

Clasificación de materiales mediante la técnica de small punch y red neuronal de tipo perceptrón

Erik López Vargas

Instituto Tecnológico de Celaya

erik_lv@hotmail.com

Luis Alejandro Alcaraz Caracheo

Instituto Tecnológico de Celaya

alejandro.alcaraz@itcelaya.edu.mx

Reséndiz Juárez Sara Inés

Instituto Tecnológico de Celaya

ines.resendiz.03@gmail.com

Resumen

Cada día estamos inmersos en mayor grado de dependencia a sistemas y procesos tecnológicos complejos, en donde la disponibilidad y el correcto funcionamiento se han convertido en una cuestión estratégica, y es ahí donde las tareas de clasificación toman una gran fuerza. Para realizar estas tareas de clasificación, en este trabajo se emplea la red neuronal perceptrón para evaluar su funcionamiento en el área de ciencias de los materiales que se entrenaron con curvas carga-desplazamiento obtenidas de ensayos de small punch a materiales de acero colado, para la implementación de la red se utilizó Matlab.

Palabra(s) Clave(s): Acero colado, Ensayo Small Punch, Red Neuronal Perceptrón.

1. Introducción

Hoy en día es de gran importancia evaluar la integridad mecánica de estructuras y componentes en servicio, ya que permite conocer el desempeño de un componente y evaluar su situación frente al fallo. Dentro de los requerimientos para llevar a cabo dicho análisis, se encuentra la estimación de las propiedades mecánicas del material, las

cuales pueden determinarse mediante procedimientos convencionales [1,2]. No obstante, el tamaño de las probetas que demandan estos estándares es generalmente significativo, lo que implica retirar muestras de gran tamaño comprometiendo la integridad del componente. Una alternativa que permite evaluar las propiedades utilizando una mínima cantidad de material es la llamada técnica Small Punch, la cual consiste en el registro de una curva carga-desplazamiento del punzonado de una probeta plana de reducidas dimensiones [3,4].

Por otro lado, el modelado computacional de redes neuronales es una herramienta que ha sido empleada en diferentes aplicaciones, entre las que se encuentra la estimación de propiedades mecánicas [5]. Para ello, la red neuronal es entrenada a través de un registro de parámetros de entrada, característicos del material, y un registro de salidas deseadas. Un ejemplo de red neuronal es la conocida como perceptrón simple, la cual busca entregar a la salida una clasificación de objetos de acuerdo a sus características de entrada.

En este trabajo se ha utilizado una red neuronal perceptrón simple para la clasificación de aceros colados, introduciendo como datos de entrada las curvas experimentales obtenidas a partir de ensayos Small Punch. Los aceros colados pertenecen a 2 de los 112 anclajes de un puente atirantado [4], y han sido seleccionados por sus diferencias en su resistencia, catalogándose de esta manera en favorable y perjudicial. La finalidad del estudio es analizar la aplicabilidad del ensayo Small Punch y el uso de redes neuronales en la clasificación de estos aceros, ya que marcaría una pauta en la determinación del tipo de acero (favorable o perjudicial) de los anclajes restantes del puente atirantado. En el apartado 2, se realiza una breve descripción de las redes neuronales, haciendo hincapié en las redes de tipo perceptrón simple, en el punto 3 se realiza el desarrollo del proyecto describiendo la obtención de las curvas de carga-desplazamiento, y la aplicación de las redes neuronales, por otro lado en el apartado 4, se analizan los resultados.

2. Desarrollo

Redes neuronales

Para los autores Freman y Skapura [5], una Red Neuronal Artificial (RNA) es un sistema de procesadores paralelos conectados entre sí en forma de grafo dirigido. Su esquema

de cada elemento de procesamiento denominado 'neuronas' de la red, se presenta como un nodo. Dichas conexiones establecen una estructura jerárquica tratando de emular la fisiología del cerebro humano y buscar nuevos modelos de procesamiento para solucionar problemas concretos del mundo real. Por la versatilidad de las RNA y debido a su comportamiento para aprender, reconocer y aplicar relaciones entre objetos y tramas de objetos propios de la vida cotidiana, son utilizadas como herramienta que puede llegar a resolver problemas difíciles, tanto de clasificación como de reconocimiento.

