

Cobertura total de la fricción de pavimentos asfálticos a nivel de red

Christian A. Sabillón Orellana

christian.sabillon@utexas.edu

Jorge A. Prozzi

prozzi@mail.utexas.edu

Joaquin B. Hernandez

joaquinb@utexas.edu

La resistencia al deslizamiento es una característica crítica de la superficie del pavimento asociada con la seguridad de los usuarios de la carretera. La mayor parte de la literatura sobre seguridad vial indica una correlación inversa donde a medida que disminuye la fricción de una carretera, el número de accidentes en pavimento mojado tiende a aumentar. No obstante, medir fricción a nivel de red es complicado debido a las ineficiencias relacionadas con el consumo de agua, el desgaste de neumáticos y estrictas restricciones presupuestarias.

Estas limitaciones han creado una gran demanda por un modelo capaz de predecir la fricción del pavimento con un alto grado de exactitud utilizando información que es fácil de recolectar, como la textura del pavimento. Este estudio recolectó una muestra de treinta tramos de carreteras en el estado de Texas que cubren una amplia gama de superficies asfálticas, texturas y fricción. Estos datos se utilizaron para crear modelos de aprendizaje automático que utilizan textura para predecir con exactitud la fricción y el tipo de superficie del pavimento.

El modelo final estima fricción en términos del número de deslizamiento (ND) en los principales pavimentos asfálticos presentes en la región central de Texas con un coeficiente de determinación múltiple (R_{adj}^2) de 80%. La forma innovadora en que se utilizan los algoritmos de aprendizaje automático en este estudio tiene el potencial de permitir que las agencias de carreteras obtengan una cobertura total de la red caminera con estimaciones de fricción con alto nivel de confiabilidad.

Palabras Clave: Fricción, textura, deslizamiento, aprendizaje automático

Skid resistance is a critical pavement surface characteristic associated with road user safety, especially during wet weather conditions. The bulk of literature on highway safety indicates an inverse correlation between roadway friction levels and number of wet weather crashes. In other words, as skid resistance decreases, the number of wet weather crashes increases. Nonetheless, skid resistance remains a cumbersome characteristic to measure at a network level due to the inefficiencies of the measuring equipment such as water usage, tire wear, and strict budgetary constraints from highway agencies.

These limitations have created a high demand for an alternative model capable of predicting pavement friction continuously using readily available information, such as pavement texture, with a high degree of accuracy. This study collected a representative sample of thirty highway pavement sections in the state of Texas that cover a vast range of pavement surfaces, textures, and friction levels. The data were subjected to stringent quality control and used to create machine learning models that use pavement texture to accurately predict surface information and friction.

The final model estimates skid in terms of skid number (SN) on the major types of flexible pavements present in Central Texas with an accuracy in the order of 80% in terms of the coefficient of multiple determination (R_{adj}^2). The innovative way in which machine learning algorithms are used in this study has the potential to allow highway agencies to obtain full network coverage of reliable estimates for friction.

Keywords: Friction, texture, skid resistance, machine learning.

1. INTRODUCCIÓN

Los accidentes automovilísticos pueden ser causados debido a numerosos factores; sin embargo, las causas más comunes se pueden agrupar en tres categorías: aquellas relacionadas con el conductor, con el vehículo y con el estado de la carretera [1,2]. No obstante, los malos hábitos de conducir, fallas mecánicas del vehículo y el clima severo son factores fuera del control de cualquier agencia vial, por lo que es imposible, para las mismas, evitar que ocurran este tipo de accidentes. No obstante, las agencias tienen cierto control sobre la fricción del pavimento, la cual, puede mitigar indirectamente el número de accidentes en todas las categorías cuando se mantiene en un nivel adecuado. La fricción es la característica superficial más importante del pavimento con respecto a la seguridad del conductor, especialmente en condiciones de superficie mojada.

Cada año, cuando llueve, se produce una cantidad significativa de accidentes en los Estados Unidos (EE. UU.), por lo tanto, garantizar una fricción adecuada es esencial para mejorar la seguridad pública. Las agencias de seguridad vial miden fricción directamente en las carreteras principales anualmente y una vez cada cuatro años en carreteras de bajo volumen. Sin embargo, intentar recopilar medidas de fricción en toda la red anualmente con los presupuestos disponibles es imposible debido a lo ineficiente que son las unidades usadas para medir fricción.

