

Ajuste de un Modelo no Paramétrico B-spline con Intervalos de Confianza Bootstrap de un Ciclo de Conducción Real en un Circuito RDE en la Ciudad de Riobamba, Chimborazo
Fitting a Non-parametric B-spline Model with Bootstrap Confidence Intervals of a Real Driving Cycle in an RDE Circuit in the City of Riobamba, Chimborazo

Verónica Elizabeth Luna Salguero, Jorge Saúl Sánchez Mosquera.

**CIENCIA, TECNOLOGÍA Y
SOCIEDAD**

Julio - diciembre, V°7-N°2; 2026

Recibido: 20-08-2026

Aceptado: 29-08-2026

Publicado: 31-12-2026

PAIS

- Riobamba - Ecuador
- Riobamba - Ecuador

INSTITUCION

- Universidad Nacional de Chimborazo
- Universidad Nacional de Chimborazo

CORREO:

- ✉ elizabeth.luna@unach.edu.ec
- ✉ saul.sanchez@unach.edu.ec

ORCID:

- 🌐 <https://orcid.org/0009-0006-5601-5457>
- 🌐 <https://orcid.org/0000-0001-5978-7897>

FORMATO DE CITA APA

Luna, V., Sánchez, J. (2026). Ajuste de un Modelo no Paramétrico B-spline con Intervalos de Confianza Bootstrap de un Ciclo de Conducción Real en un Circuito RDE en la Ciudad de Riobamba, Chimborazo. Revista G-ner@ndo, V°7 (N°2), p. 3629 – 3646.

Resumen

La investigación tuvo como objetivo representar el perfil cinemático mediante ciclos de conducción en condiciones reales RDE. Se recolectaron datos de tres ciclos RDE con tramos urbanos, rurales y de autopista con duración de 56,08 km, en la ciudad de Riobamba, Ecuador. La metodología consistió en una investigación bajo el paradigma positivista, de enfoque cuantitativo, carácter descriptivo y analítico, diseño experimental y computacional. Se emplearon técnicas no paramétricas de regresión con bases B-spline y remuestreo paramétrico Bootstrap para la estimación de incertidumbre. Para superar variaciones propias de la conducción real, se estandarizaron los recorridos mediante interpolación lineal con remuestreo y dominio funcional común de 5,995 segundos, se obtuvo una base de datos apilada de 17,985 observaciones. Los resultados reflejan un MSE de 38,3412 km/h², RMSE de 6,1920 km/h, RRMSE de 19,04% y MAPE de 23,46%, representado adecuadamente la tendencia general de la velocidad. Las 5,000 réplicas permitieron cuantificar la incertidumbre, observándose bandas más amplias en el tramo de autopista debido a su mayor variabilidad. La evaluación del modelo evidenció residuos insesgados media de -0.000 km/h, desviación estándar de 16,2172 km/h. Con el uso de 5,000 réplicas Bootstrap con intervalos de predicción al 95% se identificó heteroscedasticidad en fases de autopista debido a mayores niveles de variabilidad.

Palabras clave: Modelo no paramétrico, B-spline, Intervalos de Confianza, Bootstrap, Ciclo de Conducción Real, Circuito RDE

Abstract

The research aimed to represent the kinematic profile by means of driving cycles in real RDE conditions. Data were collected from three RDE cycles with urban, rural and highway sections with a duration of 56,08 km, in the city of Riobamba – Ecuador. The methodology consisted of research under the positivist paradigm, with a quantitative approach, descriptive and analytical character, and experimental and computational design. Non-parametric regression techniques with B-spline bases and Bootstrap parametric resampling were used for uncertainty estimation. To overcome variations typical of real driving, the routes were standardized by linear interpolation with resampling and common functional domain of 5,995 seconds, a stacked database of 17,985 observations was obtained. The results reflect an MSE of 38,3412 km/h², RMSE of 6,1920 km/h, RRMSE of 19,04% and MAPE of 23,46%, adequately representing the general speed trend. The 5,000 aftershocks made it possible to quantify the uncertainty, with wider bands being observed in the section of highway due to its greater variability. The evaluation of the model showed unbiased residues mean -0.000 km/h, standard deviation of 16,2172 km/h. Using 5,000 Bootstrap replicates with 95% prediction intervals, heteroskedasticity was identified in highway phases due to higher levels of variability.

Keywords: Non – parametric model, B – spline, Confidence Intervals, Bootstrap, Real driving cycle, RDE circuit

Introducción

Los modelos estadísticos se consideran actualmente medios indispensables para la representación, predicción y explicación de fenómenos donde se identifica la relación entre variables explicativas y una variable de respuesta. En este sentido, se diferencian principalmente los modelos paramétricos, semiparamétricos y no paramétricos. Según Selk & Gertheiss (2022), la característica fundamental que los distingue reside en que los modelos paramétricos poseen una estructura funcional y parámetros establecidos previamente, mientras que los modelos no paramétricos destacan por su flexibilidad al perfilar su estructura en función de la propia naturaleza de los datos. Como argumentan Toalombo et al. (2022), la regresión no paramétrica hace posible la inclusión de predictores categóricos o funcionales sin depender de estructuras rígidas, por lo que su selección debe fundamentarse en el tipo de relación que se pretenda demostrar. De este modo, los modelos paramétricos resultan altamente eficientes y fáciles de interpretar cuando se cuenta con evidencia adecuada que respalde una forma funcional simple; sin embargo, presentan serias deficiencias al intentar representar comportamientos complejos o cambios abruptos. Por el contrario, Zhang et al. (2026) afirman que la regresión no paramétrica ofrece una mayor adaptabilidad matemática, situándose como la opción óptima en regresiones que requieren aproximar relaciones funcionales desconocidas.

