

# **APLICACIÓN DE TÉCNICAS DE APRENDIZAJE AUTOMATIZADO PARA LA PREDICCIÓN DE LOS DETERIOROS SUPERFICIALES EN PAVIMENTOS.**

Muzzulini R., Pagola M., Giovanon O.

Laboratorio Vial del Instituto de Mecánica Aplicada y Estructura. Facultad de Ciencias Exactas, Ingeniería y Agrimensura. Universidad Nacional de Rosario.  
remuzzu@gmail.com

## **1. Resumen**

Desde el inicio del período de vida de una ruta se inicia un proceso de deterioro, tal que al final de su vida útil manifestará un conjunto de fallas que reducirán la calidad de circulación, incrementando los costos de mantenimiento y de los usuarios. El relevamiento periódico de la condición del pavimento, en forma ordenada y sistemática, permite conformar la función del comportamiento de los distintos tramos de una ruta; para luego poder predecir las tareas de mantenimiento necesarias en magnitud y oportunidad. En este trabajo se presenta el desarrollo de una herramienta para predecir la evolución de los valores de deterioro superficial mediante técnicas de “aprendizaje automatizado” Machine Learning. Esta técnica permite crear una función capaz de predecir el valor del atributo correspondiente a cualquier objeto después de haber visto una considerable serie de ejemplos. Es decir, realizar predicciones de evolución basadas en comportamientos o características que se han visto en los datos ya almacenados. La tarea se realizó a partir de observaciones periódicas de los deterioros de tramos en servicio ubicados en rutas de la región Litoral de Argentina. Se logró desarrollar modelos de comportamiento a partir de la aplicación de Support Vector Machine Regression y Random Forest Regressor. Estas son herramientas de Machine Learning, que permitieron resolver problemas de estimación de funciones multidimensionales, basadas en este caso en datos de fechas, resistencia estructural, tránsito y deterioros. Los análisis realizados plantean un inicio en esta línea de investigación y nos alientan a realizar mejoras que posibiliten una más certera predicción del comportamiento. Se espera que esta herramienta pueda ser implementada en sistemas de gerenciamiento viales y como función de transferencia en programas de diseño estructural. Se lograron resultados óptimos lo que muestra que ambos métodos son apropiados para realizar ajuste y predicción.

## **2. Objetivos**

Una vez que el pavimento se ha puesto en servicio, comienza a tener deterioros superficiales, lo que hace que el usuario modifique su comportamiento y comience a conducir a una

velocidad menor para mantener las condiciones de seguridad del tránsito. Esta circunstancia hace que los tiempos de viaje aumenten y, por lo tanto, aumenten los costos de circulación.

Existen diferentes parámetros para controlar la calidad proporcionada a los usuarios, tales como: rugosidad, adherencia de la superficie de la carretera, ahuellamiento, fisuras y baches. La valoración periódica de los mismos permite que se puedan anticipar acciones correctivas, de modo que la calidad de la carretera no caiga por debajo de los límites de aceptabilidad.

En este trabajo, se presentan técnicas de "aprendizaje automatizado" para predecir la evolución de los deterioros. El aprendizaje automatizado es el subcampo de la informática y una rama de la inteligencia artificial que tiene como objetivo desarrollar técnicas que permitan a las computadoras aprender.

Se espera que esta herramienta se pueda implementar en los sistemas de gestión vial y como función de transferencia en los programas de diseño estructural.

### **3. Deterioros superficiales en pavimentos**

Se requieren técnicas de manejo de pavimento y metodologías de auscultación de caminos de pavimento, que consisten en la evaluación del nivel de deterioro superficial y estructural que afecta la calidad del servicio prestado a los usuarios, utilizando metodologías de análisis definidas y el equipo apropiado. Existen diferentes parámetros de deterioro para evaluar la calidad de la superficie de la carretera proporcionada a los usuarios: rugosidad, ahuellamiento, fisuras, baches, desprendimientos, exudación, etc. (Pagola, 2016); (Mohamed, 2015).