Durante décadas, las agencias de transporte de todo el mundo han invertido tiempo y dinero en encontrar formas de estimar fricción mediante la correlación con la textura del mismo pavimento. Sin embargo, estas correlaciones no son sencillas. Se sabe que factores como la calidad de los agregados, las condiciones ambientales y de tráfico, y los daños en la carretera afectan la resistencia al deslizamiento con el tiempo, pero esa información no siempre se sabe a nivel de red [3,1]. Por lo tanto, actualmente, no existe un método consensuado para predecir la fricción del pavimento a nivel de red con un alto nivel de confiabilidad. Sin embargo, este estudio propone una forma innovadora de utilizar el aprendizaje automático para estimar la fricción del pavimento utilizando medidas de textura.

1.1 Fricción del pavimento/resistencia al deslizamiento

La fricción del pavimento se define como la proporción entre la fuerza que resiste el movimiento relativo hacia adelante de un vehículo en movimiento y la fuerza vertical [3]. La fuerza de fricción es el resultado de una interacción compleja entre histéresis y adhesión a medida que los neumáticos del vehículo ruedan sobre la carretera [3,4]. La adherencia es el resultado de las fuerzas de Van der Waals que se desarrollan en el interfaz del neumático con el pavimento, lo que refleja el entrelazamiento de microestructuras a pequeña escala en las dos superficies [3,4]. La histéresis se refiere a la disipación de energía que ocurre cuando un neumático se mueve sobre las protuberancias y depresiones en la superficie del pavimento. Esta energía se almacena dentro del caucho y se libera en forma de calor durante la relajación del neumático. La pérdida resultante deja una fuerza de fricción neta que ayuda a detener el avance de los vehículos [2,3,4].

La resistencia al deslizamiento se refiere a la capacidad del pavimento para evitar la pérdida de tracción de los neumáticos y, en los EE. UU., se mide mediante el número de deslizamiento (ND) [4]. El ND se determina utilizando un dispositivo llamado "Locked-Wheel Skid Tester" (LWST) y depende principalmente de la textura del pavimento, pero también es sensible a la humedad, el deterioro del pavimento y la temperatura [1].

1.2 Equipos para medir fricción

Los equipos que se utilizan para medir la resistencia al deslizamiento consisten en dispositivos que deslizan caucho sobre la superficie del pavimento, generalmente mojado, para medir la fuerza de reacción generada. La forma en que se mide esta fuerza de reacción se puede resumir en tres principios. El principio del deslizador consiste en un componente deslizante unido al pie de un brazo de péndulo o cabeza giratoria, que frena al entrar en contacto con la superficie del pavimento. Los dispositivos que usan este principio son relativamente económicos y requieren control de tráfico para usarse en el campo. El principio del coeficiente de fricción longitudinal

(CFLo) utiliza una rueda de medición montada en línea con la dirección de desplazamiento. El CFLo se cuantifica utilizando la relación entre las fuerzas verticales y de arrastre promediadas a lo largo de una distancia fija. El dispositivo ejemplar de este principio es el LWST. El principio del coeficiente de fuerza lateral (CFLa) utiliza un juego de ruedas de medición en ángulo con respecto a la dirección de desplazamiento del vehículo. La relación de las fuerzas verticales y laterales promediadas a lo largo de una distancia fija representa la resistencia al deslizamiento. El dispositivo más común que usa el principio CFLa es el "Sideway-force Coefficient Routine Investigation Machine" (SCRIM) [6].

1.3 Limitaciones

El dispositivo de medición de fricción ideal es uno que sea de bajo costo, efectivo, eficiente y tenga facilidad para recolectar datos a nivel de red. Desafortunadamente, la mayoría de los dispositivos modernos sólo pueden sobresalir en dos de estas categorías. Considere el DFT, el dispositivo es relativamente económico y efectivo, pero tiene mala cobertura y eficiencia porque obtener medidas DFT a nivel de red consumiría demasiado tiempo. Por esta razón, los dispositivos que miden la fricción de forma dinámica y continua son una mejor alternativa que aquellos que son estáticos. En los EE. UU., el LWST es el dispositivo de medición de fricción más utilizado, pero este equipo tiene algunas limitaciones, particularmente en curvas e intersecciones. Las fuerzas verticales y de arrastre tienden a oscilar en esas secciones de carretera debido al movimiento de giro, lo que provoca medidas inestables.