Dentro del ámbito no paramétrico, Toalombo et al. (2022) recalcan que los modelos B-spline generan un ajuste superior frente a variaciones apreciables en las curvaturas, construyendo funciones basadas en segmentos polinómicos interconectados bajo condiciones de suavidad y continuidad. De acuerdo con Govindarajan et al. (2022), los splines destacan por su capacidad de incorporar soporte local, lo que permite modificar el comportamiento de la curva en regiones específicas sin alterar el ajuste global. Esta propiedad diferencia a las bases B-spline de los modelos polinómicos globales, elevando su potencial en la aproximación funcional (Cai & Wang, 2023). No obstante, la eficiencia de un modelo B-spline depende de la configuración de sus bases y de la complejidad del ajuste; Poliak et al. (2025) señalan que una complejidad insuficiente limita la capacidad del modelo para capturar la variabilidad de los datos. Por su parte, Kim et al. (2023) enfatizan que el comportamiento predictivo debe evaluarse mediante métricas de error y procesos de validación, aspectos de vital importancia al analizar series dinámicas altamente variables en el tiempo.

Sin embargo, la determinación de la función que mejor representa a los datos constituye solo un primer paso, siendo imprescindible cuantificar la incertidumbre inherente a cada estimación. Los intervalos de confianza permiten representar dicho nivel de incertidumbre mediante rangos de valores plausibles bajo un nivel de significancia determinado (Cai & Wang,

2023). En el contexto de las regresiones no paramétricas, esta estimación es especialmente crítica, ya que la alta flexibilidad de los estimadores limita la aplicación de los procedimientos inferenciales paramétricos convencionales. Por ello, la integración de bandas de confianza junto con la suavización spline proporciona una caracterización inferencial notablemente superior del fenómeno en estudio.

Para abordar la inferencia en estos entornos, el método Bootstrap se posiciona como una estrategia fundamental para cuantificar la incertidumbre mediante el remuestreo repetido de los datos. Kim et al. (2023) aseveran que su eficiencia radica en la capacidad de obtener errores estándar, intervalos de confianza y distribuciones empíricas sin asumir distribuciones teóricas rígidas. Al combinar el Bootstrap no paramétrico con regresiones B-spline, se logran construir bandas de confianza al 95% altamente fiables; mientras el B-spline aporta la flexibilidad necesaria para capturar las curvaturas de los datos, el Bootstrap evalúa la estabilidad del ajuste frente a la variabilidad muestral (Zúñiga & Meneses, 2024). No obstante, cuando los datos presentan dependencia temporal, el remuestreo convencional destruye la estructura secuencial; en estos escenarios, el Bootstrap por bloques resulta sumamente eficiente al remuestrear grupos consecutivos de datos, preservando así la autocorrelación interna propia de las series temporales (Sennefelder et al., 2022).

Esta caracterización resulta indispensable cuando se analizan ciclos de conducción real perfilados mediante estructuras dinámicas de velocidad y aceleración secuenciales en el tiempo. Sennefelder et al. (2022) sostienen que el uso de bases de datos originadas en condiciones reales incrementa la capacidad de reproducir perfiles cinemáticos representativos. A diferencia de los ciclos estandarizados en laboratorio, los datos reales capturan las variaciones intrínsecas entre aceleraciones, desaceleraciones y detenciones derivadas de cada ruta y estilo de conducción (Jiang et al., 2024; Xin & Gao, 2024). En este marco se sitúan los ensayos de Emisiones en Conducción Real (Real Driving Emissions, RDE), que integran tramos urbanos, rurales y de autopista para registrar, con alta resolución temporal, variables como velocidad, aceleración y posición vehicular (Dabčević et al., 2022; Rivera et al., 2024).

En virtud de lo expuesto, el presente estudio se orienta al uso de datos generados a partir de ciclos de conducción RDE en la ciudad de Riobamba, abarcando trayectorias irregulares en tramos urbanos, rurales y de autopista. El objetivo principal es desarrollar y aplicar un marco metodológico basado en la regresión no paramétrica B-spline combinada con el Bootstrap por bloques para modelar las estructuras cinemáticas de tiempo y velocidad, garantizando un ajuste preciso de las variaciones continuas del perfil de conducción junto con la cuantificación de su respectiva incertidumbre mediante bandas de confianza al 95%.

Métodos y Materiales

La investigación se enmarca en un paradigma positivista con un enfoque cuantitativo, orientado al análisis objetivo y observable de la dinámica vehicular mediante datos empíricos de ciclos de conducción en condiciones reales (*Real Driving Emissions*, RDE). Las variables cinemáticas se registraron de forma directa e instrumental mediante sensores y sistemas de adquisición de datos embarcados, permitiendo una cuantificación precisa para su posterior modelado estadístico. El procesamiento de la información se fundamenta en técnicas no paramétricas de regresión B-spline combinadas con remuestreo *Bootstrap*, con el propósito de caracterizar las relaciones funcionales no lineales y estimar la incertidumbre mediante bandas de confianza al 95%.

