente de determinación, el cual mide la proporción de la dispersión capturada por el modelo de regresión, es de 0,756 para el primer modelo y de 0,773 para el segundo.




Figura 7: Predicciones obtenidas sobre el conjunto de testeo para ambos modelos

7. TRABAJOS FUTUROS

Los trabajos futuros a realizar para completar la evaluación de la respuesta del sistema en estudio pueden ser tanto experimentales como numérico-analíticos.

Experimentales:

- Medición de la respuesta del sistema en un ambiente de temperatura constante y con aporte de calor externo conocido o nulo para verificar el modelo presentado
- Medición de temperatura dentro del receptáculo y fuera del mismo para verificar la respuesta de la señal de temperatura
- Medición de la respuesta del dispositivo de medición con una cobertura (que abarque también una porción de la viga) que lo mantenga protegido de la radiación solar directa

Numérico-analíticos:

- Evaluación de la respuesta de la celda y del receptáculo ante aportes de calor que sean más representativos de la realidad. Por ejemplo $q_{SOL} = H \sin^2(gt)$, donde H es la amplitud máxima y gt es el período que debe adaptarse a las condiciones “diurnas” y “nocturnas” previamente mencionadas.
- Evaluación de la respuesta de la celda y del receptáculo ante cambios en la temperatura ambiente. Por ejemplo $T_a = f \sin(gt + \varphi) + T_0$, donde φ es el desfase temporal entre el aporte de calor y la respuesta del ambiente y T_0 es la temperatura media.
- Modelado de una red neuronal dinámica, en donde los datos de las mediciones puedan ser suministrados en orden cronológico. De este modo, la red neuronal será capaz de decidir su salida de acuerdo a la entrada presentada y al estado temporal representado por las entradas anteriores. Este modelo requiere de una recolección más cuidadosa de los datos con los que se entrena el modelo de red neuronal.

8. CONCLUSIONES

El medidor de deformación en estudio presenta susceptibilidad ante cambios en el flujo de calor que recibe de una fuente externa, como puede ser la radiación solar. La señal de salida puede representarse de manera aceptable mediante un ajuste exponencial, en concordancia con el análisis analítico-numérico de la Parte 1 del presente trabajo.

Con respecto a los resultados obtenidos a partir con la red neuronal, puede afirmarse que la mismo provee una capacidad aceptable para modelar la deformación medida por el dispositivo, y por ende, corregir la deformación provocada por la temperatura. El error relativo obtenido en la predicción con los dos modelos de red neuronal es menor al 10%, lo que representa un error aceptable para la aplicación en estudio. De ambos modelos se destaca al segundo de ellos como más promisorio, dado que éste permite un error aún menor en las predicciones obtenidas. Puede apreciarse también de la Fig. 7 que la mayor cantidad de observaciones se realizaron con una lectura adimensional de la carga (deformación) cercana a los 0,95. Por tal motivo, la red neuronal predice con mayor precisión esos valores.

Finalmente, es necesario advertir que una recolección de datos más amplia, homogéneamente tomada en el tiempo y con distintas mediciones de carga aplicada, mejoraría la calidad y la robustez del modelo presentado.

9. REFERENCIAS

- [1] R.S. Figliola y D.E. Beasley, *Mediciones Mecánicas, Teoría y Diseño*, Alfaomega, 2003.
- [2] V.I. Feodosiev, *Resistencia de Materiales*, Mir, 1972.
- [3] C.V. Collet y A.D. Hope, *Mediciones en Ingeniería*, Gustavo Gili S.A., 1976.
- [4] Vignolo, G.G. y Vázquez, J.A., Medidor de Deformación en Elementos Estructurales, Patente Arg. En trámite N°Tr.:20127 - Ex.:20090103772 (TECSS SRL:85%, UNPSJB:15%), 2009.
- [5] Vignolo, G.G. y Vázquez, J.A., Desarrollo de un Medidor de Deformación Paralelo No Intrusivo Para la Determinación de Cargas en Vigas, *I CAIM*, 2008.
- [6] I.H. Witten, E. Frank, *Data Mining: Practical Machine Learning Tools and Techniques 2º ed.* Gray J, editor. San Francisco, CA: Morgan Kaufmann, 2005.
- [7] C.M. Bishop, *Neural Networks for Pattern Recognition*, Oxford University Press; 1995.
- [8] Y. Kang, Ch.W. Chang, Y. Huang, Ch. Hsu, y I. Nieh, Modification of a neural network utilizing hybrid filters for the compensation of thermal deformation in machine tools, *International Journal of Machine Tools & Manufacture*, Vol. 47, pp. 376–387, 2007.
- [9] A. Bryson, Y.C. Ho, *Applied Optimal Control*. Blaisdell, New York, 1969.
- [10] D. MacKay, Bayesian interpolation, *Neural Computation*, Vol. 4, pp. 415-447, 1992.
- [11] D.M. Hawkins, The Problem of Overfitting, *Journal of Chemical Information and Computer Sciences*, Vol. 44, pp. 1-12., 2004.