El equipo de medición de fricción continua (CFME), como el SCRIM, puede superar muchas limitaciones del LWST. Además, los CFME también proporcionan datos de mayor resolución que tienen una fuerte correlación con los accidentes automovilísticos [7,9]. Sin embargo, este equipo todavía tiene dos inconvenientes: un alto costo inicial y de mantenimiento y la utilización de volúmenes sustanciales de agua para producir estos datos de alta calidad. La tendencia observada es que todos los dispositivos son efectivos, pero existe un delicado equilibrio entre costo, eficiencia y cobertura.

1.4 Textura del pavimento

La textura del pavimento se define por irregularidades en la superficie del pavimento que se desvían de una superficie plana. El perfil de textura es una función aleatoria estacionaria bidimensional (2-D) de la elevación de la superficie del pavimento a lo largo de una distancia horizontal que puede ser longitudinal o transversal. Los perfiles de textura son la representación más simple de textura del pavimento [1] y normalmente se utilizan para calcular estadísticas de textura, como el "Mean Profile Depth" (MPD). La textura del pavimento también se puede caracterizar mediante el uso de superficies tridimensionales (3-D). Una superficie de textura 3-D se recrea combinando varios perfiles 2-D contiguos, o tomando una imagen de un área usando dos cámaras en ángulo y colocadas una frente a la otra. La Figura 1 muestra una representación tridimensional y bidimensional de textura del pavimento.

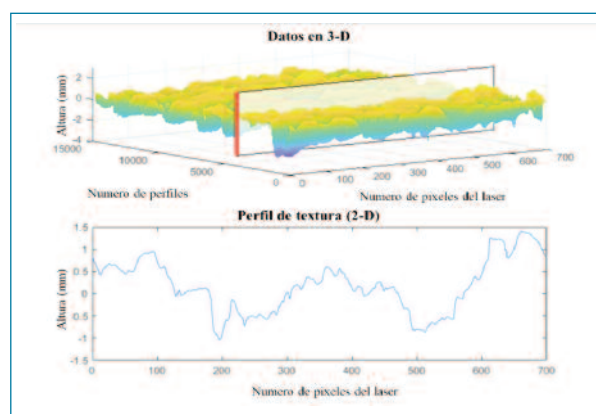


Figura 1. Superficie de pavimento 3-D (arriba), perfil de pavimento transversal 2-D (abajo)

En 1987, la Asociación Mundial de la Carretera estableció las cuatro categorías de textura del pavimento: irregularidad/rugosidad, megatextura, macrotextura y microtextura. Cada categoría es una función de las longitudes de onda de la textura o la frecuencia espacial y su amplitud vertical [9], sin embargo, en este artículo solo se enfocará en las últimas dos. La macrotextura es importante para prevenir el hidroplaneo en pavimentos con velocidades de 80 km/h o más, así como para reducir el ruido automovilístico y salpicaduras [10]. Por otro lado, la microtextura es importante para la fricción en pavimen-

tos secos con velocidades de 80 km/h o más y pavimentos mojados, pero demasiada microtextura puede aumentar el desgaste de los neumáticos. [1, 10]

Los primeros dispositivos para medir textura, como el "parque de arena", tenían limitaciones en cuanto a repetibilidad y variación entre diferentes operadores. Los dispositivos de medición sin contacto, como el Circular Track Meter (CTM), son más consistentes y permiten mediciones precisas y consistentes en cualquier ubicación, pero aun así tienen la desventaja de reducir la textura a un solo atributo. Para superar estas limitaciones, se desarrollaron sensores que permiten capturar un área de pavimento más amplia y calcular múltiples estadísticas de textura. Algunos ejemplos de dichos dispositivos incluyen el analizador de superficie tridimensional portátil LS-40 y el escáner láser lineal (LLS). Estos dispositivos proporcionan una mayor precisión y resolución espacial que los dispositivos anteriores, sin embargo, su limitación más grande es que son estáticos. Para recolectar dinámicamente datos de macrotextura sin control de tráfico, se han desarrollado dispositivos láser montados en vehículos, que utilizan la perfilometría de textura basada en láser. También se pueden utilizar cámaras de esteorevisión para capturar imágenes tridimensionales del pavimento, aunque estas se utilizan mejor para pruebas de baja velocidad debido a los largos tiempos de exposición [1]. En general, aunque cada dispositivo tiene sus limitaciones y problemas asociados, la selección cuidadosa del método de medición según las necesidades específicas puede proporcionar mediciones precisas y útiles de la textura del pavimento de la carretera.