Dicha posibilidad de resolución de problemas difíciles, se debe a los principios de las redes neuronales, que cuentan con las siguientes características que cita Hilera y Martínez [6]:

- **Aprendizaje adaptativo.** Es una característica importante de las RNA, debido al comportamiento de entrenamiento con una serie de ejemplos ilustrativos, de esta forma, no es necesario elaborar un modelo a priori, ni el establecimiento de funciones probabilísticas. Una RNA es adaptativa, dado que puede modificarse en repetidas ocasiones con el fin de obtener nuevas condiciones de trabajo.
- **Autoorganización.** Mientras que el aprendizaje es un proceso donde se modifica información interna de la red neuronal artificial, la autoorganización consiste en la modificación de la red completa con el fin de llevar a cabo un objetivo específico. Autoorganización significa generalización, de esta forma una red puede responder a datos o situaciones que no ha experimentado antes, pero que puede inferir sobre la base de su entrenamiento. Esta característica es muy útil sobre todo cuando la información de entrada es poco clara o se encuentra incompleta.
- **Tolerancia a fallos.** La razón por la que las redes neuronales son tolerantes a los fallos, es que tienen su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en este tipo de almacenamiento. La mayoría de los ordenadores algorítmicos y sistemas de recuperación de datos almacenan cada pieza de información en un espacio único, localizado y direccionable. En cambio, las redes neuronales almacenan información no localizada. De ahí que, la mayoría de las interconexiones entre los nodos de la red tendrán sus valores en función de los estímulos recibidos, y se generará un patrón de salida que represente la información almacenada.

- **Operación en tiempo real.** Una de las mayores prioridades casi en la totalidad de las áreas de aplicación, es la necesidad de realizar procesos con datos de forma muy rápida. Las redes neuronales se adaptan bien a esto debido a su implementación paralela. Para que la mayoría de las redes puedan operar en un entorno de tiempo real, la necesidad de cambio en los pesos de las conexiones o entrenamiento es mínimo.

Estructura de las RNA

Las RNA están formadas por una gran cantidad de neuronas que suelen denominarse nodos o unidades procesadoras. Un nodo o neurona cuenta con una cantidad variable de entradas (X_1, X_2, \dots, X_m) y a su vez dispone de una sola salida (Y_i), la cual transmite la información al exterior o hacia otras neuronas. Cada salida o señal de salida tiene asociada un peso que se calculará en función de las entradas, por lo que cada una de ellas es afectada por un determinado peso definido por w_i , con $i = 1, 2, \dots, n, n + 1$, que modifica las entradas antes de que sean sumadas y suministradas al elemento de umbral. En este sentido, los pesos son similares a las sinapsis en el sistema neuronal humano. La función que transforma la salida correspondiente a la suma en la salida final, se denomina *función de activación* y toma el valor de 1 si su argumento es verdadero y -1 si es falso, como se puede ver en la fig. 1. Pajares, Santos [7].

El proceso de aprendizaje consiste en hallar los pesos que codifican los conocimientos. Una regla de aprendizaje hace variar el valor de los pesos de una red hasta que estos adoptan un valor constante, cuando esto ocurre se dice que la red ya "ha aprendido".

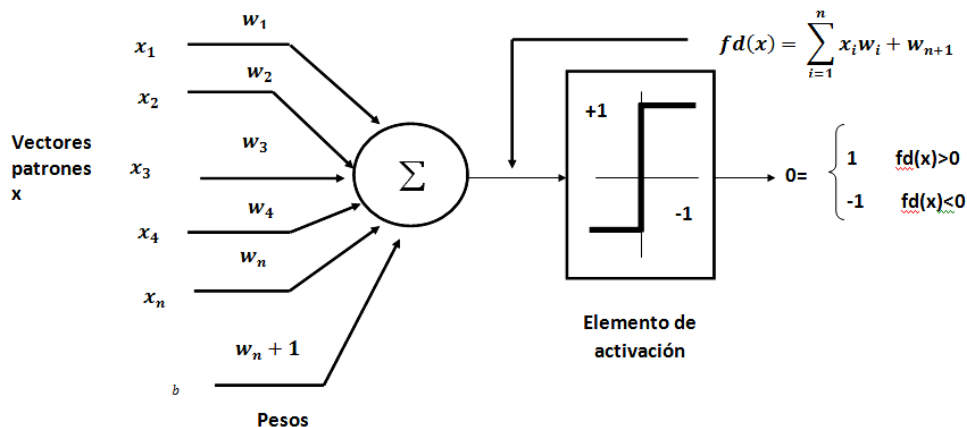


Fig. 1. Estructura de una red neuronal de tipo perceptrón.

