




XIII Congreso Mexicano del Asfalto. 20, 21y 22 de agosto de 2025, Cancún, Quintana Roo, México

Tema:

**Aplicación de Machine Learning en la
evaluación de la resistencia al
agrietamiento y predicción de ciclos de
falla en pavimentos flexibles**



Yesica Alexandra Salcedo Velandia

21 de agosto 2025

Tema: Coautores



Pedro Limón Covarrubias



Valeria Montserrat
Mora Gutiérrez



Karla Ávila Cárdenas

21 de agosto 2025

Aplicación de Machine Learning en la Evaluación de la Resistencia al Agrietamiento y Predicción de Ciclos de Falla en Pavimentos Flexibles

Ing. Yesica Alexandra Salcedo Velandia



XIII Congreso Mexicano del Asfalto. 20, 21y 22 de agosto de 2025, Cancún, Quintana Roo, México

CONTENIDOS



01

Introducción y objetivos

02

Metodología general

03

Ensayo EFC

04

Preprocesamiento y variables

05

Modelos de Machine Learning

06

Validación y resultados

07

Interfaz Gráfica y aplicaciones

08

Conclusiones



Introducción

- El agrietamiento por flexión es una de las principales causas de deterioro estructural y funcional en pavimentos flexibles.
- Se propone integrar el Ensayo de Flexión Circular (EFC) con modelos de Machine Learning (ML) como alternativa eficiente para predecir el comportamiento estructural de mezclas asfálticas.



Objetivos

Evaluar

La resistencia al agrietamiento mediante EFC.

Desarrollar

Modelos predictivos de FI y NF usando algoritmos ML.

Validar




Los modelos comparándolos con la guía AASHTO MEPDG.

Implementar

Una interfaz para su aplicación en ingeniería vial.



Metodología general



Ensayo EFC


Evalúa resistencia a fractura en modo mixto I/II.



Requiere probeta cilíndrica, carga vertical y sensor LVDT.




Permite obtener la curva carga-desplazamiento y parámetros clave como la energía de fractura (EF) y el factor de intensidad de tensiones (FI).



Ensayo EFC y curva carga-desplazamiento de la muestra 2725 V2-1

Preprocesamiento y variables

- ❖ 240 muestras → 14 variables físicas, reológicas y mecánicas.
- ❖ Proceso: limpieza, análisis exploratorio, normalización (StandardScaler), partición 80/20.
- ❖ Variables clave: EF, FI, Va, torsión, penetración, % asfalto.



Etapas del preprocesamiento de datos para el desarrollo del modelo predictivo

Preprocesamiento y variables

Variable	Descripción
N°4, P#8, P#200	Porcentaje de material retenido o que pasa por tamices
% Vacíos (Va)	Porcentaje de vacíos de aire en la mezcla compactada
Contenido de Asfalto (%)	Porcentaje de ligante asfáltico en la mezcla
Torsión (Nm)	Esfuerzo torsional durante el ensayo
Reblandecimiento (°C)	Temperatura a la cual el ligante comienza a fluir
Penetración (mm)	Medida de la consistencia del asfalto bajo carga estándar
Energía de fractura (J)	Energía absorbida antes de la fractura total (área bajo la curva)
Factor de intensidad (FI)	Umbral crítico de esfuerzo para la propagación de una grieta


Variables del dataset.



Modelos de Machine Learning


Factor de intensidad

Random Forest



NF (AASHTO)

eXtreme Gradient Boosting



NF (Empírico)

Regresión Múltiple (EF y FI)

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i$$

Magnitud común a todos los sujetos Peso de cada una de las k variables independientes dentro de la ecuación de regresión Error para cada sujeto



Asociación Mexicana
del Asfalto, A.C.




@AMAACmx

<http://www.amaac.org.mx>



Validación y resultados

El desempeño de los modelos se evalúa mediante métricas estadísticas estándar que permiten cuantificar el error y la capacidad explicativa de las predicciones. El coeficiente de determinación (R^2).



Modelo de ML	R^2
FI (Random Forest)	0.6179
NF - AASHTO MEPDG (XGBoost)	0.9692
NF - EF & FI (Regresión Múltiple)	0.958

Desempeño de R^2 cada modelo

Gráficos de dispersión (real vs predicho).

Interfaz grafica y aplicaciones

La interfaz de usuario que permite:

- ✓ Ingresar parámetros de mezcla (granulometría, vacíos, EF, FI)
- ✓ Obtener predicciones de FI y NF
- ✓ Aplicación directa en diseño estructural vial.

EF	4347.81466
FI	18.871
Va	2.57
Et	0.00023

Predecir

Predicción:

NF: 20592776.3943

Interfaz de usuario para predicción del Numero de ciclos a la falla

N°4	3.36
P#200	2.57
%Vacios	2.95
Cont. Asfalto	5.73
Torsion	67.8
Reblandeci...	66.4
Penetración	59

Predecir

Predictions:

Factor de intensidad: 18.87100818698332

Interfaz de usuario para predicción del FI



Interfaz grafica y aplicaciones

La interfaz amplía su aplicabilidad en distintos contextos operativos y estratégicos dentro de la ingeniería vial:



Mayor eficiencia en diseño y mantenimiento predictivo.



Reducción de ensayos, materiales y personal especializado.



Integración en sistemas de gestión vial.



Compatible con mezclas recicladas (RAP).

Conclusiones

- ✓ La integración de datos experimentales obtenidos mediante el Ensayo de Flexión Circular (EFC) con algoritmos de ML demostró ser una alternativa eficaz para predecir el desempeño estructural de mezclas asfálticas, en términos de resistencia al agrietamiento y vida útil estimada.
- ✓ El modelo de Random Forest para estimar el Factor de Intensidad de Tensiones (FI) utilizó variables comunes en controles de calidad, permitiendo prescindir de ensayos complejos como el módulo resiliente o la fatiga. Esto se traduce en una reducción significativa de tiempo, materiales y carga operativa en laboratorio.
- ✓ La predicción del número de ciclos a la falla (NF) fue altamente precisa tanto con el modelo XGBoost basado en la guía AASHTO MEPDG, como con el modelo empírico propuesto que emplea solo EF y FI, alcanzando este último un $R^2 = 0.9682$, con mayor simplicidad y adaptabilidad.

Conclusiones

- ✓ La implementación práctica de estos modelos permite automatizar la evaluación estructural, mejorar la repetibilidad y disminuir la variabilidad técnica y humana, lo cual mejora la confiabilidad en el diseño de mezclas.
- ✓ Desde el punto de vista económico, estos enfoques permiten optimizar recursos técnicos y financieros al reducir el uso de probetas, materiales y personal especializado. Además, su bajo costo computacional permite realizar simulaciones y análisis sin elevar los costos del proyecto.
- ✓ Finalmente, por su diseño replicable y uso de datos accesibles, esta metodología tiene un alto potencial de escalabilidad, siendo aplicable en distintos contextos climáticos, tipos de tráfico y materiales. También es compatible con el uso de materiales reciclados (RAP y NFU), fomentando la infraestructura vial sostenible y resiliente.

¡muchas gracias!

Ponente: Yesica Alexandra Salcedo Velandia

Contacto: yesica.salcedo9384@alumnos.udg.mx

