

# Reconocimiento de defectos en rieles ferroviarios por corrientes inducidas aplicando redes neuronales

Gutiérrez, M. , Di Fiore, T.  
Departamento de Ingeniería Electrónica  
Universidad Tecnológica Nacional  
Facultad Regional Haedo  
mgutierrez@frh.utn.edu.ar

Vorobioff, J.  
Departamento de Ingeniería Electrónica  
Universidad Tecnológica Nacional  
Facultad Regional Buenos Aires  
vorobioff@cnea.gov.ar

Fava, J. O.  
Departamento de Ingeniería Ferroviaria  
Universidad Tecnológica Nacional  
Facultad Regional Haedo  
jfava@frh.utn.edu.ar

**Abstract**—El análisis de fisuras en materiales ferromagnéticos utilizando la técnica de corrientes inducidas es de gran interés a nivel mundial en la industria ferroviaria. La detección del daño producido por fatiga de contacto por rodadura en rieles demanda mucho interés por los riesgos de accidentes que implica. Existen registros de daños en los rieles producidos por este fenómeno en la Argentina. En el presente trabajo, se utilizan redes neuronales artificiales para clasificar las profundidades de fisuras fabricadas sobre un tramo de riel. Se analizan fisuras de 0.2 mm de espesor y profundidades entre 1 y 7 mm.

**Keywords**—Corrientes inducidas, rieles, defectos, procesamiento de señales, redes neuronales.

## I. INTRODUCCIÓN

En servicio, los rieles están sometidos a grandes esfuerzos normales y de corte, intensas deformaciones plásticas y desgastes. Esto conduce a una de las principales causas actuales de defectos en rieles: fallas en los rieles causadas por la propagación de defectos superficiales originados en la cabeza del riel. Esos defectos superficiales tienen su origen en la interacción rueda-riel, por el fenómeno de fatiga de contacto por rodadura (FCR) [1]. El área de la superficie de contacto rueda/riel es muy pequeña ( $1.5$  a  $5$  cm<sup>2</sup>); debido a esto se generan enormes tensiones de interacción que causan deformaciones plásticas recurrentes de la microestructura del riel y como consecuencia la capa superficial deformada se endurece. Finalmente el material se fatiga y aparecen los defectos debidos a FCR. Una vez producido el daño, generalmente en forma de fisuras, los siguientes ciclos de rodadura producen la propagación del mismo en la cabeza del riel; así se desarrolla un crecimiento del daño que es típico de un proceso de fatiga. La propagación del daño puede ocasionar pérdida visible de material; pero el mayor riesgo ocurre cuando alguna de esas fisuras se propaga en un plano transversal al riel. En este caso, no detectarla a tiempo puede producir la rotura catastrófica del riel en servicio [2].

La importante renovación de la infraestructura ferroviaria que se está llevando adelante en la Argentina ya ha determinado la necesidad de renovar los métodos de inspección. Los rieles y el material rodante nuevos, el aumento de la frecuencia y las cargas transportadas determinará la aparición, cada vez más frecuente, de defectos de FCR inducidos por el tráfico; de hecho este grupo tiene registros de este tipo de defectos en las líneas Sarmiento y San Martín de Buenos Aires. En un sistema global de mantenimiento predictivo los ensayos no destructivos (END) ocupan un lugar central. Actualmente, en Argentina, el único END que se aplica regularmente a rieles es el ultrasonido convencional; este método no puede

detectar fisuras superficiales o sub-superficiales, como es el caso del estado incipiente del daño producido por FCR. El método de corrientes inducidas (CI) es, justamente, un método superficial que se aplica a componentes conductores; y tiene excelentes resultados desde hace más de una década en otros países [1]. En este sentido, se está trabajando en el desarrollo de un dispositivo de CI que permita detectar y evaluar el daño producido por FCR [3]; en este trabajo se presenta la aplicación de redes neuronales artificiales (RNA) para el reconocimiento de las profundidades de los defectos superficiales en rieles ferroviarios.