#### **3.1. Rugosidad**

La rugosidad evalúa las desviaciones del perfil longitudinal de la carretera con respecto a una superficie plana, que afectan de manera muy importante la dinámica del vehículo, la calidad de la circulación, el efecto dinámico de las cargas y el drenaje. La rugosidad es percibida por los usuarios como movimientos vibratorios que afectan la comodidad de la circulación.

Expresado en IRI (Índice de rugosidad internacional, definido en 1982 por el Banco Mundial), es una variable de tipo continuo, donde el rango va desde 0 para superficies idealmente planas (las pistas de los aeropuertos pueden proporcionar valores más bajos que la unidad), tomando valores entre 1 y 2 m/km para nuevos pavimentos y valores mayores de 6 m/km para superficies deterioradas. Los datos utilizados en el presente trabajo son mediciones realizadas con equipos de respuesta dinámica, de acuerdo con la clase 3 del Banco Mundial.

### **3.2. Ahuellamiento**

Es la pérdida del perfil transversal de la carretera, con depresiones canalizadas en las huellas; siendo esta la zona en la que circulan la mayoría de los vehículos pesados. La forma de medición de este parámetro en Argentina se expresa como la depresión existente bajo una regla rígida de 1.20 m. Los datos utilizados en este trabajo se han obtenido a partir de mediciones manuales realizadas por personas capacitadas, a intervalos de 1 km.

### **3.3. Fisuras**

La presencia de grietas en la capa superficial del asfalto es un indicador de que el material ha consumido su capacidad de fatiga. Este indicador solo lo visualiza el usuario cuando la superficie presenta un alto grado de deterioro, donde pueden producirse escalonamientos y pérdida de material. En Argentina, este parámetro se mide asignando grados de deterioro según el patrón de evolución, por fatiga del material, crecientes de 0 a 10. Grado 0, sin fisuras. Grado 2, fisuras finas y aisladas ubicadas en correspondencia con las huellas. Grado 4, fisuras ramificadas con tendencia a formar mallas. Grado 6, fisuras interconectadas formando bloques. Grado 8, fisuras de alto nivel de severidad, interconectadas con bloques más pequeños tipo piel de cocodrilo. Grado 10 son fisuras generalizadas, con desprendimiento de bloques. Los datos utilizados en el presente trabajo han sido obtenidos del procesamiento de medición manual efectuada cada 1 Km y realizada por personal entrenado que recorre la carretera. Las mediciones se han expresado en porcentaje de fisuras totales manifestadas en superficie, utilizando correlaciones entre metodologías.

## **4. Metodologías**

Se analizaron y compararon dos modelos de regresión: Support Vector Machine Regression y Random Forest Regression. (Cutler, 2013); (Drucker, 1996); (Guareño, 2016).

### **4.1. Support Vector Machine Regression (SVR)**

La técnica de los vectores soportes es una herramienta universal para resolver problemas de estimación de funciones multidimensionales. Se trata de seleccionar el hiperplano regresor que mejor se ajuste al conjunto de datos de entrenamiento, basándose en considerar una distancia margen  $\epsilon$ , de manera que todos los ejemplos se encuentren en una banda o tubo entorno a dicho hiperplano. Se pretende que la función esté lo más próxima posible a los puntos. A la hora de definir el hiperplano, solo se consideran los ejemplos que disten más de  $\epsilon$  del hiperplano. Estos ejemplos son los considerados vectores soporte, se identifican con la

posibilidad estricta de las variables artificiales asociadas, que cuantifican el error cometido entre la aproximación y el valor real de cada ejemplo del conjunto de entrenamiento.

#### **4.2. Random Forest Regression (RFR)**

RFR son un conjunto de árboles de regresión diferentes y se utilizan para la regresión múltiple no lineal, donde cada hoja contiene una distribución para la variable de salida continua. El objetivo de estos métodos es inyectar al algoritmo la aleatoriedad justa para maximizar la independencia de los árboles manteniendo una precisión razonable. Los resultados resultan ser insensibles al número de características seleccionadas para dividir cada nodo. Por lo general, al seleccionar una o dos características se obtienen resultados óptimos.

