



AUTOMATIZACIÓN DEL ANÁLISIS DE ESPECTROS DE CARGA CON MACHINE LEARNING A TRAVÉS DE UNA API Y SU APLICACIÓN EN UN CASO PRACTICO

Fernando Trejo¹, Roberto Hernández², Carlos Chávez³

¹ Universidad Michoacana de San Nicolás Hidalgo, Morelia, México, 2023174g@umich.mx

² Ceviter, Querétaro, México, roberto.hernandez@ceviter.com.mx

³ Universidad Michoacana de San Nicolás Hidalgo, Morelia, México, cachavez@umich.mx

Resumen

El tránsito es uno de los principales factores de deterioro en los pavimentos. Tradicionalmente, los ejes equivalentes han sido utilizados para estimar el daño, pero estos tienen la limitación de que solo consideran pesos vacíos y máximos, sin reflejar la variabilidad real de las cargas ni el porcentaje de sobrecarga. Para un análisis más detallado, los espectros de carga permiten capturar datos reales de pesos para distintas configuraciones de ejes, aunque su manejo en hojas de cálculo resulta complejo y propenso a errores.

El objetivo de este estudio es mostrar el desarrollo de una API en Python con Machine Learning (ML) que automatiza el análisis de espectros de carga, mostrando además su aplicación en un caso práctico, el cual sirve para mostrar su potencial para la optimización del proceso de evaluación del tránsito vehicular y su impacto en la vida útil del pavimento. La herramienta está diseñada para procesar grandes volúmenes de datos de estaciones de pesaje dinámico, detectando patrones de carga, identificando valores atípicos. Su alcance permite transformar un proceso que en hojas de cálculo podría tomar horas, en una tarea que se resuelve en segundos. La API genera automáticamente una carpeta con un archivo de Excel que contiene el espectro de carga con cálculos detallados, incluyendo el ajuste log-normal con sus tres medias, tres desviaciones estándar, tres pesos, diferencias al cuadrado y coeficiente de correlación. Además del Factor de Espectro de Carga (LSF) y la gráfica del espectro. Esta API permite la planificación del mantenimiento vial y la optimización de recursos.

Palabras Clave: Espectros de carga, Machine Learning, API, Impacto ambiental

1 Introducción

El tránsito vehicular, especialmente el transporte de carga pesada, es uno de los principales factores responsables del deterioro acelerado de los pavimentos. Cuando las cargas reales que circulan por una vialidad son subestimadas, el diseño estructural o la planeación del mantenimiento pueden resultar inadecuados, lo que provoca fallas prematuras, mayores costos de conservación y un incremento significativo del impacto ambiental asociado a reparaciones frecuentes, emisiones y consumo energético.

Para estimar el daño que produce el tránsito, tradicionalmente se han utilizado los ejes equivalentes como simplificación del problema. Sin embargo, este enfoque no considera la variabilidad real de las cargas, ni refleja de forma precisa el comportamiento del tránsito en condiciones de sobrecarga, lo cual es especialmente crítico en países como México.

En este contexto, el análisis de espectros de carga vehicular representa una herramienta más precisa y representativa para evaluar la agresividad del tránsito pesado. No obstante, su aplicación práctica es limitada debido a la complejidad del procesamiento manual y a la falta de herramientas accesibles para su análisis.



Este artículo presenta el desarrollo de una API en Python que automatiza el análisis de espectros de carga mediante técnicas de Machine Learning, y demuestra su aplicación en un caso práctico utilizando datos reales de estaciones de pesaje dinámico. La propuesta busca facilitar el diagnóstico del tránsito, mejorar la estimación del daño inducido por los vehículos pesados, y apoyar decisiones más sostenibles en el diseño, mantenimiento y rehabilitación de pavimentos.

2 Metodología y aplicación práctica

La API desarrollada automatiza el análisis de espectros de carga vehicular a partir de archivos .xlsx o .csv generados por estaciones de pesaje dinámico. Este proceso, que normalmente implicaría horas de trabajo manual, se ejecuta en segundos e integra múltiples etapas, desde la limpieza y organización de los datos hasta su clasificación, segmentación y visualización gráfica. Para ilustrar su funcionamiento, cada fase metodológica se explica en conjunto con su aplicación práctica, basada en datos del año 2011 provenientes de la estación Zacatal, perteneciente al programa EECAN disponibles en la plataforma del Instituto Mexicano del Transporte (IMT) [1]. A continuación, se detallan los pasos seguidos en el proceso.