## II. MATERIALES Y MÉTODOS

El método de CI utilizado emplea un puente de corriente alterna (CA); está formado por dos sondas conectadas en modo diferencial y un tercer inductor que emite el campo magnético variable el cual genera las CI en el material a inspeccionar. El balanceo del puente se hace en una región libre de defectos y para lograr una tensión diferencial, cercana a la nula, se utilizan las impedancias variables  $Z1$  y  $Z2$  que conforman las ramas restantes, Fig. 1. Las señales diferenciales del puente de CA son acondicionadas y digitalizadas, para luego ser procesadas mediante un amplificador lock-in digital para demodular la señal modulada de las indicaciones que se registran durante el ensayo [3]. Se inspeccionaron fisuras realizadas por electroerosión sobre un tramo de riel, Fig. 2; los defectos son perpendiculares a la banda de rodamiento y tienen profundidades entre 1 mm y 7 mm.

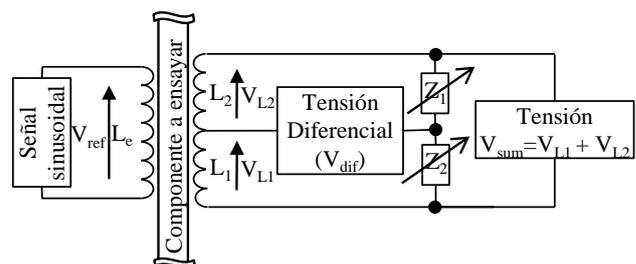


Fig. 1. Puente de AC del equipo de CI. Técnica Emisor – Receptor en modo diferencial.

Un oscilador suministra una onda sinusoidal  $V_{ref}(t)$  a un amplificador de corriente cuya carga es la bobina  $L_c$ , creando corrientes inducidas sobre el riel. La obtención de las indicaciones provenientes de las variaciones del flujo magnético debido a los defectos, son captadas por las bobinas exploradoras  $L_1$  y  $L_2$ , las cuales constituyen una parte del puente de CA. La tensión diferencial  $V_{dif}(t)$  del puente es amplificada y cuantificada, también es convertida  $V_{ref}(t)$  en muestras discretas. Las señales digitales  $X_{ref}[n]$  y

$X_{dif}[n]$ , son procesadas por el amplificador lock-in digital. El amplificador lock-in incorpora un filtro digital pasa-bajo de respuesta al impulso infinita para recuperar la componente de corriente continua cuya salida es  $V_{out}(V)$ , Fig. 3. La señal  $V_{out}(V)$  depende del lift-off (separación entre las bobinas y el riel); y en el caso de que el lift-off varíe durante la inspección, eso afectará la correcta caracterización de los defectos. Por la disposición diferencial de las bobinas exploradoras, los cambios de lift-off no alterarán el balance del puente de CA cuando se produzcan a lo largo de todo el escaneo del riel y en una zona homogénea; pero sí afectarán a la amplitud de la señal  $V_{out}(V)$  cuando se encuentre en presencia de alguna discontinuidad. Con la tensión amplificada de  $V_{sum}(t)$  proveniente de sumar las tensiones inducidas sobre L1 y L2 se pueden evaluar y compensar los efectos producidos por los cambios del lift-off sobre la amplitud de  $V_{out}(V)$ ; en este trabajo, esto se logró mediante la utilización RNA, Fig. 4.

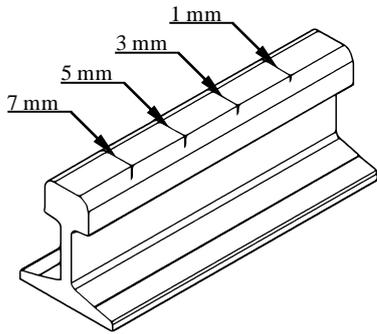


Fig. 2. Patrón.