Por su alcance, el estudio es de carácter descriptivo-analítico y adopta un diseño de tipo observacional con una fase experimental y computacional. Descriptivo, en tanto caracteriza la estructura cinemática y los perfiles dinámicos de los ciclos de conducción RDE en los diferentes tramos evaluados; y analítico, al evaluar el comportamiento de las curvas ajustadas y la precisión de las estimaciones no paramétricas bajo intervalos de incertidumbre. Para la ejecución del estudio, el proceso metodológico se estructuró en cuatro etapas secuenciales y lógicas:

Figura 1.

Proceso Metodológico para la construcción del ciclo de conducción RDE



Etapla 1: Recolección, Preprocesamiento e Integración de Datos

Fase 1 (Recolección de datos experimentales): El punto de partida consistió en la captura de datos cinemáticos en tres recorridos bajo un circuito RDE en la ciudad de Riobamba. La información se registró mediante sistemas GPS a una frecuencia de muestreo de 1 Hz (observaciones por segundo), obteniendo registros continuos de tiempo, distancia y velocidad.

Fase 2 (Preprocesamiento y normalización): Debido a las condiciones variables del tráfico, los tres recorridos mostraron duraciones heterogéneas (6325 s, 5995 s y 6186 s para los

viajes 1, 2 y 3, respectivamente). Para garantizar la comparabilidad temporal, se aplicó una interpolación lineal para normalizar los perfiles a una longitud común de $N = 5995$ segundos.

Fase 3 (Integración de datos): Las series temporales normalizadas se consolidaron mediante una estructura de apilamiento (stacking), conformando una base de datos unificada de observaciones (5995×3) para abordar la modelación funcional global.

Etapa 2: Modelación Matemática Funcional y Ajuste B-Spline

Fase 4 (Formulación del modelo funcional): Bajo el enfoque de Análisis de Datos Funcionales (FDA), la velocidad instantánea se definió como una función continua dependiente del tiempo $t \in [0, T]$, representada por el modelo de la ecuación 1:

$$y_i(t) = \mu(t) + \varepsilon_i(t) \quad (1)$$

Donde:

$y_i(t)$ denota la velocidad observada en el segundo t para el recorrido i , $\mu(t)$ representa el patrón o perfil funcional subyacente de velocidad, $\mu(t) = \sum_{j=1}^k \beta_j \beta_j(t)$; y $\varepsilon_i(t)$ es el término de error aleatorio con $E[\varepsilon_i(t)] = 0$

Fase 5 (Ajuste no paramétrico B-spline): Para capturar el dinamismo no lineal sin imponer una forma rígida, se ajustó un Modelo Aditivo Generalizado (GAM) empleando bases B-spline. Mediante el análisis de complejidad se seleccionaron $k = 120$ bases polinómicas, obteniendo la estimación suavizada del perfil $\hat{\mu}(t)$.

Etapa 3: Evaluación y Diagnóstico del Modelo

Fase 6 (Diagnóstico estadístico): El desempeño predictivo y el ajuste del modelo B-spline se evaluaron mediante el análisis de residuos e indicadores estadísticos de error: la Raíz del Error Cuadrático Medio (RMSE), el Error Cuadrático Medio Relativo (RRMSE) y el Error Porcentual Absoluto Medio (MAPE), verificando la ausencia de patrones sistemáticos en los residuos.

Etapa 4: Cuantificación de Incertidumbre y Generación del Ciclo Representativo

Fase 7 (Inferencia mediante Bootstrap por bloques): Dada la autocorrelación interna de las series temporales RDE, la estimación de la incertidumbre se realizó empleando el método de Bootstrap por bloques. Se generaron $B = 5000$ réplicas de remuestreo para construir la distribución empírica y determinar las bandas de confianza al 95% mediante los percentiles 2.5% y 97.5%.

Fase 8 (Ciclo RDE representativo final): Como resultado integrador, se obtuvo el ciclo de conducción RDE representativo de Riobamba junto con su banda de incertidumbre al 95%, ofreciendo un rango estocásticamente plausible de variación para el perfil modelado.

Análisis de Resultados

Serie Temporal Continua de Muestreo Experimental

La figura 2 refleja la serie temporal continua originada en la velocidad instantánea registrada mediante los tres viajes de circuito RDE. La duración total aproximada corresponde a 17.985 segundos. Las líneas discontinuas de forma vertical representan la delimitación de cada viaje, permitiendo visualizar la variación de velocidad en los diferentes contextos de conducción: urbano, rural y autopista.




Figura 2. Serie Continua: Ciclos RDE (viaje 1 + viaje 2 + viaje 3)

De forma general, se aprecia que los tres recorridos reflejan patrones similares, respaldando consistencia en las pruebas realizadas, lo que hace posible el análisis conjunto del comportamiento dinámico del vehículo en cada tramo.

Los tramos urbanos son representados de color rojo, en el predomina las fluctuaciones con mayor frecuencia y velocidades bajas, se identifican descensos con valores que se encuentran cercanos a cero. Esta dinámica es congruente con el comportamiento del tráfico urbano, con semáforos, intersecciones, detenciones y congestión vehicular.

