

# De las redes neurales a la ingeniería civil. Parte 3

*Uso en Ingeniería Civil. Productividad en la construcción.  
Predicción de flujo en ríos. Evaluación de la condición de  
pavimentos.*

## Uso en Ingeniería Civil


Una explicación general sobre el uso de redes neurales en Ingeniería Civil puede encontrarse en la siguiente referencia de profesores de la Universidad de Maryland, USA.

Ian Flood and Nabil Kartam. *Neural Networks in Civil Engineering. I: Principles and Understanding. II: Systems and Application.* Journal of Computing in Civil Engineering, Vol 8. N° 2, April, 1994. ASCE.

## Conceptos y temas

### ◆ Tipos de datos de entrada y salida

#### EJEMPLO DE ENTRADAS Y SALIDA DE LA RED



Los datos de entrada o salida pueden ser:

- Continuos o discretos

- Simbólicos (en forma no numérica aunque pueden pasarse a tal; por ejemplo: *pequeño, medio, grande y extra-grande*, ser representado por entradas binarias 00, 01, 10 y 11. O por 0.00, 0.33, 0.67 y 1.00).
- O por una combinación de ambos.

Es el caso del ejemplo de la figura, donde:

- Las entradas son las cargas  $i_1, i_2$ , que son valores reales.
- La salida  $y$  es binaria (discreta). Si el valor de salida es del orden de 1.0, significa que es excedido el momento máximo admisible de flexión.

#### ◆ Descripción general

Las redes neurales son configuradas por operaciones en paralelo efectuadas por neuronas o unidades conectadas en algún circuito como el de la Figura 21.

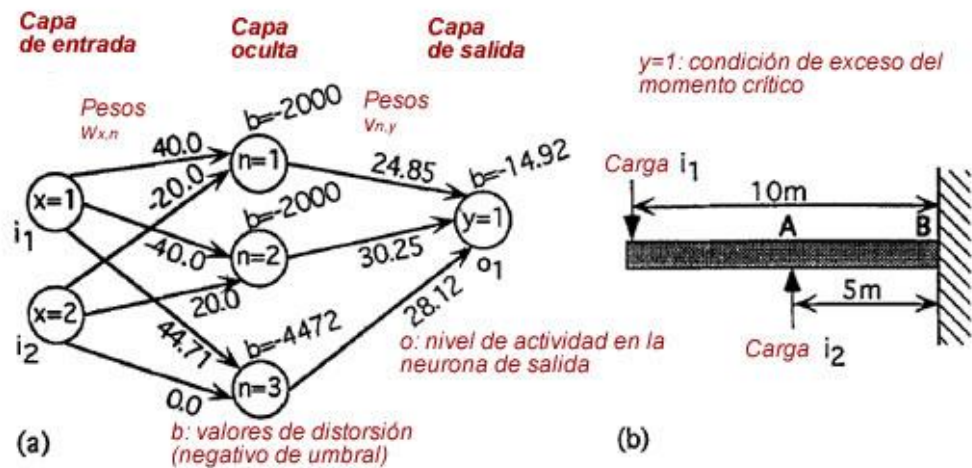


Figura 21. (a) Modelo de red neural de seis nodos. (b) Viga y carga que se representan

Típicamente hay muchas neuronas en cada capa de una red, pudiendo haber incluso más de una capa oculta. Las siguientes ecuaciones proporcionan una descripción generalizada del modo de operación de este tipo de red.

$$h_n = F\left(\sum_x (w_{x,n} i_x) + b_n\right)$$

$$o_y = F\left(\sum_n (v_{n,y} h_n) + b_y\right)$$

Donde  $h_n$  y  $o_y$  son, respectivamente, los niveles de una neurona de la capa oculta y la neurona de salida. Además,  $w_{x,n}$  y  $v_{n,y}$  son los pesos en las conexiones a las capas ocultas y de salida, respectivamente. Los valores de distorsión son  $b_n$  y  $b_y$ .  $F()$  es la función de activación, considerada como la función sigmoideo.

Para el entrenamiento, la red se presenta con un juego de patrones de entrenamiento, partiendo de un problema a ser resuelto, con las entradas y la correspondiente solución. En el caso del ejemplo, se usaron 21 patrones, una muestra de los cuales se presenta en la siguiente tabla. Para la solución de empleó la regla delta generalizada.