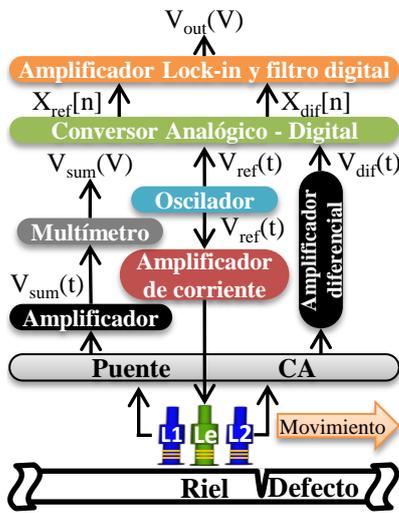


Fig. 3. Diagrama en bloques del dispositivo.

Se extraen los parámetros más relevantes de las señales y se clasifican las fisuras mediante RNA, cuya principal característica es vincular los datos de entradas y de salida para clasificar las muestras. A diferencia del método de ajuste de curvas utilizado en [3], las RNA no requieren obtener los parámetros de la función que mejor se adapte a los valores iniciales [4]. Una característica importante de estas RNA, es la capacidad de estimar sistemas no lineales. Existen varios trabajos que utilizan RNA para caracterizar defectos usando CI [5], [6]. Aquí se empleó el algoritmo de Levenberg-Marquardt, el cual combina algoritmos de descenso en gradiente y de optimización Gauss-Newton. La estructura de la RNA corresponde a un perceptrón multicapa

feedforward con una única capa oculta. El número de neuronas y conexiones de la RNA se muestran en la Fig. 4. Se empleó una validación cruzada para el entrenamiento, validación y prueba de 60%, 15% y 25% respectivamente. El criterio de finalización del entrenamiento fue la clasificación correcta de todas sus muestras de entrenamiento y validación o un tiempo máximo de procesamiento de 60 segundos.

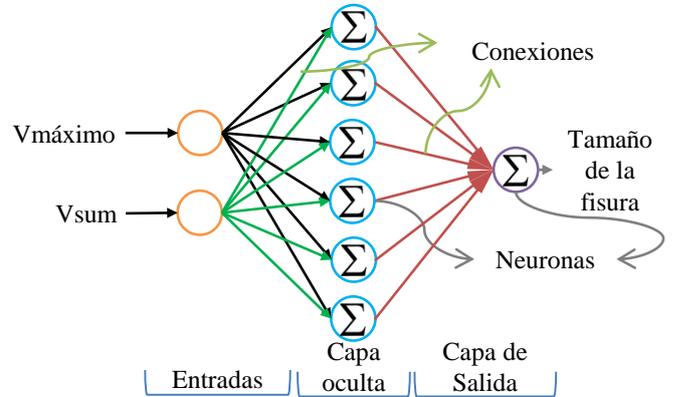


Fig. 4. RNA feedforward.

### III. RESULTADOS

Los ensayos se realizaron a una frecuencia de 8 kHz para los lift-off de la Fig. 5; escaneando 3 veces para cada lift-off. Antes de ingresar en la RNA se realizó un pre-procesado, normalizando la línea de base inicial de la salida del amplificador lock-in. La Fig. 5 muestra las señales para la fisura de 7 mm. Para obtener el valor de la tensión  $V_{sum}(t)$ , Fig. 6, se posicionó el cabezal de inspección sobre una zona libre de defecto.

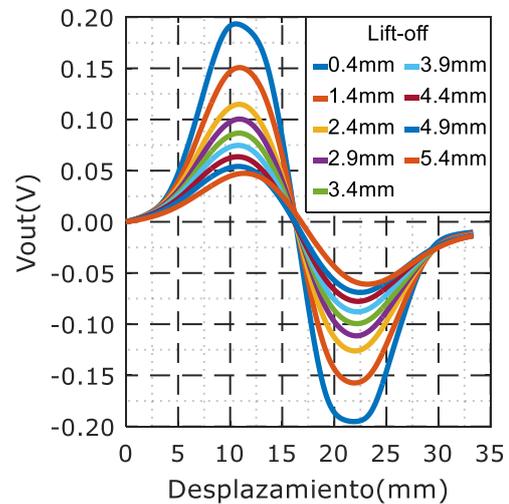


Fig. 5. Salida del amplificador lock-in para la fisura de 7 mm.