2. METODOLOGÍA

Se inspeccionaron un total de 30 tramos de carretera en el estado de Texas, EE. UU. Cada tramo era 800 metros de largo y fue subdividido en cinco secciones de aproximadamente 160 metros de largo. Esto da un total de 150 puntos de datos. Estos tramos fueron seleccionados para cubrir una amplia gama de texturas y fricciones en pavimentos asfálticos. Dentro de estas secciones, las medidas de textura y resistencia al deslizamiento se recolectaron simultáneamente a una velocidad de 80 km/h. Las medidas de deslizamiento se reco-

pilaron a lo largo de la trayectoria de la rueda izquierda utilizando un LWST de acuerdo con la especificación de ASTM E274 [5]. Las medidas de textura se recopilaron a lo largo de la línea central del carril utilizando un sensor láser de línea. El sensor está sincronizado con el eje del vehículo de tal manera que, por cada revolución en el eje motriz, el sensor láser tomará 20 mediciones. Esto da como resultado que el sensor láser se dispare aproximadamente cada 40 mm en la dirección longitudinal (i.e., dirección de desplazamiento).

2.1 Diseño experimental

Los datos del LWST se examinaron cuidadosamente para garantizar que la velocidad del vehículo permaneciera en 80 km/h y que no hubiera anomalías en la fuerza vertical (p. ej., anomalías debidas a rebotes o giros). Se seleccionó una película de agua de 0.5 mm. Se utilizó un algoritmo que combina procesamiento de señales y técnicas estadísticas para procesar los datos de textura. Una vez que los perfiles de textura se procesaron por completo, se calcularon las estadísticas de textura. Estas estadísticas capturan diferentes características topológicas del pavimento como amplitud, espaciamiento, pendiente y frecuencia. Este artículo se centra únicamente en las estadísticas que se usaron en los modelos posteriores. La Tabla 1 muestra estas estadísticas.

En la Tabla 1, h_i es la altura de la coordenada "i" en mm; h_{p_j} y h_{v_j} son las alturas en mm del $j^{\text{ésimo}}$ pico más alto y del $j^{\text{ésimo}}$ valle más bajo, respectivamente; \bar{h} es la elevación media del perfil en mm; n es el número de coordenadas; x es la distancia transversal en mm entre puntos de inflexión, \bar{x} es la distancia media entre los puntos de inflexión en mm; y Δx es el espaciado horizontal entre puntos adyacentes.

Tabla 1. Estadísticas de textura

Estadística	Ecuación	Estadística	Ecuación
Factor de solidez (R_r)	$R_r = \frac{\min(h_i)}{\max(h_i)}$	Promedio de ancho transversal (C_m)	$C_m = \frac{1}{n} \sum_{i=1}^n x_i$
Rugosidad promedia de diez puntos (R_t)	$R_t = \frac{1}{5} \sum_{j=1}^5 (h_{pj} - h_{vj})$	Variación de ancho transversal (C_v)	$C_v = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_i)^2$
Media cuadrática (RMS)	$RMS = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (h_i - \bar{h}_i)^2}$	Desviación estándar del ancho transversal (C_{std})	$C_{std} = \sqrt{C_v}$
Oblicuidad (R_s)	$R_s = \frac{n}{(n-1)(n-2)} \sum_{i=1}^n \left(\frac{h_i - \bar{h}_i}{RMS} \right)^3$	Variación de pendiente de dos puntos (SV_2)	$SV_2 = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{h_i - h_{i+1}}{\Delta x} \right)^2}$

Nota: cada estadística se calcula para cada perfil de pavimento transversal 2D y luego se promedia sobre secciones de 160 metros para resumir la superficie 3D.

2.2 Clasificación de superficies

El proceso de promediar los datos supone que el pavimento es homogéneo en la distancia promediada. Las secciones de pavimento de este estudio se estudiaron cuidadosamente antes de la recopilación de datos y se demostró que eran homogéneas; sin embargo, en la práctica, la superficie del pavimento no se conoce a nivel de red. Por lo tanto, se desarrolló un clasificador de superficies de pavimento para asegurar que se cumpla la suposición de homogeneidad. En este estudio se utilizó un árbol de decisión (AD) como el clasificador para predecir la superficie del pavimento. Los AD son modelos no paramétricos con estructura de árbol que utilizan un conjunto de reglas para tomar decisiones. El modelo crea una serie de preguntas de sí/no para dividir continuamente los datos hasta que se hayan aislado todas las observaciones pertenecientes a cada superficie de pavimento. Se utiliza una estadística conocida como puntaje F1 para resumir la exactitud de un modelo, donde 0% es la peor exactitud posible y 100% es la mejor.