---

### Muestra de los patrones de entrenamiento

Patrón de entrenamiento	Valores de entrada		Valores de salida
	$i_1$	$i_2$	$o_1$
1	0.0	0.0	0.0
2	49.0	0.0	0.0
3	51.0	0.0	1.0
4	100.0	0.0	1.0
5	120.0	25.0	1.0
6	25.0	50.0	0.0
7	75.0	51.0	0.0

### Para elegir los pesos. Caso de estabilidad de talud

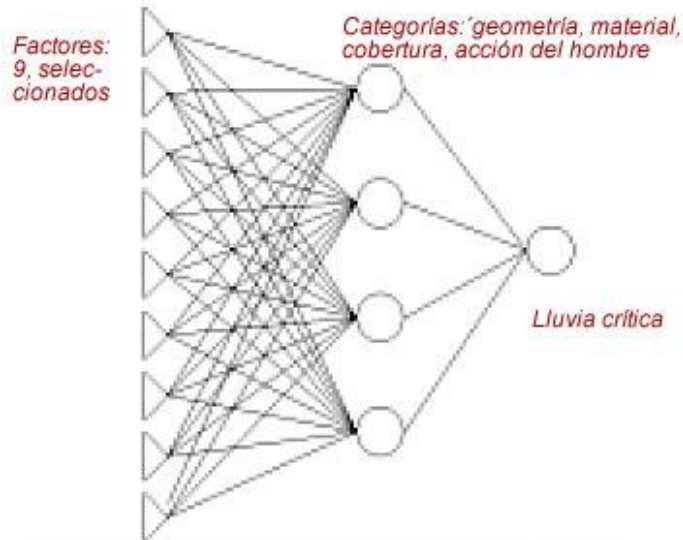
Al no haber una regla única de cómo elegir los pesos de partida (una vez definida la red neural en términos de capas y neuronas), se pueden utilizar diferentes criterios para asignarlos. Se ilustra esta posibilidad a partir del siguiente ejemplo disponible en Internet.

D. P. Ortiz, J. C. Penagos y A. Lizcano. *Determinación de lluvias críticas que activan deslizamientos empleando redes neuronales*. Universidad de los Andes, Bogotá D. C., Colombia, 2002.

El propósito es estudiar la influencia de diversos factores en la estabilidad de taludes que son afectados por agua proveniente de las lluvias. Esta última variable es considerada tomando en cuenta la intensidad y la duración de las lluvias (la acumulación del agua hasta que se produce el colapso). Esto porque los autores postulan que la estabilidad de un talud se encuentra íntimamente relacionada con la presencia de agua en la masa de suelo y la fluctuación en su interior, siendo la lluvia la fuente principal.

#### ◆ Introducción

El estudio considera nueve factores, representados en igual número de entradas en la capa de inicio, los cuales están agrupados en cuatro categorías (número que corresponde al de nodos en la capa intermedia u oculta), y la salida representativa de la lluvia crítica.



**Figura 22. Topología de la red para el entrenamiento**

Estos factores y los métodos de ponderación, se indican en la tabla adjunta, según es tomado del estudio.

Categoría	Factor	Método de ponderación
<b>Geometría</b>	1. Altura del talud	Lógica difusa
	2. Inclinación del talud	Lógica difusa
	3. Forma del perfil longitudinal	Comparación por pares
<b>Material</b>	4. Tipo de material	Comparación por pares
	5. Formación del suelo	Comparación por pares
	6. Consistencia del material	Directo de un análisis geotécnico
	7. Condición de humedad	Directo de un análisis geotécnico
<b>Cobertura</b>	8. Tipo de cobertura	Comparación por pares. Lógica difusa

Categoría	Factor	Método de ponderación
<b>Acción del hombre</b>	9. Tipo de acción	Comparación por pares

En el método de comparación por pares se comparan dos entradas a la vez y se le califica en función de su potencial relativo de falla. El estudio utilizó un rango de valores entre 0 y 1.

El resto de la información de partida, fue tomada de datos de 51 registros de deslizamientos, reportando el estudio que se adoptó un margen de validez para los mismos. El entrenamiento y prueba se realizó para diferentes combinaciones de estos casos, lo cual permite conocer cuáles de esto proporcionaba el mejor desempeño.