Los resultados de clasificación relativos a la estimación de los defectos de la RNA se muestran en la Fig. 7. El número de neuronas en la capa oculta se seleccionó luego de analizar el error cuadrático medio (ECM) entre 2 y 10 neuronas. El menor ECM se obtuvo con 6 neuronas.

## REFERENCIAS

- [1] A. Dey, H. M. Thomas, R. Pohl, "The important role of eddy current testing in railway track maintenance", 17th World Conference on Nondestructive Testing, Shanghai, China. 25-28 October 2008.
- [2] A. Doherty, Why rails crack?, Ingenia Online. Royal Academy of Engineering: London, 2005, 23-28.
- [3] M. Gutiérrez, J. Fava, T. Di Fiore, M. Ruch, R. Romero, J. Vorovioff, "Development of a differential test device for eddy current rail inspection", 12th European Conference on Non-Destructive Testing (12th ECNDT), Gothenburg, Sweden, 2018, June 11-15.
- [4] John Hertz, Anders Krogh, Richard Palmer, Introduction to the Theory of Neural Computation, 1991, Addison Wesley.
- [5] M. Wrzuszczak, J. Wrzuszczak, "Eddy current flaw detection with neural network applications". Measurement, 2005, Vol.38-2, 132-136.
- [6] T. Chady, M. Enokizono, R. Sikora, "Natural crack recognition using inverse neural model and multi-frequency eddy current method", Magnetism, IEEE Transactions on, 2001, Vol.37-4, 2797-2799.

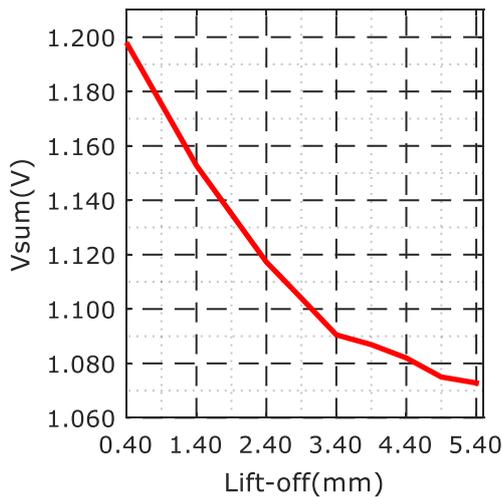


Fig. 6. Vsum en función del lift-off.

También, se verificó la función activación que minimizaba el ECM entre: tangente hiperbólica, logarítmica y lineal. El mejor resultado se obtuvo con la función de activación tangente hiperbólica en la capa oculta y la función activación lineal en la capa de salida. El valor máximo de  $V_{out}$  ( $V_{máximo}$ ) y la tensión  $V_{sum}$ , son ingresadas en la RNA para que su salida estime la profundidad de fisura real para esas condiciones, Fig. 7.

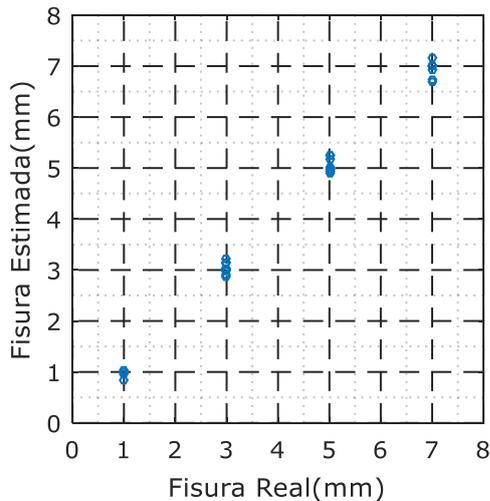


Fig. 7. Dispersión correspondiente a la RNA.

## IV. CONCLUSIONES

Se procesaron señales de CI y mediante diferentes técnicas de inteligencia computacional, se clasificaron correctamente 4 fisuras diferentes con 9 niveles de lift-off. Se logró una dispersión entre las fisuras reales y estimadas con un ECM de 0.213 mm.

La combinación de técnicas presentadas aquí es innovadora y presenta ventajas respecto a otras técnicas como las aplicada en [3] y representa una posible mejora a las técnicas convencionales de CI.