2.3 Predicción de resistencia al derrape

Se utilizó un análisis de regresión múltiple con numerosas variables para construir un modelo probabilístico que relaciona la fricción con múltiples variables explicati-

vas. Para medir el rendimiento de dicho modelo se utilizó el coeficiente de determinación múltiple (R_{adj}^2), el cual cuantifica que tan bien se ajusta el modelo a los datos, pero castiga al usuario por cada parámetro agregado. Este estudio evaluó cuatro modelos estadísticos para predecir fricción. El primer modelo (modelo de textura) representa el enfoque de predicción tradicional donde la fricción se estima utilizando sólo estadísticas de textura. Estos modelos tienden a funcionar bien en un análisis a nivel de proyecto. Sin embargo, cuando se usan a nivel de red con diferentes superficies de pavimento, tienen dificultades para mantener una alta exactitud. El segundo modelo de regresión (modelo de superficie) usó las superficies de pavimento pronosticadas por el AD descrito anteriormente. Las superficies se representan como variables discretas en el modelo. Esto permite que diferentes superficies tengan su propia línea de regresión. El tercer modelo utiliza superficies predichas y estadísticas de textura (modelo de textura y superficie). Según este modelo, cada superficie tiene su propia línea de regresión con una pendiente distinta de cero, y se supone que todas las líneas de regresión son paralelas. Finalmente, el cuarto modelo es el modelo de interacción entre textura y superficie. Este modelo relaja la suposición de paralelismo y permite que cada superficie tenga su propia línea con su propia pendiente. Esto significa que no todas las superficies del pavimento tienen la misma variación en fricción dando un cambio en textura. Las ecuaciones de regresión para los cuatro modelos se proporcionan en las Ecuaciones 2-5. Donde los parámetros de regresión son α, β, γ , y δ .

Cobertura total de la fricción de pavimentos asfálticos a nivel de red

Modelo #1:	$SN = \alpha_0 + \alpha_1 \text{ RMS} + \alpha_2 \text{ Rr} + \alpha_3 \text{ C}_m$
Modelo #2:	$SN = \beta_0 + \beta_1 \text{ HM CS} + \beta_2 \text{ LM CS} + \beta_3 \text{ OMS}$
Modelo #3:	$SN = \gamma_0 + \gamma_1 \text{ RMS} + \gamma_2 \text{ R}_s + \gamma_3 \text{ LM CS} + \gamma_4 \text{ OMS} + \gamma_5 \text{ DMS}$
Modelo #4:	$SN = \delta_0 + \delta_1 \text{ R}_s + \delta_2 \text{ C}_{std} + \delta_3 \text{ HM CS} + \delta_4 \text{ LM CS} + \delta_5 \text{ HM CS} * \text{R}_s$

3. RESULTADOS Y DISCUSIÓN

Los pavimentos en este estudio cubren seis superficies de pavimento flexible: RG con macrotextura alta (HM CS), RG con macrotextura baja o media (LM CS), mezclas de granulometría abierta (OMS), asfaltos de masilla de piedra (SMA), mezclas gruesas densas (DCM), y mezclas finas densas (DFM). Antes de entrenar al clasificador AD, se realizó una prueba de análisis de varianza (ANOVA) para evaluar si el efecto de la textura sobre la fricción era diferente en estas seis superficies de pavimento. Los datos indican fuertemente que la superficie del pavimento afecta directamente a la fricción de la superficie. Luego, se realizaron múltiples comparaciones para probar si el efecto de fricción de cada una de las seis superficies era significativamente diferente. Las pruebas indicaron que HM CS, LM CS y OMS tenían efectos completamente distintos, pero DCM, DFM y SMA tenían efectos estadísticamente similares. Por lo tanto, las últimas tres superficies se combinaron en una sola categoría designada como DMS. Esto resultó en un total

de cuatro superficies de pavimento con distintos efectos sobre la fricción.

3.1 Clasificación

El AD se entrenó utilizando datos de textura antes de promediar cada 160 metros. El número total de puntos de datos fue de 14.210. El modelo de AD final se puede observar en la Figura 2. La Tabla 2 muestra el informe de clasificación. Este informe resume el rendimiento del modelo. La Tabla 2 muestra que la exactitud del modelo es del 93%. Esto significa que, en promedio, el modelo puede clasificar correctamente 93 de 100 superficies de pavimento. Además, los datos indican que LM CS y HM CS son las superficies más difíciles de distinguir dados sus puntajes F1 de 79% y 89%. Esta condición podría resolverse potencialmente con la incorporación de datos de microtextura, ya que LM CS normalmente tiene agregados pulidos.