Los tramos rurales se reflejan de color azul, en este tramo se observan ascensos progresivos y variabilidad moderada, se identifican, desaceleraciones relacionadas con las condiciones de tránsito y características geográficas propias de la vía. Los tramos de autopista se representan en color verde, se identifican velocidades más elevadas y mayor nivel de variación que en los tramos anteriores, en este sentido se visualizan picos que superan los 100 km/h alcanzando 150 km/h en el viaje 3.

Los datos en conjunto respaldan las variaciones que se generan en la transición de los tramos urbanos, rurales y autopista que conforman la naturaleza de las pruebas RDE.

Identificar repetición de patrones y continuidad temporal en los tres viajes constituye una base ideal para el ajuste del modelo no paramétrico B-spline. Las oscilaciones abruptas que se identifican en la velocidad, los periodos de detención y cambio de comportamiento en los distintos tramos, respaldan el uso del modelo B-spline puesto que una relación lineal no reflejaría de forma eficiente su evolución.

En este sentido, el modelo B-spline suaviza la trayectoria sin dejar de lado las variaciones relevantes que reflejan el ciclo real y los intervalos de confianza que se obtienen a través de Bootstrap cuantifican la incertidumbre y la estabilidad del ajuste.

Estructura Segmentada de los Recorridos RDE

Al comparar de forma individual los tres viajes de circuito RDE, con la normalización temporal aproximada a una duración común de 5.995 segundos. Cada recorrido fue segmentado en tres fases: 1) urbana, oscila entre 0 y 1.998 segundos; 2) rural, de 1.999 a 3.996 segundos; y 3) autopista, de 3.997 a 5.995 segundos. De esta forma se alinean los recorridos en una escala temporal compartida que hace posible la comparación de los patrones de velocidad, sin que las pequeñas variaciones originales de cada viaje interfieran en la comparación.




Figura 3. Segmentación de los recorridos RDE

Como se observa en la figura 3, los tres recorridos reflejan una estructura operacional similar, en las zonas urbanas (línea roja) existen más detecciones y descensos de velocidad cercanos a cero, en las zonas rurales (línea azul) la velocidad incrementa de forma moderada y

progresiva, las detenciones son menores con algunas oscilaciones por las condiciones de las vías. Y, la autopista (línea verde), refleja velocidades más elevadas y más variaciones.

Los tres recorridos mantienen características que los diferencian entre sí, el primer y segundo viaje reflejan descensos más frecuentes mientras que el tercer viaje refleja incremento de velocidad más sostenido y progresivo. No obstante; la ubicación semejante de los cambios de velocidad efectuados, variaciones puntuales y la conservación del orden de los tramos o fases (urbano, rural y autopista), respalda una estructura comparable.

La normalización a través de interpolación, no elimina las variaciones propias que refleja la conducción real, sino que realiza un ajuste temporal longitudinal que lo hace comparable para un análisis conjunto. Esta fase es esencial para el ajuste del modelo B-spline que se realizará puesto que permite identificar una curva suavizada, valorar la estabilidad de las predicciones e identificar comportamientos recurrentes.

Sin embargo; es importante resaltar que la normalización modifica la escala temporal original, por esta razón las detenciones, desaceleraciones y aceleraciones se consideran patrones relativos en cada una de las fases más no como duraciones equivalentes entre los recorridos.

Análisis Comparativo de Variabilidad Inter-Viaje

La representación de los tres viajes sobre un mismo dominio temporal normalizado, permite identificar diferencias y similitudes presentes en la evolución de la velocidad (Figura 4). Los viajes conservan una estructura general semejante, en el tramo urbano velocidades bajas, en el tramo rural un incremento moderado, y en el tramo de autopista velocidades más altas. Las trayectorias no coinciden completamente, resaltando que aun cuando se recorre un mismo tramo o circuito, la velocidad está condicionada por diferentes factores como la respuesta del conductor, las características de la vía, las detenciones y el flujo vehicular.

En los tramos urbanos predominan las velocidades bajas menos de 50 km/h y las detenciones con velocidades cercanas a cero. No obstante; estas interrupciones no se visualizan exactamente en los mismos instantes en los viajes, por esta razón se relacionan con condiciones cambiantes del tráfico vehicular, semáforos, congestión e intersecciones.

En el tramo rural, la velocidad es ligeramente mayor, las desaceleraciones y oscilaciones varían de un viaje a otro. En el tramo de autopista la dispersión es visiblemente mayor donde se identificaron velocidades más elevadas y mayor diferencia entre los tres viajes, las detenciones y desaceleraciones se presentan en momentos distintos y con diferente intensidad en cada viaje. Los picos alcanzan 160 km/h aproximadamente.

La variabilidad inter viaje identificada respalda que los ciclos RDE, reflejan las condiciones reales de la conducción y no trayectorias repetibles y determinadas. En este sentido, el uso del modelo no paramétrico B-spline es óptimo porque no genera una lógica funcional rígida, estima la tendencia subyacente y complementado con Bootstrap, permite construir una curva a partir de intervalos de confianza para incorporar la variabilidad existente, obteniendo además del análisis de la trayectoria promedio la cuantificación de la incertidumbre originada por las condiciones cambiantes de la conducción en circuitos RDE.