### **5. Modelado de una Red Vial**

#### **5.1. Selección de Variables Independientes**

Las variables independientes, predictores en el futuro, son independientes en el sentido de que son variables externas y medibles. La elección de estas variables no es menos importante que la elección de la variable objetivo, ya que determina el éxito del modelado. La mayor parte del tiempo invertido en el desarrollo de modelos se emplea precisamente en el análisis y la elección del conjunto de variables independientes. Algunas de las variables utilizadas en el modelo son: tránsito, ahuellamiento, fisuras.

El tránsito es la variable más importante en el diseño de las rutas, ya que se estudia los efectos que las cargas de los vehículos causarán sobre las mismas. Por esto, es necesario conocer el número y tipo de vehículo que circulará por una vía, así como la intensidad de la carga y la configuración del eje que la aplica. Para el presente estudio, la intensidad de tránsito y las cargas se expresaron en ejes equivalentes de 80 KN (ESAL 80 KN), para cada año de servicio.

#### **5.2. Tipo de Información recolectada**

Los datos se obtuvieron de diferentes tramos ubicados en vías de servicio. Las mediciones fueron hechas por personal de la Dirección Nacional de Vialidad y compartidas con la Universidad.

Los datos son de tramos homogéneos, con la misma estructura y tránsito. Los tramos están situados en diferentes ubicaciones geográficas de la Región Litoral de Argentina.

De los tramos se conocen el tránsito, la estructura, los materiales de la capa, el mantenimiento aplicado y los resultados de las mediciones periódicas: fisuras, ahuellamiento y rugosidad.

En resumen, hay disponibles 325 datos de 59 tramos homogéneos. La calidad del paquete estructural y el terreno, valorados en su conjunto por la deformabilidad bajo carga (deflexión) es un dato que se asume casi constante a través de los años en los casos que no fue reevaluado, mientras que la rugosidad se midió anualmente. La Tabla 1 muestra un ejemplo de datos para los tramos 51 y 55.

| Tramo | Año  | ESAL anual | Deflec. (0.001mm) | % Fisuras | Ahuell. (mm) | IRI (m/km) |
|-------|------|------------|-------------------|-----------|--------------|------------|
| ...   | ...  | ...        | ...               | ...       | ...          | ...        |
| 51    | 2007 | 660        | 1.5               | 0         | 0            | 1.54       |
| 51    | 2008 | 660        | 1.55              | 0         | 0            | 1.54       |
| 51    | 2009 | 660        | 1.672             | 0         | 3            | 1.96       |
| 51    | 2010 | 660        | 1.46              | 1         | 5            | 1.96       |
| 51    | 2011 | 660        | 1.655             | 0         | 6            | 2.56       |
| 51    | 2013 | 660        | 1.7               | 3         | 8            | 2.16       |
| 51    | 2015 | 660        | 1.773             | 1         | 10           | 2.56       |
| 51    | 2016 | 660        | 1.74              | 0         | 10           | 2.95       |
| ...   | ...  | ...        | ...               | ...       | ...          | ...        |
| 55    | 2010 | 590        | 1.5               | 31        | 4            | 2.16       |
| 55    | 2011 | 590        | 1.496             | 31        | 4            | 2.95       |
| 55    | 2012 | 590        | 1.55              | 33        | 3            | 2.95       |
| 55    | 2014 | 590        | 1.749             | 37        | 5            | 2.95       |
| 55    | 2017 | 590        | 1.846             | 33        | 7            | 2.95       |

Tabla 1. Ejemplo de datos de tramos disponibles

### 5.3. Análisis del modelo experimental

El entrenamiento se realizó para los tres deterioros en el orden que se muestran. Primero se desarrolló un modelo para predecir las fisuras. Luego se optimizó el modelo de predicción del ahuellamiento considerando las fisuras. Y por último, se ajustó la rugosidad, utilizando los valores de fisuras y ahuellamiento; en forma semejante al proceso de calibración indicado en el Modelo HDM. Para valorar los modelos se calculó la desviación estándar del error de predicción de ambas técnicas. Para minimizar los errores, los datos se filtraron utilizando los siguientes criterios:

- ID del tramo es una variable que se utiliza como parte de la programación, pero no está incluido en los modelados.
- Cuando la rugosidad aumentó más de 0.6 m/Km IRI de un año a otro, se asumió que se realizó alguna tarea sobre la superficie y no se documentó. Por lo que ese tramo se dividió en dos tramos: un tramo hasta el incremento de rugosidad, y otro tramo después de eso (inicializándolo desde el año cero).