Cuando se conectan varias neuronas, se consigue una red que puede presentar diversas variaciones en las tipologías, las cuales son clasificadas según los criterios que se exponen a continuación:

- Número de niveles o capas.
- Número de neuronas por nivel.
- Formas de conexión.

De acuerdo al problema que se vaya a solucionar, el diseño de una u otra tipología variará. Si se toma como ejemplo la elaboración de un programa de filtro digital en una computadora, se deberá emplear un algoritmo que permita que todas las capas estén uniformemente interconectadas, es decir, que todos los nodos de una capa estén conectados con los nodos de otra capa. Para hacer referencia a este tipo de red, en la fig. 2 se muestra la arquitectura de una RNA clásica con 4 variables de entrada, dos capas intermedias y una capa con 2 variables de salida, todas ellas conectadas entre sí.

Existe una gran variedad de modelos de RNA que dependen del objetivo para los cuales fueron diseñados y del problema práctico a solucionar. En la actualidad, el éxito de las RNA, depende muchas veces del usuario, para lograr alcanzar aplicaciones que sean de gran utilidad y porque no, hasta valor comercial. Existen varios tipos de redes neuronales como: perceptrón simple, adeline/madeline, backpropagation, kohonen, hopfield. En este trabajo se empleó la red perceptrón simple.




Fig. 2. Esquema de una RNA de dos capas de neuronas intermedias.

Red Neuronal tipo perceptron

El perceptron simple fue desarrollado por Rosenblatt en 1962[6], es un modelo unidireccional compuesto de dos capas de neuronas, una de entrada y otra de salida, es decir, n neuronas de entrada y m neuronas de salida que se puede expresar de la siguiente manera:

$$y_i = f \left(\sum_{j=1}^n w_{ij} x_j - \theta_i \right)$$

con $i = 1, \dots, m$

Donde:

- Las neuronas de entrada son discretas.
- La función de activación de las neuronas de la capa de salida es de tipo escalón.
- Tiene un dispositivo entrenable: determinar automáticamente los pesos sinápticos que clasifican un conjunto de patrones etiquetados.

El perceptrón simple tan sólo puede discriminar entre dos clases linealmente separables.

Ejemplo: Se tiene x_1 y x_2 dos neuronas de entrada, la operación efectuada por el perceptrón simple consiste en:

$$y = \begin{cases} 1 & \text{si } w_1 x_1 + w_2 x_2 \geq \theta \\ 0 & \text{si } w_1 x_1 + w_2 x_2 < \theta \end{cases}$$

Si consideramos x_1 y x_2 situadas sobre los ejes de abscisas y ordenadas respectivamente, la condición $w_1 x_1 + w_2 x_2 - \theta = 0$, es equivalente a $x_2 = -\frac{w_1}{w_2} x_1 + \frac{\theta}{w_2}$

y representa una recta que define la región de decisión determinada por el perceptrón simple como se puede observar en la Fig. 3. Minski y Papert en 1969[6], trabajaron exponiendo sus limitaciones, como una consecuencia de recursos de las redes neuronales a otros campos de la Inteligencia artificial.

3. Desarrollo

Los dos materiales empleados para esta investigación son aceros colados y se obtuvieron de los anclajes de un puente atirantado. Ambos aceros han sido

caracterizados en [8]. En la Tabla 1 se muestran los resultados del análisis químico, en donde puede observarse su alto contenido en Cromo y Níquel. Por ello, los aceros han sido denominados de la siguiente forma: 1Cr-0.5Ni y 0.8Cr-0.6Ni.