Figura 4. Comparación temporal de ciclos RDE

Ajuste no Paramétrico B-spline

El ajuste no paramétrico B-spline a partir del ciclo general RDE, construido con 17.985 observaciones de tres viajes normalizados y apilados, representa mediante la línea roja refleja la tendencia suavizada de la velocidad instantánea en función del tiempo normalizado, y las líneas de menor intensidad son los registros originales de cada viaje.

En el ajuste se aplicó una base B-spline de $k = 120$, esta flexibilidad hace posible la representación de los cambios locales y relaciones no lineales sin la imposición de una estructura rígida.

La curva estimada logra reproducir cada pico de forma individual. El tramo urbano comprendido entre 0 y 1.998 segundos, refleja velocidades bajas y oscilaciones originadas por aceleraciones, detenciones frecuentes y frenados. El tramo rural comprendido entre 1.999 y 3.996 segundos, refleja velocidades que permanece en niveles moderados con descensos e incrementos progresivos. En autopista aproximadamente en los 4.000 segundos, se determina

incremento de la velocidad sostenido y fluctuaciones más amplias, los niveles más altos se observan en la parte final del recorrido.

Reflejando que el modelo B-spline logra conservar las transiciones originadas de la fase urbana, rural y autopista.

El ajuste B-spline se enfoca en estimar la tendencia central subyacente que comparten los tres viajes y no en reproducir cada pico fluctuación o detención por esta razón la curva roja atenúa el ruido experimental, las perturbaciones de los sensores y variaciones momentáneas del tránsito manteniendo los patrones dinámicos relevantes (Figura 5).

El valor $K=120$ genera una curva flexible capaz de incluir los cambios sin que se centre excesivamente en cada variación u oscilación aleatoria. En el tramo final se identifica una caída pronunciada de la curva ajustada, lo que requiere una interpretación cautelosa, al considerar que el modelo spline reflejan efectos de frontera cuando la información es limitada en el final del dominio temporal. En este sentido, el descenso que se visualiza puede originarse con la sensibilidad matemática del modelo en el último intervalo y la desaceleración real al final del recorrido.

El modelo B-spline ofrece una representación adecuada para el estudio de la tendencia de velocidad y la construcción de intervalos de confianza Bootstrap posterior.




Figura 5. *Ajuste B-spline del ciclo general RDE*

Diagnóstico Estadístico y Residual del Ajuste B-spline

Para respaldar la pertinencia de los datos se realiza el análisis estadístico de los residuos que ha generado el modelo B-spline, considerando factores como la relación con los valores ajustados, el comportamiento temporal, la distribución y aproximación a la normalidad. Se

identifica que los residuos reflejan una media igual a cero $-0,0000$ km/h, respaldando que el modelo no presenta sesgos globales sistemáticos originados por subestimación o sobreestimación. Sin embargo; la desviación estándar con un valor de $16,2172$ km/h, resalta una dispersión importante en la curva ajustada relacionado con variaciones instantáneas que no reproduce completamente el modelo.

En la figura 6 literal 1, el histograma se puede observar que los residuos se concentran mayormente alrededor del cero, conservando la forma acampanada en la parte central, no obstante; se identifican diferencias entre la curva normal y la distribución empírica especialmente en las colas. Esto se confirma (Figura 6 literal 2) en gráfico Q-Q que refleja puntos que se apartan en la línea teórica, en los cuantiles inferiores, la gráfica presenta asimetría y valores externos que sugieren que los datos no cumplen con el supuesto de normalidad.

En la figura 6 literal 3, el gráfico de residuos del tiempo no permite que se sostenga el supuesto de independencia. En las primeras fases la dispersión de los errores es relativamente moderada, sin embargo; en el tramo de autopista la amplitud incrementa y se identifican secuencias de residuos negativos y positivos. El estadístico Kolmogorov-Smirnov con un valor $0,0389$, respalda una autocorrelación positiva y fuerte y no ausencia de dependencia temporal. Estos datos son coherentes con la naturaleza de los datos recolectados puesto que la velocidad que se registra en un segundo depende de forma significativa de los valores anteriores.

La figura 6 literal 4, el gráfico de residuos respecto a los valores ajustados refleja una forma de abanico o triangular, con dispersión que incrementa respectivamente con el aumento de la velocidad estimada. Los datos respaldan la existencia de heterocedasticidad, es decir que los errores no mantienen una varianza constante en los recorridos. La frontera diagonal inferior que se observa, se origina por la restricción física que determina que la velocidad no puede ser negativa, cuando el modelo estima valores de velocidades elevados, los valores negativos pueden presentar una mayor magnitud, pero; en velocidades cercanas a cero es limitado.

De forma general, el modelo B-spline, refleja la tendencia central del ciclo RDE de forma apropiada, no obstante; los supuestos de normalidad, homocedasticidad e independencia no se cumplen completamente por los residuos. Estas apreciaciones no invalidan el ajuste no paramétrico aplicado, pero deben ser considerados para la estimación de la incertidumbre, a fin de obtener intervalos de confianza más realistas y evitar subestimaciones respecto a la variabilidad del ciclo de conducción analizado.