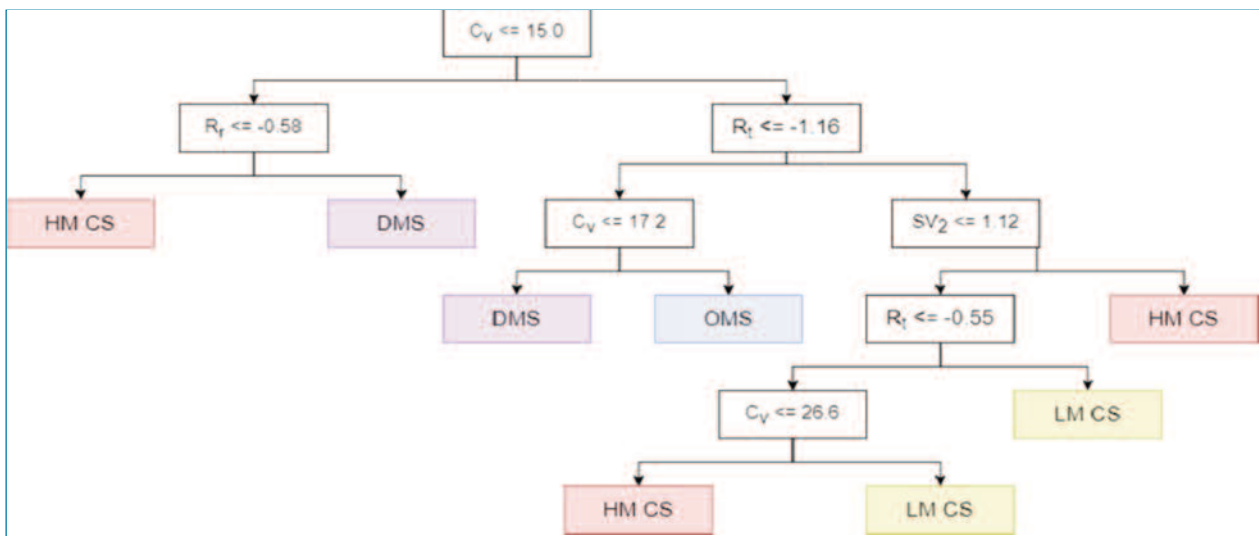


Figura 2. Modelo AD para predecir superficie del pavimento

Tabla 2. Reporte de clasificación para el AD en el conjunto de datos de validación

Superficie	Precisión	Exhaustividad	Puntaje F1	Numero de datos
HM CS	0.74	0.86	0.79	400
LM CS	0.93	0.87	0.89	831
DMS	0.98	0.98	0.98	700
OMS	0.99	0.97	0.98	911
Exactitud global del modelo			0.93	

Tabla 3. Resumen completo del análisis de regresión

Variable	Modelo #1	Modelo #2	Modelo #3	Modelo #4
	Influencia (Valor P)			
Intercepción	0.446 (0.000)*	0.363 (0.000)*	0.318 (0.000)*	-0.107 (0.026)*
Media cuadrática (RMS)	0.585 (0.000)*	~	0.147 (0.000)*	~
Factor de Solidez (Rr)	-0.197 (0.000)*	~	~	~
Promedio de ancho transversal (Cm)	-0.181 (0.000)*	~	~	~
Oblicuidad (Rs)	~	~	-0.207 (0.000)*	-0.296 (0.000)*
Desviación estándar del ancho transversal (Cstd)	~	~	~	0.027 (0.000)*
RG macrotextura alta (HM CS)	~	0.190 (0.000)*	~	0.566 (0.000)*
RG macrotextura baja/media (LM CS)	~	-0.073 (0.000)*	-0.167 (0.000)*	0.239 (0.000)*
Granulometría abierta (OMS)	~	-0.058 (0.000)*	-0.418 (0.000)*	~
HM CS Mezclas densas (DMS)	~	~	-0.302 (0.000)*	~
Interacción entre HM CS y Rs	~	~	~	0.414 (0.000)*
Bondad de Ajuste				
R_{adj}^2	0.273	0.567	0.746	0.793
Error estándar residual	0.100	0.073	0.0516	0.051
* Indica que el valor P es menor a 10^{-3}				