2.1 Carga y limpieza de datos

El primer paso en el análisis automatizado consiste en la carga del archivo original y la depuración de los datos crudos provenientes de estaciones de pesaje dinámico. Esta fase es fundamental para garantizar que los resultados posteriores sean estadísticamente válidos y técnicamente confiables.

La API realiza este proceso de forma automática, eliminando columnas irrelevantes como identificadores administrativos o metadatos, registros con valores nulos, negativos o igual a cero, y valores atípicos extremos en el rango superior. Estas acciones permiten reducir el volumen de información sin perder datos representativos, preservando la calidad del ajuste estadístico.

En la aplicación práctica se utilizaron registros del año 2011 de la estación Zacatal. El archivo original contenía 30,287 filas y 42 columnas, lo que representaba más de 1.2 millones de datos, tal como se ve en la Figura 1. Sin embargo, una parte considerable de esta información no era útil para el análisis de espectros.

Después de aplicar el proceso de limpieza, el conjunto de datos quedó reducido a 7,849 filas y 11 columnas útiles, lo que representa un total de 86,328 datos válidos para el análisis técnico.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA	AB	AC
	REGISTRO	DIASEM	SENTIDO	HORA	PLACA	TIPO	VEHICULO	POBORI	MUNORI	ENTORI	VEPOBOR	POBOES	MUNDOES	ENTDOES	VEPODOES	EMARCA	MARCA	MODELO	UBUSTISAJER	PULAVEMO	MOTIVCLAVE	CARGA	RGATEX	CANTIDAD	CVEUNI	UNIDAD			
2	1	2	1	0	VP66K7	7	CAMION DI Villahermi	Centro	Tabas	27 004 00	Acayucan	Acayucan	Verac	30 003 00	W102	CAMION F	1999	DIESEL	0	2		7424	PAPEL Y PAPELES	100	P			PARES	
3	2	2	1	0	SP	8	CAMION DI Villahermi	Centro	Tabas	27 004 00	México	México	Dist	09 015 00	W115	CAMION F	2004	DIESEL	0	2									
4	3	2	1	0	U		VEHICULO	Coatzaco	Coatzaco	Verac	30 039 00	Oluta	Oluta	Verac	30 116 00	U203	PICK UP R	1990	GASOLIN	0	2								
5	4	2	1	0	A		AUTOMOV	Coatzaco	Coatzaco	Verac	30 039 00	Acayucan	Acayucan	Verac	30 003 00	W211	AUTOMOV	2010	GASOLIN	2	0	T	Trabajo						
6	5	2	1	0	XX396	7	CAMION DI Cosoleaca	Cosoleaca	Verac	30 048 00	Acayucan	Acayucan	Verac	30 003 00	W110	CAMION F	2005	DIESEL	0	1		7465	ROPA P.ROPA	0	G			GRANEL	
7	6	2	1	0	XP9539	7	CAMION DI Coatzaco	Coatzaco	Verac	30 039 00	Acayucan	Acayucan	Verac	30 003 00	W102	CAMION F	2011	GASOLIN	0	2		5019	OTRAS / POLLO	144	PZ			PIEZAS	
8	7	2	1	0	688DG7	8	CAMION DI Palenque	Palenque	Chiap	07 065 00	México	México	Dist	09 015 00	W112														
9	8	2	1	0	793AH5	11	TRACTOR E Chinamec	Chinamec	Verac	30 059 00	Playa Vice	Playa Vice	Verac	30 130 00	W105	CAMION E	1971	DIESEL	0	1		7351	MAIZ H.MASEAC	11	T			TONELAD.	
10	9	2	1	0	X059AC	12	TRACTOR E Chinamec	Chinamec	Verac	30 059 00	Playa Vice	Playa Vice	Verac	30 130 00	W105	CAMION E	1971	DIESEL	0	1									