Figura 6. *Residual del ajuste B-spline*

Ciclo General RDE con Bandas de Confianza Bootstrap al 95 %

En la integración de la estimación B-spline del ciclo RDE con bandas de incertidumbre al 95% originadas a partir de 5.000 simulaciones. En la figura 7, se observa la línea gris que representa el promedio empírico de los viajes y la línea roja corresponde a la tendencia suavizada que estima el modelo B-spline.

La proximidad que se observa entre las dos trayectorias respalda que el modelo reproduce de forma eficiente la tendencia central del comportamiento de la velocidad, reduciendo las fluctuaciones abruptas que origina la variabilidad experimental y condiciones momentáneas del tránsito.

En la fase urbana, la curva ajustada refleja niveles bajos, con oscilaciones derivadas de detenciones, frenados y cortos periodos de aceleración. La línea inferior en periodos repetidos alcanza niveles de 0 km/h, originado por la restricción física de evitar velocidades con valores negativos y a las detenciones registradas en el ciclo real. En la fase rural se determina dispersión moderada e incrementos graduales con tendencia relativamente estable. En estas dos fases el modelo se caracteriza en representaciones de velocidades bajas y medias, con variaciones propias de la realidad de conducción como condiciones geométricas de la vía, flujo vehicular e intersecciones.

En la fase de autopista aproximadamente a partir del segundo 4.000 la velocidad incrementa de forma sostenida, lo que ensancha la banda en el gráfico de forma progresiva. La mayor magnitud de la banda resalta que existe mayor incertidumbre en esa fase, esto coincide con la condición de heterocedasticidad que se identificó en el análisis residual. Los datos reflejan

que los comportamientos de los viajes fueron menos homogéneos cuando el vehículo circulaba a mayores velocidades.




Figura 7. *Ciclo RDE - Banda de Confianza Bootstrap al 95%*

Discusión

Los resultados del estudio permitieron identificar que los tres viajes realizados en circuito RDE en la ciudad de Riobamba, mantuvieron una estructura cinemática semejante, constituida por tres fases: urbana, rural y autopista con variaciones de velocidad instantánea. En la fase urbana prevalecen velocidades bajas inferiores a 50 km/h, oscilaciones y detenciones frecuentes. La fase rural estuvo caracterizada por incrementos moderados y la fase de autopista alcanzó las velocidades más elevadas con picos cercanos a 160 km/h. La caracterización del ciclo guarda el comportamiento dinámico en condiciones reales de conducción.

Mediante la superposición de viajes se identificaron coincidencias en la tendencia general de los recorridos, con diferencias claras en las detenciones, desaceleraciones y aceleraciones. Estas variaciones no son el resultado de error experimental, sino el reflejo de la influencia de factores propios de la conducción como: las características de la vía, las intersecciones, el tráfico, el comportamiento del conductor. En este sentido, Edwards (2022), afirma que los ciclos reales de conducción están influenciados por diversos factores como las condiciones ambientales, las condiciones de la ruta, el tráfico, la interacción del conductor, por esta razón un mismo recorrido puede generar perfiles distintos.

Además, Giechaskiel et al. (2024), mediante un estudio comparativo respalda las variaciones en diferentes ensayos de RDE repetidos en una misma ruta originados por los elementos que influyen en el contexto real y que son altamente cambiantes. Por lo expuesto se justifica el uso de un modelo flexible que cuantifique la incertidumbre.

El modelo no paramétrico B-spline con $k=120$, permitió la representación de la tendencia central del ciclo, sin que se imponga una relación lineal entre la velocidad y el tiempo, Mediante la curva ajustada se puede observar la conservación de las transiciones de las tres fases de conducción, suavizando el ruido de los datos originales y los cambios instantáneos, teniendo en cuenta que el objeto no fue la reproducción individual de cada pico sino la reproducción cinemática del comportamiento subyacente compartido en los tres viajes analizados.

En este sentido, Araveeporn (2024), respalda que los modelos B-spline son propicios para representar y analizar series temporales cíclicas y no lineales y que su desempeño depende significativamente del nivel de flexibilidad o número de nodos.

Respecto al análisis cuantitativo el MSE de $38,3412^2$, corresponde a un RMSE de 6,1920 km/h, sugiriendo que la separación de las velocidades en las estimaciones en términos cuadráticos medios equivale a 6,19 km/h. Es un error reducido de forma relativa respecto al rango total del ciclo, no obstante; al encontrar RRMSE de 19,04% y MAPE de 23,46%, resalta una diferencia porcentual estimable sobre todo en tramos donde la aceleración es mayor, donde se dan cambios bruscos y detenciones. Estos resultados no permiten calificar el ajuste como excelente. En este sentido, estudios similares como el de Zhao et al. (2024) y Jing et al. (2022) reflejan errores semejantes. Zhao obtuvo un error promedio en un ciclo real del 13,6% y Jing 5,46%.

El diagnóstico residual permite identificar una media residual equivalente a cero, respaldando ausencia de sesgo global en el modelo, no obstante, estos resultados son interpretados con cautela y no reflejan que el modelo sea insesgado en todas las fases del circuito. Mediante el gráfico Q-Q y el histograma se identificaron desviaciones en las colas y los residuos del tiempo frente a valores ajustados reflejan cambios en la dispersión especialmente en la fase de autopista.