- En los datos de rugosidad, y considerando los errores tomados durante la medición, como las diferencias entre la línea de medición (aspecto crítico en carreteras con alto nivel de deterioro); se aplicó un filtro cuando la diferencia de datos entre dos años consecutivos fue más de 0.3 m/km y menos de 0.6 m/Km. Los datos se eliminaron y se obtuvieron datos nuevos utilizando una regresión polinómica de grado 3 entre los datos de años anteriores y posteriores.
- Para años sin deterioro dado, como en el año 2012 del tramo 51, los datos se crearon como extrapolación de datos previos utilizando una regresión polinómica de grado 3 entre los datos del año anterior y posterior. Para estos períodos, el tránsito se incrementó utilizando una tasa de incremento del 2%.
- Los datos de deterioro fueron forzados a tener un incremento entre años. Si el ahuellamiento, la formación de fisuras o la rugosidad de un año a otro disminuían, se forzaba a aumentar.

#### **5.4. Entrenando con los primeros n-1 años**

En primera instancia, se entrenó con los primeros n-1 años para optimizar ambos modelos de regresión. Se comienza con la predicción de las fisuras. El porcentaje de fisuras del año anterior se tomó como entrada; siendo el objetivo de predicción el porcentaje de fisuras del año actual. Además de los datos de entrada: año de medición, deflexión, anual ESAL.

Como segundo paso, se ajustó el modelo de predicción del ahuellamiento. Se realizó entrenando los modelos de datos con los primeros n-1 años y considerando los datos de fisuras. Se tomó como dato de entrada el ahuellamiento del año anterior; siendo el objetivo de predicción el ahuellamiento del año actual.

En la Figura 1a se grafica el valor real del % de fisuras totales correspondiente al último año medido vs los valores predichos por los modelos. El error de predicción de los modelos es: 4.41% para el modelo SRV y 4.19% para el modelo RFR. En la Figura 1b se grafica el valor real del ahuellamiento correspondiente al último año medido vs los valores predichos por los modelos. El error de predicción de los modelos expresado en mm son 1.13 para el modelo SRV y 1.60 para el modelo RFR. De manera similar a la predicción del ahuellamiento y fisuras, se realizó la predicción de la rugosidad. La rugosidad del año anterior, los datos de fisuras y ahuellamiento se utilizaron como datos del modelo; siendo el objetivo de predicción

la rugosidad del año actual. En la Figura 1c se grafica el valor real de la rugosidad correspondiente al último año medido vs los valores predichos por los modelos. El error de predicción de los modelos expresado en IRI es: 0.20 m/Km para el modelo SRV y 0.19 m/Km para el modelo RFR.