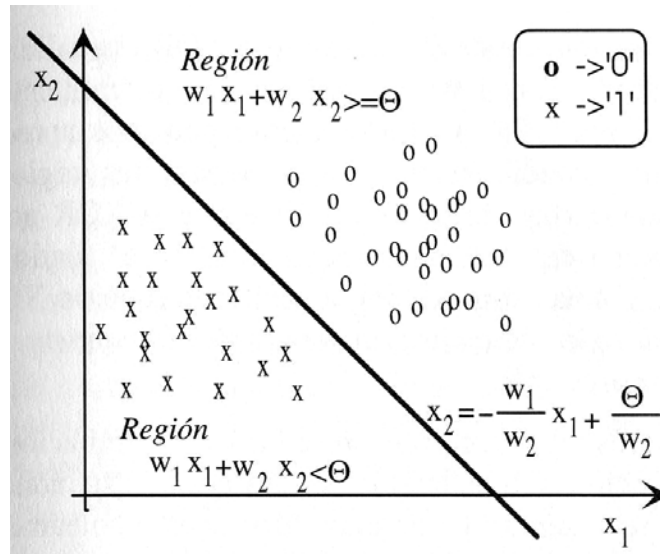


Fig. 3. Región de decisión correspondiente a un perceptrón simple con dos neuronas de entrada.

Para obtener las propiedades mecánicas de tensión de los aceros, se utilizó el procedimiento americano ASTM E8 [9], cuyos resultados se muestran en la Tabla 2.

Tabla 1. Análisis químico de ambos aceros.

| % en peso | 1Cr-0.5Ni | 0.8Cr-0.6Ni |
|-----------|-----------|-------------|
| C | 0.423 | 0.397 |
| Mn | 0.820 | 0.707 |
| Si | 0.803 | 0.300 |
| S | 0.022 | 0.036 |
| P | 0.034 | 0.036 |
| Cr | 1.007 | 0.813 |
| Mo | 0.093 | 0.080 |
| Ni | 0.537 | 0.603 |
| Cu | 0.343 | 0.340 |

Tabla 2. Propiedades de tensión de ambos aceros [4].

| Material | S_y (MPa) | S_u (MPa) |
|-------------|----------------|----------------|
| 1Cr-0.5Ni | 323±28.7 | 621±53.8 |
| 0.8Cr-0.6Ni | 280±17.5 | 591±30.0 |

El Ensayo Miniatura de Punzonado

El ensayo Small Punch es un método alternativo (no convencional) para la caracterización mecánica de materiales metálicos. El ensayo consiste en el registro de una curva carga-desplazamiento del punzonado de una probeta plana de reducidas dimensiones. El herramental empleado está formado por dos matrices en donde se introduce la probeta, y un punzón, cuya función principal es aplicar una fuerza sobre la probeta para lograr la indentación de la misma. El esquema del utillaje empleado para los ensayos Small Punch se muestra en la Fig. 4.




Fig. 4. Esquema del herramental para ensayos Small Punch [10].

El tipo de curva obtenida tras realizar un ensayo Small Punch se muestra en la Fig. 5, donde puede observarse en el eje de las abscisas el desplazamiento experimentado por el punzón, y en el eje de las ordenadas la carga ejercida sobre la probeta.

La preparación y ejecución de los ensayos se realizaron obedeciendo al código europeo de buenas prácticas [10] de la Comisión Europea de Normalización (CEN). De esta manera, los ensayos se realizaron con probetas cuadradas de 10x10x0.5 mm a una velocidad del descenso del punzón de 0.02 mm/min. La preparación de las probetas

consistió en mecanizar prismas de sección cuadrada de 10 mm por lado, de los cuales se cortaron placas con espesor un poco mayor a 0.5 mm. Posteriormente, fueron pulidas hasta llegar al espesor final deseado (0.5 mm).

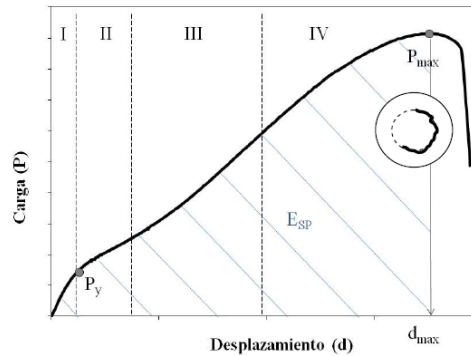


Fig. 5. Curva carga-desplazamiento características de un Ensayo Miniatura de Punzonado (EMP) de un material dúctil [8].

Para las pruebas de la clasificación, se realizó una red neuronal, con dos neuronas entrada y una de salida, que se puede observar en la Fig. 6.




Fig. 6. Entrada de curvas a la red.