Por su parte el estadístico Kolmogorov–Smirnov con valor 0,0389, sugiere distancia entre la distribución normal y la empírica. Las 5.000 réplicas aplicadas representan la incertidumbre referente a la curva B-spline. Las bandas muestran mayor estabilidad en las fases urbana y rural, presentándose más amplias en la fase de autopista donde existe incremento de velocidad y mayor variabilidad entre los viajes, Keskin et al. (2025), respalda que la inclusión de aleatoriedad y variabilidad es importante en la representación de ciclos de conducción real. Por su parte, Vitale et al. (2024), respaldan que el Bootstrap permite cuantificar la incertidumbre de forma realista.

Conclusiones

Los viajes analizados mediante circuito RDE en la ciudad de Riobamba, reflejaron una estructura cinemática semejante constituido por tramos urbano, rural y autopista, con características propias influenciadas por aceleraciones, desaceleraciones, velocidades máximas y detenciones, generando dispersiones que respaldan la representación de condiciones reales de conducción, circulación, comportamiento del conductor, tráfico y demás factores que hacen que se originen perfiles distintos en los recorridos.

El modelo no paramétrico B-spline con el uso de $k=120$, refleja de forma adecuada la tendencia general de velocidad en los ciclos analizados, con MSE de $38,3412 (km / h)^2$ y RMSE de $6,1920 km/h$. Se observa diferencias en los cambios bruscos de velocidad al identificar valores RMSE de $19,04\%$ y el MAPE de $23,46\%$, estos resultados sugieren que el modelo es más eficiente para representar tendencia central frente a la representación individual de variaciones instantáneas. Las 5.000 réplicas hicieron posible la cuantificación de la incertidumbre del ajuste, resaltando mayor amplitud de la banda en las fases de mayor velocidad especialmente en el tramo de autopista.

Referencias Bibliográficas

- Araveeporn, A. (2024). The Estimating Parameter and Number of Knots for Nonparametric Regression Methods in Modelling Time Series Data. *Modelling 2024*, Vol. 5, Pages 1413-1434, 5(4), 1413–1434. <https://doi.org/10.3390/MODELLING5040073>
- Cai, L., & Wang Soujin. (2023). *Oracle - efficient global inference for variance funtion in nonparametric regression with missing covariates*. <https://www3.stat.sinica.edu.tw/statistica/j33n1/j33n113/j33n113.html>
- Castillo, J., Cordero, D., Fernández, E., Solórzano, B. A., & Jaramillo, P. R. (2024). Definición de un Ciclo Típico de Conducción de un taxi eléctrico en una ciudad Andina. *Revista Facultad de Ingeniería Universidad de Antioquia*, (114), 63–70. <https://doi.org/10.17533/UDEA.REDIN.20240728>
- Dabčević, Z., Škugor, B., Topić, J., & Deur, J. (2022). Synthesis of Driving Cycles Based on Low-Sampling-Rate Vehicle-Tracking Data and Markov Chain Methodology. *Energies* , 15(11), 4108. <https://doi.org/10.3390/EN15114108>
- Edwards, A. J. (2022). Aggressive-dynamics metrics for drive-cycle characterization. *Transportation Research Interdisciplinary Perspectives*, 14, 100592. <https://doi.org/10.1016/J.TRIP.2022.100592>
- Giechaskiel, B., Valverde, V., Melas, A., Clairotte, M., Bonnel, P., & Dilara, P. (2024). Comparison of the Real-Driving Emissions (RDE) of a Gasoline Direct Injection (GDI) Vehicle at Different Routes in Europe. *Energies 2024*, Vol. 17, Page 1308, 17(6), 1308. <https://doi.org/10.3390/EN17061308>
- Govindarajan, N., Vervliet, N., & De Lathauwer, L. (2022). Regression and Classification With Spline-Based Separable Expansions. *Frontiers in Big Data*, 5, 688502. <https://doi.org/10.3389/FDATA.2022.688496/TEXT>
- Huang, R., Ni, J., Shi, X., Wang, Q., & Cheng, Z. (2023). Assessing and Characterizing the Effect of Altitude on Fuel Economy, Particle Number and Gaseous Emissions Performance of Gasoline Vehicles under Real Driving. *SAE Technical Papers*, 81, 1–19. <https://doi.org/10.4271/2023-01-0381>
- Jiang, Z., Wu, L., Niu, H., Jia, Z., Qi, Z., Liu, Y., Zhang, Q., Wang, T., Peng, J., & Mao, H. (2024). Investigating the impact of high-altitude on vehicle carbon emissions: A comprehensive on-road driving study. *Science of The Total Environment*, 918, 170671. <https://doi.org/10.1016/J.SCITOTENV.2024.170671>
- Jing, Z., Wang, T., Zhang, S., & Wang, G. (2022). Development Method for the Driving Cycle of Electric Vehicles. *Energies* , 15(22), 8715. <https://doi.org/10.3390/EN15228715>
- Keskin, F., Yıldız, M., & Arslannur, B. (2025). A Data-Driven Framework for Driving Cycle Generation and Analysis. *Transportation Research Record*, 2679(1), 2199–2212. <https://doi.org/10.1177/03611981241260700;ISSUE:ISSUE:DOI>
- Kim, H., Luan, Y., Zoh, R. S., Wu, G., & Tekwe, C. D. (2023). Parametric and Semiparametric Approaches to Analyzing Device-Based Measures of Energy Expenditure in Zucker
-