Cobertura total de la fricción de pavimentos asfálticos a nivel de red

3.2 Predicción de resistencia al deslizamiento

El modelo de textura (Modelo #1) se desempeña bien en pavimentos homogéneos, pero se comporta más como generador de números aleatorios en pavimentos heterogéneos. Esto se debe a que, matemáticamente, este modelo utiliza una línea para explicar el comportamiento de múltiples superficies de pavimento. Los resultados del modelo de superficie (Modelo #2) indicaron que los HM CS tienen la mayor fricción, seguido de DMS, OMS y LM CS. Sorprendentemente, el rendimiento de este modelo parece ser de alrededor del 56,7%. Esto implica que, para las superficies estudiadas, más de la mitad de la variabilidad de la fricción en pavimentos flexibles puede explicarse únicamente por la superficie del pavimento. El tercer modelo de textura y superficie (Modelo #3) explica el 74,6% de la fricción, pero no es necesariamente el mejor modelo. Un análisis de segmentación completa se utilizó para incorporar al modelo las estadísticas de textura, las superficies del pavimento y las interacciones más significativas. La única interacción que resultó significativa fue la de la oblicuidad con HM CS. Los datos indican que HM CS es la única superficie cuyo deslizamiento aumenta a medida que la textura del pavimento se vuelve más positiva, mientras que todas las demás superficies ganan deslizamiento a medida que la textura del pavimento se vuelve más negativa. El Mo-

delo #4 tuvo el rendimiento más alto con casi un 80% y es potencialmente el modelo lineal más poderoso que se puede desarrollar usando seis predictores. La Tabla 3 proporciona un resumen del análisis de regresión. La Figura 3 muestra el rendimiento de los modelos estadísticos.

4. CONCLUSIONES Y RECOMENDACIONES

Este estudio demostró que las estadísticas de textura medidas con instrumentación de alta definición tienen una influencia estadísticamente significativa en la resistencia al deslizamiento y se pueden usar para la predicción de la superficie del pavimento a nivel de red y con un alto grado de exactitud. De hecho, la incorporación de la inteligencia artificial y los avances tecnológicos permiten desarrollar modelos predictivos de fricción más potentes que nunca. Con base en los datos analizados, existe una clara relación entre la textura y la fricción; sin embargo, esta relación depende en gran medida del tipo de superficie del pavimento. Las estadísticas de textura por sí solas tienen un rendimiento inferior al 30% bajo pavimentos heterogéneos. Se demostró que incorporar el tipo de superficie predichas por el AD explica más del 50% de la variabilidad en fricción. No obstante, una combinación inteligente de información superficial y estadísticas de textura puede producir un