Para tomar en cuenta el tiempo en la importancia de la lluvia se empleó una expresión que regula los valores totales de lluvia acumulada, la misma que se expresa con el auxilio de dos parámetros (uno de ellos representa el efecto de disminución de las lluvias a medida que se alejan del día de ocurrencia del evento)

## Productividad en la construcción

### Caso de una operación de excavación-carga-descarga

#### Referencia

La información está tomada del trabajo de un Investigador Asociado y de un Profesor de la Universidad de Purdue, Indiana, USA.

Li-Chung Chao and Miroslaw J. Skibniewski. *Estimating Construction Productivity: Neural-Network-Based Approach*. Journal of Computing in Civil Engineering, Vol. 8, N° 2, April, 1994. ASCE.

La necesidad de recurrir a un modelo de redes neurales para estudiar la productividad en operaciones de construcción, está basada en la complejidad de las condiciones involucradas, y porque usualmente no es claro qué factores realmente influyen en la productividad. Por ejemplo, la productividad de una operación de vaciado de concreto con bombas depende de los atributos de las máquinas, del concreto, de las condiciones ambientales, y de la gestión, tanto cuantitativa como cualitativamente. La relación entre entradas y salidas, y las correspondientes combinaciones de factores conducen a arreglos no lineales de variables múltiples difíciles de desarrollar con modelos de regresión.

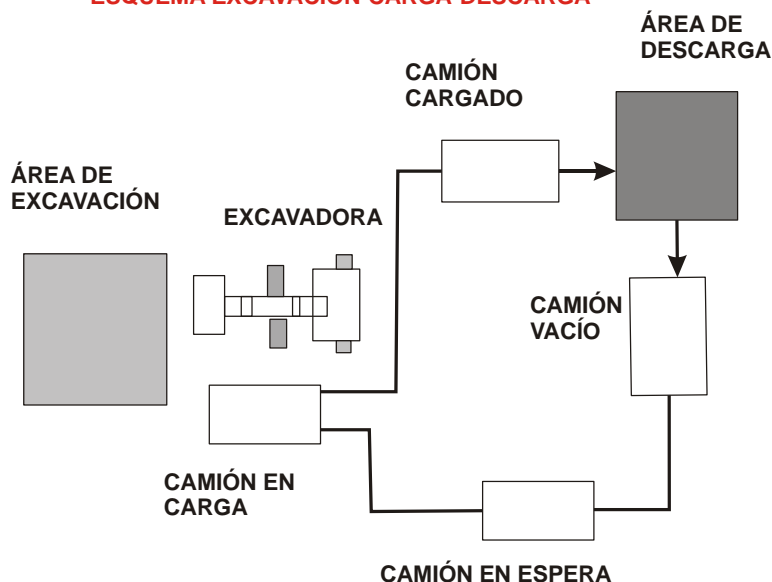
#### Descripción metodológica

Un modelo de redes neurales para estudiar la productividad de una operación de construcción puede seguir los siguientes pasos.

- Definir una operación con la secuencia de actividades, los recursos involucrados, y la medida de la producción.
- Identificar los factores que tienen un impacto en la productividad de la operación según las tareas y las condiciones de gestión.

- Dividir el análisis de productividad en varios módulos más simples, definiendo las entradas y salidas de cada módulo. Por ejemplo, un módulo sobre la capacidad de producción, y otro sobre la eficiencia de la operación.
- Recolectar datos de entrada-salida para cada módulo usando métodos de observación como videos, fotografías, mediciones temporales.
- Convertir los datos acopiados para cada módulo en una representación genérica de entradas y salidas, usando un rango 0-1 según es requerido por la función de activación.
- Usar una porción de los datos preparados para cada módulo como un conjunto de entrenamiento para la respectiva red neural, completando los datos para el entrenamiento. Usar el resto de los datos para probar el desempeño de la red entrenada. Definir los errores aceptables de predicción. Mejorar el desempeño de la red por el ajuste de parámetros ante varias pruebas.

### ESQUEMA EXCAVACIÓN-CARGA-DESCARGA



### Ejemplo de una excavación-carga-descarga

El caso que se reporta en la investigación es el de un sistema de excavación y el subsecuente proceso de carga, transporte y descarga, que esquemáticamente se ilustra en la figura anterior.