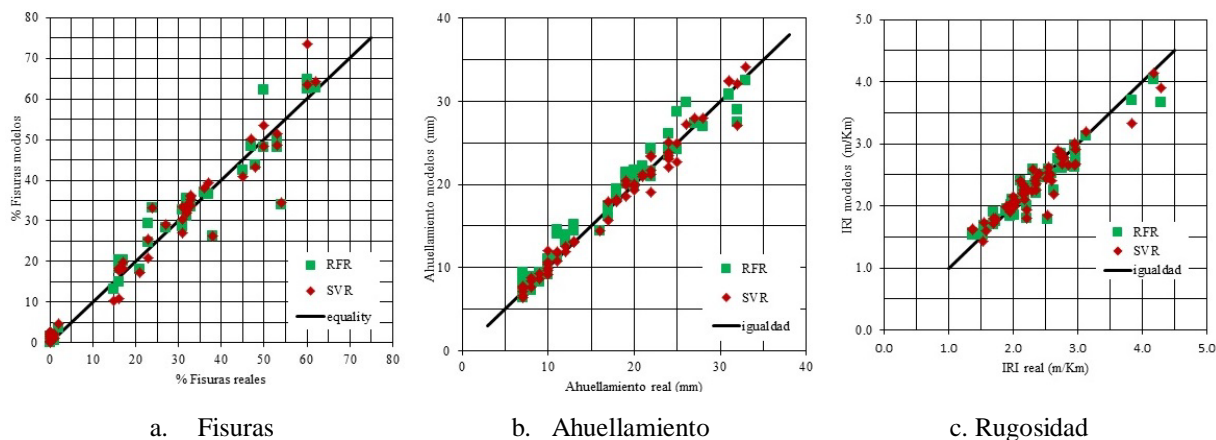


Figura 1. Fisuras, ahuellamiento, rugosidad último año, valores reales medidos vs predichos por los modelos

### 5.5. Análisis de predicción utilizando los modelos desarrollados

Lo que se hizo hasta ahora fue utilizar como modelo de entrada los primeros n-1 años, y se analizó la predicción para cada uno de los deterioros mencionados para el último año. Los errores obtenidos utilizando SVR y RFR son similares.

Ahora es el momento de usar los datos y los modelos para validar la predicción. A partir de los primeros datos, los modelos se utilizaron para predecir la evolución de la rugosidad año por año, utilizando los modelos previamente desarrollados utilizando SVR y RFR. Para este análisis, se generó un vector de entrada como sigue: el año de medición se incrementó en un año, la deflexión se consideró constante al último año, se adoptó una tasa de crecimiento del tránsito de 2 % y el ahuellamiento y las fisuras se obtuvieron a partir de los modelos ajustados. La Figura 2 muestra la evolución de la rugosidad de un tramo, como ejemplo.

Los resultados muestran que ambas metodologías son apropiadas para realizar ajustes y predicción de deterioros. El presente estudio fue nuestra primera prueba de utilizar los modelos de regresión SVR y RFR para el entrenamiento y predicción de deterioros. Los resultados obtenidos son satisfactorios y vamos a continuar en futuras investigaciones utilizando otro grupo de datos de tramos, para otras regiones de Argentina.




Figura 2. Predicción de la rugosidad con SVR y RFR

## 6. Conclusiones

Al momento de priorizar obras o mantenimientos de rutina es necesario el desarrollo de herramientas adecuadas que permitan predecir la evolución de los deterioros, que puedan ser incorporadas en los sistemas de gerenciamiento que se usan para elaborar los planes plurianuales de obras y mantenimiento y en programas de diseño mecanicista de pavimentos como funciones de transferencia para valorar el comportamiento futuro de las mejoras diseñadas en parámetros como las fisuras, el ahuellamiento y la rugosidad, como MEPDG (AASHTO, 2008).

Los resultados obtenidos muestran que ambos métodos SVR y RFR son apropiados para realizar ajuste y predicción.

Los análisis realizados plantean un inicio en esta línea de investigación y nos alientan a realizar mejoras que posibiliten una más certera predicción del comportamiento.

## 7. Bibliografía

AASHTO. 2008. Mechanistic-Empirical Pavement Design Guide.

Cutler, A. 2013. Trees and Random Forests. Mathematics and Statistics. Utah State University.

Drucker, C., Burges, J., Kaufman, L., Smola, A. and Vapnik, V. 1996. Support Vector Regression Machines. Bell Labs and Monmouth University Department of Electronic Engineering West Long Branch.

Mohamed Jaafar, S., Ahlan, M and Uddin, W. 2015. Modeling of pavement roughness performance using LTTP database for southern region in the U.S. Bituminous Mixtures & pavements VI

Pagola, M. and Giovanon, O. 2016. Curso Evaluación de Calzada. FCEIA UNR. Argentina.