- Diabetic Fatty Rats. *Frontiers in Bioscience* , 28(2), 48. <https://doi.org/10.31083/J.FBL2802030>
- Kusalaphirom, T., Satiennam, T., Satiennam, W., & Seedam, A. (2022). Development of a Real-World Eco-Driving Cycle for Motorcycles. *Sustainability* , 14(10), 6192. <https://doi.org/10.3390/SU14106176>
- Luján, J. M., Piqueras, P., De la Morena, J., & Redondo, F. (2022). Experimental Characterization of Real Driving Cycles in a Light-Duty Diesel Engine under Different Dynamic Conditions. *Applied Sciences* , 12(5), 2472. <https://doi.org/10.3390/APP12052472>
- Poliak, M., Kubiak, P., Krukowski, M., Turoboś, F., Jaśkiewicz, M., Jaśkiewicz, J., & Frej, D. (2025). Non-Linear Method of Vehicle Velocity Determination Based on Tensor Product B-Spline Approximation with Probabilistic Weights for NHTSA Database of Compact Vehicle Class. *Applied Sciences* , 16(1), 1–14. <https://doi.org/10.3390/APP16010401>
- Rivera, N., Molina, J., Idrovo, D., & Narváez, J. (2024). Influence Analysis of Driving Style on the Energy Consumption of an Electric Vehicle Through PID Signals Study. *Communications in Computer and Information Science*, 2049 CCIS, 194–205. https://doi.org/10.1007/978-3-031-58956-0_15/SAVE-RESEARCH
- Selk, L., & Gertheiss, J. (2022). Nonparametric regression and classification with functional, categorical, and mixed covariates. *Advances in Data Analysis and Classification* , 17(2), 519–543. <https://doi.org/10.1007/S11634-022-00513-7>
- Sennefelder, R. M., Micek, P., Clemente, R. M., Carrion Risquez, J., Carvajal, R., & Carrillo Castrillo, J. A. (2022). Driving Cycle Synthesis, Aiming for Realness, by Extending Real-World Driving Databases. *IEEE Access*, 10, 54123–54135. <https://doi.org/10.1109/ACCESS.2022.3175492>
- Toalombo, B., Meneses, A., Zúñiga, L., & Espín, R. (2022). Modelos de regresión paramétricos polinomiales y no paramétricos B-splines. Una aplicación en ingeniería . *Perfiles*, 1(28), 72–82. <https://doi.org/10.47187/PERF.V1I28.185>
- Vitale, D., Fratini, G., Helfter, C., Hortnagl, L., Kohonen, K. M., Mammarella, I., Nemitz, E., Nicolini, G., Rebmann, C., Sabbatini, S., & Papale, D. (2024). A pre-whitening with block-bootstrap cross-correlation procedure for temporal alignment of data sampled by eddy covariance systems. *Environmental and Ecological Statistics* , 31(2), 219–244. <https://doi.org/10.1007/S10651-024-00615-9>
- Wu, Y., Huang, Z., Zheng, Y., Liu, Y., Li, H., Che, Y., Peng, J., & Teodorescu, R. (2023). Spatial–temporal data-driven full driving cycle prediction for optimal energy management of battery/supercapacitor electric vehicles. *Energy Conversion and Management*, 277, 116628. <https://doi.org/10.1016/J.ENCONMAN.2022.116619>
- Xin, Y., & Gao, J. (2024). Orthogonal series method for uncertain nonparametric regression with application to carbon dioxide emissions. *Communications in Statistics - Simulation and Computation*, 53(10), 5018–5027. <https://doi.org/10.1080/03610918.2023.2169711>
- Zhang, T., Peng, R., Zhou, Z., Luo, W. M., & Bai, S. (2026). A Small-Sample Reliability Estimation Method Based on Bootstrap Resampling With B-Spline Empirical Distribution and K-Medoids Clustering. *Quality and Reliability Engineering International*, 10(48), 1–18.
-

<https://doi.org/10.1002/QRE.70283>;REQUESTEDJOURNAL:JOURNAL:10991638;WGROUP:STRING:PUBLICATION

- Zhao, Z., Sun, X., Wang, X., Wang, Y., Fu, J., & Liu, J. (2024). Construction and optimization of representative actual driving cycles based on the improved autoencoder. *Scientific Reports*, 14(1), 2351-. <https://doi.org/10.1038/s41598-024-52865-z>
- Zúñiga, J. D., & Meneses Freire, M. A. (2024). Bootstrap para calcular intervalos de predicción mediante modelos no paramétricos de regresión funcional de radiación solar. *Polo Del Conocimiento*, 9(8), 3726–3740. <https://doi.org/10.23857/pc.v9i8.7909>
- Zúñiga, J. D., Zúñiga, J. D., Zúñiga, L. del C., Ruiz, S. B., & Mejía, E. F. (2024). Predicción de series temporales de humedad relativa mediante bootstrap y modelos de regresión funcional no paramétrica. *Polo Del Conocimiento*, 9(10), 133–146. <https://doi.org/10.23857/pc.v9i10.8109>
-