La productividad está relacionada con la salida o resultado del sistema por unidad de tiempo. En este caso se le relaciona a dos aspectos, que igualmente se usan como módulos (expresados por sus respectivas redes neurales):

- Las condiciones físicas del trabajo que determinan la capacidad de producción del excavador.
- La eficiencia o tasa de utilización del excavador condicionada por factores operativos.

#### ◆ Módulo para la capacidad de operación del excavador

El estudio utiliza una primera red neural resumida en la siguiente forma.

$(x_1, x_2, \dots) \rightarrow T_e$ . Donde  $x_i$  son las entradas que representan las condiciones físicas del trabajo de excavación, como el ángulo de giro, las condiciones de remoción, la profundidad de corte y el tipo de suelo.  $T_e$  es el tiempo de ciclo del excavador. Por ejemplo, expresado en segundos.

En consecuencia:

*Máximo número de ciclos/hora =  $3600/T_e$ , en segundos.*

Y a su vez:

*Capacidad de producción del excavador = Tamaño del cucharón \* Máximo número de ciclos/hora*

#### ◆ Módulo para la eficiencia de operación del excavador

La segunda red neural se expresa en la forma.

$(y_1, y_2, \dots) \rightarrow Ef$ . Donde  $y_i$  representan los parámetros para los atributos de la operación (como el tiempo de ciclo de los camiones para una carga, las demoras del excavador y de los camiones, la reducción en la producción, el número de camiones en la flota; inclusive podría ser: distancia del viaje, las condiciones de descarga, el tráfico.  $Ef$  es la eficiencia del excavador, en porcentaje (proporción del tiempo útil respecto al total del tiempo operando el excavador).

### Tasa de producción

Con el primer módulo y las consecuentes operaciones, se determina la *Capacidad de producción del excavador*. Con el segundo módulo, la *Eficiencia del excavador*, en porcentaje.

La tasa de producción de la operación resulta como:

*Tasa de producción = Capacidad de producción \* Eficiencia del excavador (%)*.

## Predicción de flujo en ríos

### Referencia

Nachimuthu Karunanithi (Bell Communications, New Jersey), William J. Grenney (Utah State University, Utah), Darrell Whitley (Colorado State University, Colorado), and Ken Bovee (National Ecology Research Center, Colorado). *Neural Networks for River Flow Prediction*. Journal of Computing in Civil Engineering. Vol 8, N° 2, April, 1994. ASCE.

Los modelos analíticos para estudiar el flujo de aguas superficiales de los ríos constituyen una labor compleja por las grandes variaciones de diversos fenómenos naturales. Debido a ello, tienen que prepararse con importantes simplificaciones que les resta credibilidad. El artículo muestra el uso de una red neural como un modelo representativo y para efectuar predicciones. Utiliza un algoritmo denominado *correlación en cascada* como base para seleccionar la topología de la red y el correspondiente entrenamiento. El modelo es aplicado a la predicción de flujo del río Huron en Michigan. Los resultados también se contrastan con aquellos de un modelo no lineal de potencias. El algoritmo empleado es lo suficientemente versátil como para adaptarse a la complejidad de los cambios en los datos históricos del flujo.

## Introducción

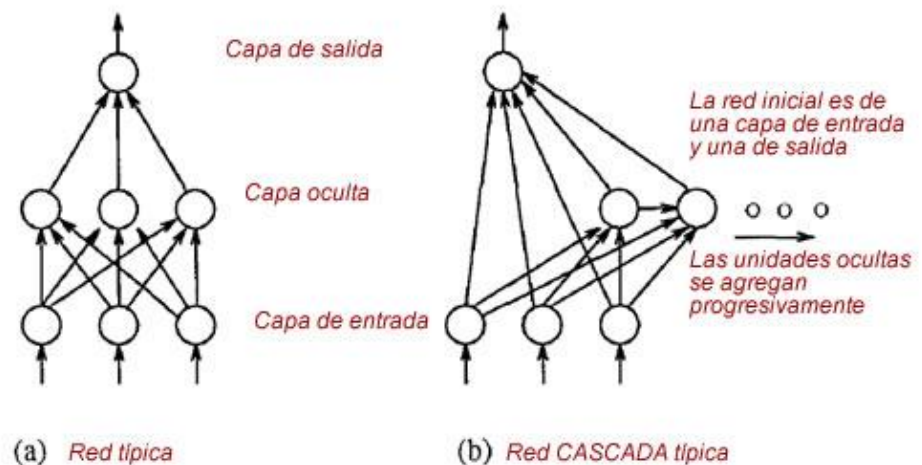
El estudio tiene el propósito de proporcionar datos para valorar las alteraciones futuras de flujo en el río que pudieran afectar a los habitantes vecinos. Se dispone de estaciones a 30 km aguas arriba y 20 km aguas abajo del lugar de muestra, con datos continuos desde 1960. Otras estaciones fueron descontinuadas en 1977 y 1982.