Donde $x1 = y$ y $x2$, curvas que son introducidas a la red, utilizando varios métodos de entrenamiento como trainlm, learnp, trainrp, mientras que en la función de transferencia se utilizó la función purelin, aunque también se pueden probar con diferentes funciones, esta fue la más adecuada para el manejo de la red.

4. Resultados

En este trabajo se muestran los resultados de la clasificación de materiales utilizando las curvas de carga-desplazamiento, obtenidas mediante la técnica de small punch, para trabajar con la red neuronal de tipo perceptrón, basado en el modelado que se muestra en la fig. 7. Para realizar el entrenamiento de la base de datos de las curvas que se introdujeron a la red, se utilizó un 70% para el entrenamiento de la red y el 30% para la validación, es decir, de la totalidad de las curvas que fueron 29 curvas, se utilizaron 20 curvas para el entrenamiento y 9 curvas para hacer la validación de la red. La red neuronal de tipo perceptrón tiene ciertas particularidades para dar respuesta a una salida y lo primero es detectar cuantos materiales se van a utilizar para llevar a cabo el aprendizaje de nuestra red. Como la red neuronal de este tipo permite salidas solo de 0 y 1, se etiquetan los materiales como se observa en la tabla 4.

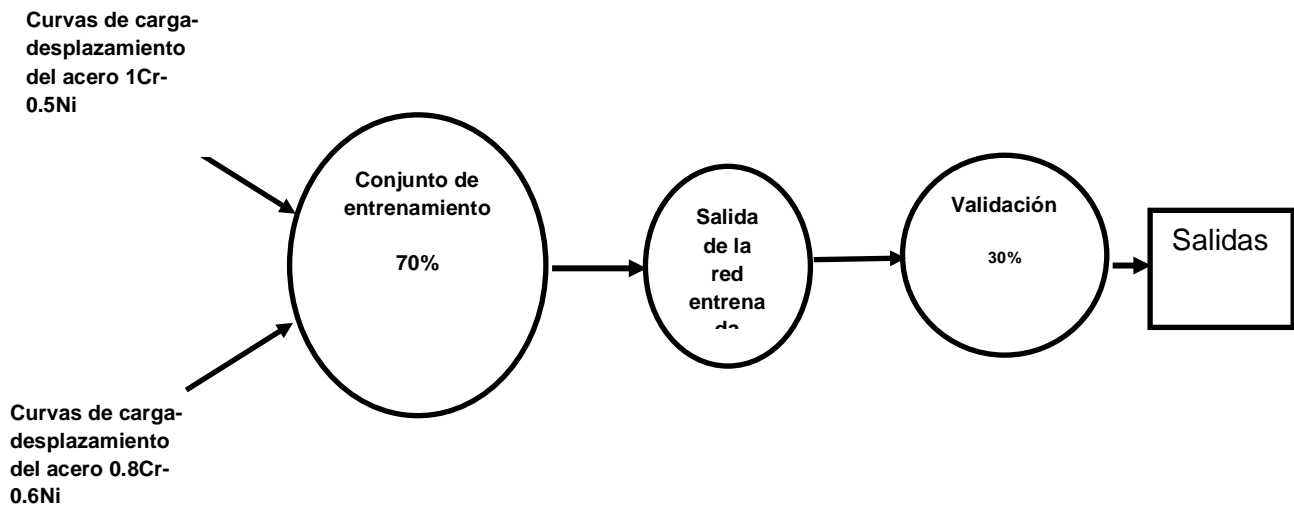


Fig. 7. Diagrama del modelado de la red de tipo perceptron.

Tabla 4. Etiquetas asignadas a los materiales.

| Materiales | Etiquetas |
|-------------------------|-----------|
| 1Cr-0.5Ni (Anclaje 1) | 0 |
| 0.8Cr-0.6Ni (Anclaje 2) | 1 |