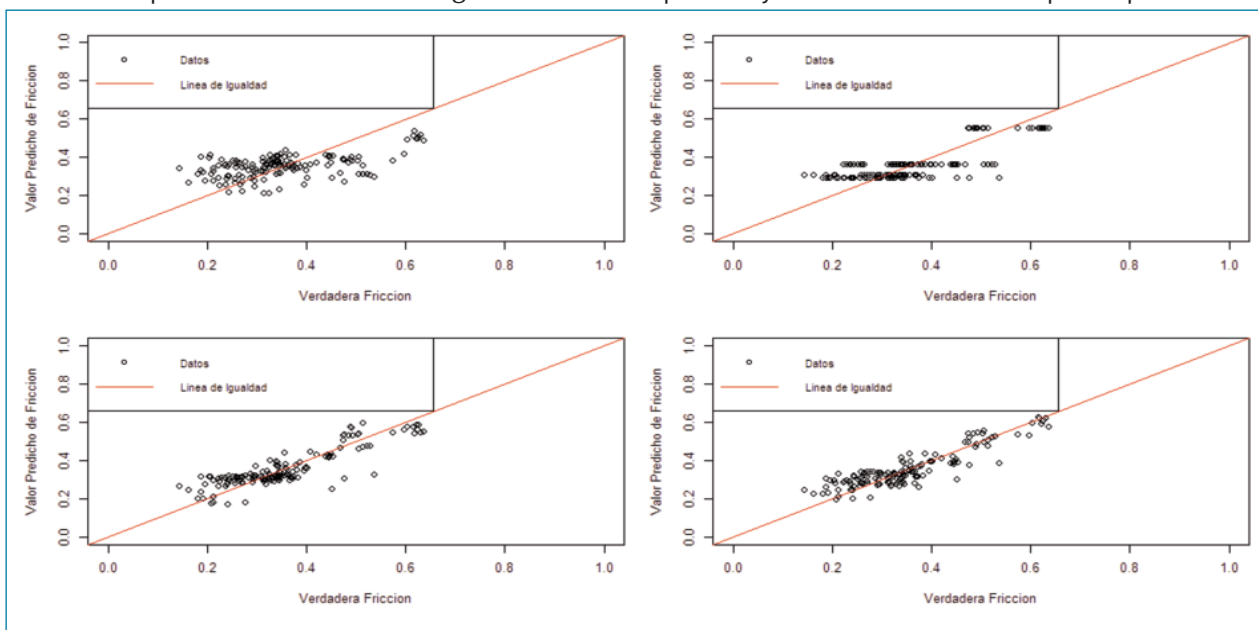


Figura 3. Rendimiento de modelos estadísticos. Valores predichos contra los valores reales.

modelo con una exactitud de 80%. Este estudio podría tener grandes implicaciones, ya que podría ayudar a las agencias de transporte a recopilar una cobertura completa a nivel de red de medidas de fricción anualmente. Actualmente, las agencias recopilan entre el 3 y el 5% de la información de fricción mediante mediciones directas. Este modelo de determinación indirecta de fricción permite una cobertura del 100% de la información con un 80% de exactitud. Dicha información sería de gran utilidad para detectar zonas de baja fricción, para modelar el rendimiento de la fricción a través de los años, entre otros análisis de gestión de pavimentos.

Para mejorar aún más este estudio, se recomienda repetir el análisis una vez que la tecnología láser tenga una resolución y una frecuencia de muestreo lo suficientemente altas como para capturar la primera década de microtextura o una vez se tenga información sobre los agregados usados en el pavimento. Esto ayudara a mejorar el rendimiento del modelo por encima de 80%.

5. REFERENCIAS

- [1] Serigos P, Buddhavarapu P, Gorman G, Hong F, Prozzi J. The Contribution of Micro and Macro-Texture to the Skid Resistance of Flexible Pavement. Austin: Center for Transportation Research; 2016.
- [2] Noyce D, Bahia H, Yambo J, Kim G. Incorporating Road Safety into Pavement Management: Maximizing Asphalt Pavement Surface Friction for Road Safety Improvements. Madison: Midwest Regional University Transportation Center; 2005.
- [3] Hall J, Smith K, Wambold J, Yager T, Rado Z. Guide for Pavement Friction. Washington DC: National Cooperative Highway Research Program (NCHRP); 2009.
- [4] American Association of State Highway and Transportation Officials (AASHTO). AASHTO Guide for Pavement Friction. Washington DC; 2008.
- [5] ASTM E274/E274M-15. Standard Test Method for Skid Resistance of Paved Surfaces Using a Full-Scale Tire. West Conshohocken: American Society for Testing and Materials (ASTM); 2015.
- [6] Flintsch G, McGhee K, de Leon Izeppi K, Najafi S. The Little Book of Tire Pavement Friction. Pavement Surface Properties Consortium. 2012.
- [7] De Leon Izeppi E, Flintsch G, Katicha S, McGhee K, McCarthy R. Locked Wheel and Sideway-Force Continuous Friction Measurement Equipment Comparison and Evaluation Report. Federal Highway Administration Pavement Friction Management Support Program; 2019.
- [8] De Leon Izeppi E, Flintsch G, Katicha S, McGhee K, McCarthy R, Smith K. Pavement Friction Management Program (PFMP) Utilizing Continuous Friction Measurement Equipment and State-of-the-practice Safety Analysis Demonstration Project. Federal Highway Administration Pavement Friction Management Support Program; 2019.
- [9] PIARC, (1987). PIARC Technical Committee on Surface Characteristics: Technical Committee Report No 1 to the XVIII World Road Congress, Brussels, Belgium.
- [10] Hibbs, B., and Larson, R., Tire Pavement Noise and Safety Performance: PCC Surface Texture Technical Working Group. Report No. FHWA-SA-96-068. Federal Highway Administration. Washington, D.C. 1996.
- [11] Amin, E. Shalaby, A, Saleh, M., and Flintsch, G. "Stereo-Vision Applications to Reconstruct the 3D Texture of Pavement Surface." The international journal of pavement engineering 12, no. 3 (2011): 263–273.