Los flujos en corrientes y ríos están influenciados por varios factores como la topografía de la cuenca, la cobertura vegetal, los tipos de suelos, las características del canal, los acuíferos de aguas subterráneas, la distribución de la precipitación, el deshielo de las nieves, las actividades rurales y urbanas, entre otros.

El estudio reconoce la importancia de elegir un tamaño apropiado de las redes neurales. Si es muy pequeña, puede tener limitaciones para un aprendizaje correcto. Si es muy grande, podría no converger o sobreajustar los datos históricos en vez de generalizarlos. Debido a ello, los autores decidieron usar el algoritmo de *correlación en cascada* que puede sintetizarse automáticamente a su propia arquitectura de red como parte de su proceso de entrenamiento.

## El algoritmo de correlación en cascada

Este algoritmo combina la idea de una arquitectura incremental y aprendizaje en un procedimiento de entrenamiento.



**Figura 23. Red neuronal típica y red neuronal CASCADA**

En resumen.

- El entrenamiento comienza con una red mínima consistente de una capa de entrada y otra de salida.
- Si el algoritmo de entrenamiento no puede disminuir el error residual, se para la etapa de entrenamiento y se ingresa a otra con una unidad oculta.
- La unidad oculta agregada tiene conexiones asociadas desde la capa de entrada, pero no hacia la capa de salida. Los pesos asociados con las unidades ocultas son optimizados por un método de gradiente ascendente. Cuando una unidad oculta es entrenada, los pesos asociados con la capa de salida permanece sin cambiar.

- Una vez que una unidad oculta es agregada a la red, llega una nueva unidad oculta. Se actualiza el entrenamiento para lograr los pesos de todas las conexiones hacia la capa de salida.
- El proceso continúa hasta que la expansión de la red entrenada indique un aprendizaje exitoso.

## Evaluación de la condición de pavimentos

### Referencia

Ahmed Shalaby and Alan Reggin (The University of Manitoba, Winnipeg, Canada). *Optimization of data collection needs for manual and automated network-level pavement condition ratings based on transverse variability and neural networks*. Canadian Journal of Civil Engineering. Vol 34, 2007. Canada.

El artículo trata con dos aproximaciones para optimizar la condición de pavimentos para la red urbana de la ciudad de Winnipeg. Primero, se aplicó una prueba estadística para valorar la variabilidad transversal de los datos. La prueba comparó los índices para una línea con aquellos de todas las líneas de cada segmento. La prueba concluyó que las medianas de los dos grupos son iguales en un 92% de intervalo de confianza y que hay distorsiones observadas en los datos. La distorsión puede ser eliminada si la línea estudiada es seleccionada aleatoriamente. La segunda aproximación consistió en predecir los valores visuales desde una medición automática (a partir del uso de láser) del ahuellamiento y del índice de rugosidad internacional, IRI. Fue seleccionado el algoritmo backpropagation, y se empleó el coeficiente Kappa para examinar la consistencia de los resultados (entre los datos recogidos en forma visuales y aquellos calculados con la red neural). Estos mostraron que sólo fue alcanzada una concordancia moderada y que se requiere de información adicional para mejorar la predictibilidad del modelo.

### Introducción

La condición de pavimentos en la zona de estudio se valora a partir de una inspección visual de la superficie con índices generales, índices de agrietamiento, e índices de despostillado de las juntas. El ámbito comprende una red regional de arterias urbanas y otra de calles colectoras y locales. Los registros tienen varios años. El estudio señala la dificultad y riesgo de efectuar inspección visual en vías de alto tráfico y velocidad de hasta 80 km/h. El trabajo requiere de ocho semanas para cada grupo de registros, en una inspección anual.

La inspección automatizada con láser muestra ser más productiva y sin exposiciones de los riesgos ya señalados. Las mediciones son efectuadas desde un vehículo que viaja a la velocidad del tráfico y sin interferirlo. Con este método es posible también registrar todas las líneas. Los datos son típicamente reportados a intervalos de 10 a 100 m.