Para proceder al entrenamiento, se utiliza el 70% y el 30% para validación. Sin embargo previo a las corridas, se observó que la cantidad de atributos con los que contaba cada una de las curvas (es decir, puntos de la curva) eran muy grandes, por lo que primero se realizó una normalización de los datos de las curvas para reducir significativamente dichos atributos (puesto que si se entrenaba con las curvas originales, el costo computacional iba a ser muy alto). Para realizar la normalización se utilizó la Transformada de Wavelets[9]. Que es un modelo matemático que permite conservar las características de los valores de las curvas, realizando un re-escalamiento, como se muestra en la siguiente fig. 8. Los círculos con flechas representan la eliminación de datos o submuestreo. Luego, cD y cA son los nuevos coeficientes obtenidos de la etapa de filtración. Intuitivamente se puede concluir que al tener cD y cA, en conjunto, se tiene la misma cantidad de datos que las de la señal original S, a la vez que se ha mantenido la información necesaria. En la Fig. 8, se ejemplifica la idea de una señal S de 1000 datos, obteniéndose en la salida dos series de aproximadamente 500 datos cada una. El concepto de aproximado, se debe a que el proceso de filtración se realiza a través de convolución de la señal de entrada con la función de transferencia (discreta) del filtro, lo que puede introducir eventualmente una o dos muestras más. La teoría de las “Wavelet” tiene muchas aplicaciones reales y aportes en diferentes campos, siendo esta herramienta muy joven en comparación con la Transformada de Fourier.

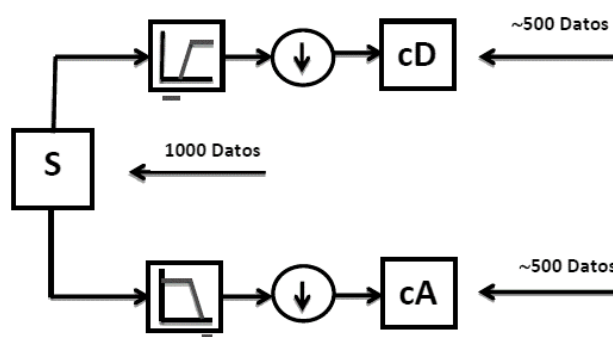


Fig. 8. Diagrama de descomposición con transformada de wavelets.

Para analizar el problema en cuestión, la entrada a la red neuronal contó con 20 curvas para el entrenamiento y 9 para clasificación. Para iniciar con el entrenamiento, se asignó a las curvas de entrada las etiquetas de 0 y 1 para los materiales previamente

asignados para realizar un aprendizaje supervisado y posteriormente, el conjunto de validación con las 9 curvas restantes, se introdujeron sin etiquetas (que es un aprendizaje no supervisado), con la finalidad de probar que efectivamente la red si aprendió. En la tabla 5, se muestran los resultados con respecto a la efectividad, es decir cuánto tiempo le costó aprender, el algoritmo de entrenamiento al que fue sometido y en cuántas épocas o ciclos demostró su efectividad.

Tabla 5. Resultados de diferentes tipos de entrenamiento.

| Tipo de material | Curvas de validación | Épocas | No de capas | rendimiento | Algoritmo de entrenamiento | tiempo |
|------------------|----------------------|--------|-------------|-------------|----------------------------|---------|
| 1Cr-0.5Ni) | 16 | 2000 | 1 | 2,43e+08 | trainlm | 0:01:33 |
| 0.8Cr-0.6Ni | 13 | | | | | |
| 1Cr-0.5Ni) | 16 | 2000 | 1 | 4,45e+07 | trainrp | 0:00:43 |
| 0.8Cr-0.6Ni | 13 | | | | | |
| 1Cr-0.5Ni) | 16 | 2000 | 1 | 4,45e+07 | learnp | 0:03:43 |
| 0.8Cr-0.6Ni | 13 | | | | | |

Se observa en la tabla 5, que los tipos de entrenamiento trainrp y learpn resultaron ser similares en su rendimiento ya que coinciden. Sin embargo trainml, demostró ser la más eficiente pues el rendimiento dela red es 2,43e+08, ya que para mostrar la efectividad de la red, en la red tipo perceptrón lo que se busca es minimizar el error cuadrático medio(mse). En la fig. 8, se muestra una gráfica que indica cuando tiende a bajar dicho error, con el entrenamiento trainlm. En cuanto al porcentaje de aciertos, al hacer varias pruebas, se pudo comprobar que nuestra red neuronal hizo una clasificación de 100% es decir, en la prueba de validación de las 9 curvas que se validaron, todas ellas fueron reconocidas.

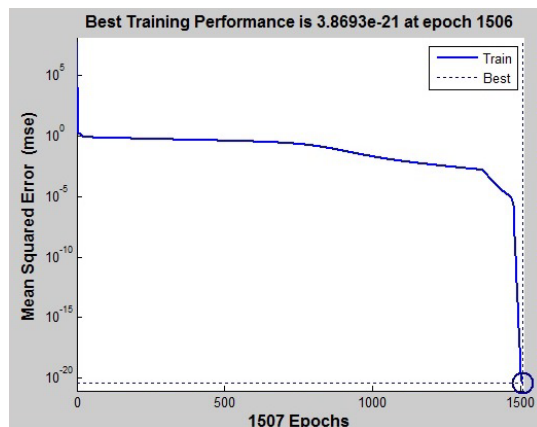


Fig. 8. Tendencia del error mse.

5. Discusión

De acuerdo a los resultados obtenidos, se puede comprobar que las redes neuronales, son muy eficientes debido a que pueden ser aplicadas en diferentes disciplinas. Sin embargo, los datos a introducir a la red, deben ser normalizados de tal manera, de que conserven las características originales, con la finalidad de evitar pérdida de información, en el caso del área de materiales, se pudo comprobar que las curvas de carga-desplazamiento, fueron sometidas a la transformada de wavelets, para hacer más eficiente el aprendizaje en la red neuronal tipo perceptrón simple.

6. Conclusiones

Se realizaron diferentes pruebas para el aprendizaje de la red de tipo perceptrón simple, con diferentes funciones de entrenamiento, utilizando aprendizaje supervisado y no supervisado, obteniendo resultados del 100% de clasificación de los tipos de los materiales, utilizando como entrada curvas de carga-desplazamiento de dos tipos de acero colado. Como continuación de este trabajo, se implementará la red neuronal de tipo backpropagation con la finalidad de estimar la tenacidad de la fractura de estos aceros a partir de la curva carga vs desplazamiento obtenida de un ensayo de small punch.

5. Referencias

- [1] Small specimen test Technique, ASTM STP 1329, 1998.
- [2] M. A. Contreras, C. Rodriguez, F. J. Belzunce and C. Botegón, "Use of the small punch test to determine the ductile-to-brittle transition temperature of structural steels", *Fatigue & Fracture of Engineering Materials & Structures*, pp. 727-737, 2008.
- [3] E. Fleury and J. S. Ha, "Small Punch test to estimate the mechanical properties of steels for steam power plant: I, Mechanical strength", *International Journal of Pressure Vessels and Piping* 75, pp. 699-706, 2008.
- [4] L. A. Alcaraz, "Análisis probabilístico de integridad de un anclaje de acero estructural", Tesis Doctoral, ESIME-IPN, México D.F., 2012.
- [5] Freeman, J.A.; Skapura, DM. *Redes Neuronales. Algoritmos, aplicaciones y*

técnicas de propagación. México: Addison-Wesley. 1993; 306 p.

- [6] Hilera González, J.; Martínez Hernández, V. Redes neuronales artificiales: fundamentos, modelos y aplicaciones. Madrid, RA-MA, 1995. 389 p
- [7] Pajares, M.; Santos, M. Inteligencia artificial e Ingeniería del conocimiento, Madrid, RA-MA 2006, 235 p.
- [8] R. Lacalle, "Determinación de las propiedades en tracción y fractura de materiales metálicos mediante ensayos Small Punch", Tesis Doctoral, Universidad de Cantabria, 2012.
- [9] ASTM E8-04, "Standard Test Method for Tension Testing of Metallic Materials", Annual Book of ASTM Standards, Vol. 03.01.
- [10] CWA 15627:2008, "Small Punch Test for Metallic Materials", European Committee for Standardization (CEN).

7. Autores

Dr. en C. Luis Alejandro Alcaraz Caracheo obtuvo su título de doctor en ciencias en Ingeniería Mecánica en el Instituto Politécnico Nacional.

Ing. Erik López Vargas es Ingeniero en Mecatrónica por el Instituto Tecnológico de Celaya.

Sara Inés Reséndiz Juárez estudiante de licenciatura en Ingeniería Mecatrónica del Instituto Tecnológico de Celaya.

Norma Verónica Ramírez Pérez, Candidato a Doctor en Ingeniería en Informática, por la Universidad Complutense de Madrid.