Aunque se reconoce que la inspección visual puede conducir a datos distorsionados, la gran cantidad de registros con este método hace deseable tratar de relacionarlos con el levantamiento automatizado con láser.

En el estudio se investigan dos métodos para reducir el volumen de datos que debe colectarse para ser evaluados.

- El primero es tomar la muestra en una línea en pocos kilómetros de la red. Este muestreo es válido a nivel de gestión, aunque no para el análisis y diseño de la red. Se requiere de un análisis de la variabilidad transversal para saber

si una sola línea puede ser tomada como representativa en el caso de líneas urbanas.

- El segundo método estudiado para minimizar la cantidad de datos a acopiar corresponde a eliminar aquellos elementos de poco uso y a otros elementos que podrían ser razonablemente estimados desde otras variables. Fueron construidas redes neurales artificiales para predecir índices de agrietamiento y despostillado a partir de mediciones automatizadas con láser del IRI y datos del ahuellamiento. De esta manera se podrán usar datos manuales de deterioro de las vías.

### Uso de la red neural

La arquitectura de la red neural requiere de la determinación de entradas y salidas, el número de capas ocultas, y el número de neuronas ocultas en cada una de ellas. En el estudio se utiliza una sola capa oculta.

El aprendizaje es efectuado en dos tipos de redes según se muestra en la Figura 24. En cada una de ellas se emplean el IRI y el ahuellamiento como entrada, cinco neuronas en la capa oculta, y funciones sigmoideo de transferencia. En la primera red se tiene como salida un vector con cuatro elementos. En la segunda, se tiene una sola salida.

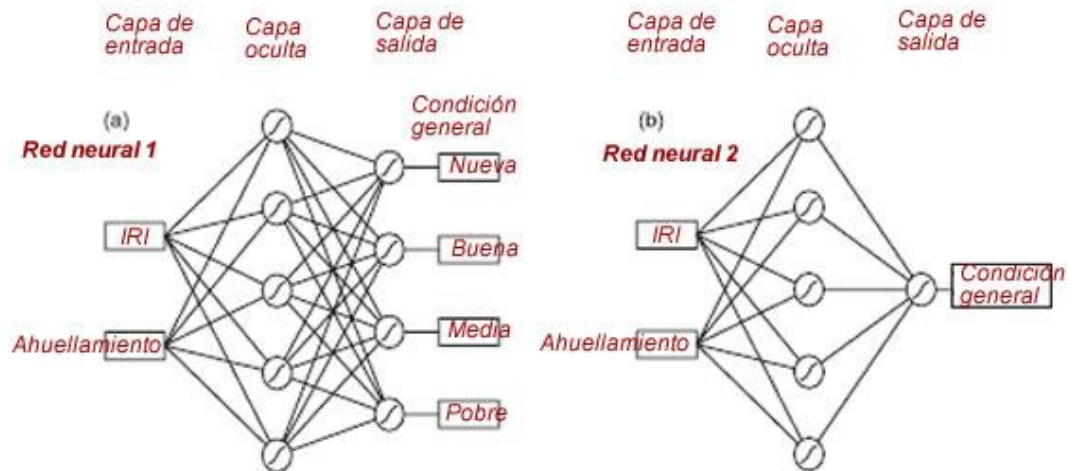


Figura 24. Arquitectura de las dos redes neurales

Las redes fueron entrenadas 100 veces para 500 iteraciones cada una. La iteración termina cuando el error se ha estabilizado y se alcanza el valor más bajo. Se emplearon el 80% de los datos para el entrenamiento, y el 20% para probar su efectividad. Se utilizó un módulo del MATLAB para estas tareas.

Se contrastaron los datos levantados en forma manual y los correspondientes resultados a partir de las redes neurales. Para el nivel de consistencia el estudio empleó el coeficiente Kappa, que tiene la forma:

$$\kappa = \frac{\text{exactitud observada} - \text{nivel acordado}}{1 - \text{nivel acordado}}$$

Aunque la comparación indica un cierto nivel de correlación entre datos y resultado, el estudio concluye en la necesidad de incluir otras variables de

entrada (además del IRI y del ahuellamiento) como la edad del pavimento, la adecuación estructural, o indicadores del tráfico.