11	10	2	1	0	428DX7	18	TRACTOR E Jáltipan	d Jáltipan	Verac	30 089 00	Acayucan	Acayucan	Verac	30 003 00	W112	CAMION I	2008	DIESEL	0	1		7239	ENVASE ENVASE	10000	PZ			PIEZAS	
12	11	2	1	0	384DX2	11	TRACTOR E Villahermi	Centro	Tabas	27 004 00	Córdoba	Córdoba	Verac	30 044 00	W121	CAMION F	1993	DIESEL	0	1		7500	TUBERU/TUBERIA	150	PZ			PIEZAS	
13	12	2	1	0	A		AUTOMOV	Jáltipan	d Jáltipan	Verac	30 089 00	Acayucan	Acayucan	Verac	30 003 00	C105	AUTOMOV	2012	GASOLIN	1	0	P	Paseo						
14	13	2	1	0	KC1211	7	CAMION DI Villahermi	Centro	Tabas	27 004 00	Tehuacan	Tehuacan	Puebl	21 156 00	W105	CAMION F	1983	DIESEL	0	3									
15	14	2	1	0	626DT2	11	TRACTOR E Coatzaco	Coatzaco	Verac	30 039 00	Tampico	Tampico	Tamau	28 038 00	W110	CAMION F	2006	DIESEL	0	2									
16	15	2	1	0	XH7499	11	TRACTOR E Villahermi	Centro	Tabas	27 004 00	Heroica P.	Puebla	Puebl	21 114 00	W112	CAMION I	1999	DIESEL	0	1		7001	ABARR/CABARR	10	T			TONELAD.	
17	16	2	1	0	714DL1	18	TRACTOR E Minatitlán	Minatitlán	Verac	30 108 00	Córdoba	Córdoba	Verac	30 044 00	W115	CAMION F	2008	DIESEL	0	1									
18	17	2	1	0	873DD0	18	TRACTOR E Villahermi	Centro	Tabas	27 004 00	Heroica P.	Puebla	Puebl	21 114 00	W121	CAMION F	1996	DIESEL	0	1									
19	18	2	1	0	897AL7	18	TRACTOR E Tuxtla Gut	Tuxtla Gut	Chiap	07 101 00	Orizaba	Orizaba	Verac	30 118 00	W121	CAMION F	1998	DIESEL	0	2									
20	19	2	1	0	B2		AUTOBUS	Coatzaco	Coatzaco	Verac	30 039 00	Xalapa-En Xalapa	Verac	30 087 00	A115	AUTOBUS	2005	DIESEL	10	2									
21	20	2	1	0	A		AUTOMOV	Jáltipan	d Jáltipan	Verac	30 089 00	Juchitán	d Juchitán	Oaxac	20 043 00	G974	AUTOMOV	1995	GASOLIN	1	0	P	Paseo						
22	21	2	1	0	A		AUTOMOV	Jáltipan	d Jáltipan	Verac	30 089 00	San Andrés	San Andrés	Verac	30 141 00	C105	AUTOMOV	1986	GASOLIN	1	0	T	Trabajo						
23	22	2	1	0	245AN6	7	CAMION DI Cancún	Benito Juárez	Quint	23 005 00	México	México	Dist	09 015 00	W105	CAMION I	1992	DIESEL	0	1		7503	TUBERU/TUBERIA	40	PZ			PIEZAS	
24	23	2	1	0	243DK5	7	CAMION DI Villahermi	Centro	Tabas	27 004 00	Heroica P.	Puebla	Puebl	21 114 00	W105	CAMION E	1982	DIESEL	0	1		5022	HUEVO/HUEVO	0	G			GRANEL	
25	24	2	1	0	KF9164	7	CAMION DI Tuxtla Gut	Tuxtla Gut	Chiap	07 101 00	Oluta	Oluta	Verac	30 015 00	W133	CAMION H	2004	DIESEL	0	1		5019	OTRAS / POLLOS	500	C			CABEZAS	
26	25	2	1	0	537AJA	15	TRACTOR E Cosoleaca	Cosoleaca	Verac	30 048 00	Reynosa	Reynosa	Tamau	28 032 00	W113	CAMION H	2001	DIESEL	0	1									
27	26	2	1	0	B2		AUTOBUS	Villahermi	Centro	Tabas	27 004 00	San Pedro	San Pedro	Oaxac	20 324 00	A115	AUTOBUS	2004	DIESEL	17	1								
28	27	2	1	0	816EE4	11	TRACTOR E Villahermi	Centro	Tabas	27 004 00	Apizaco	Apizaco	Tlaxc	29 005 00	W123	CAMION I	2000	DIESEL	0	1									
29	28	2	1	0	A		AUTOMOV	Minatitlán	Minatitlán	Verac	30 108 00	San Andrés	San Andrés	Verac	30 141 00	G313	AUTOMOV	2005	GASOLIN	3	0	T	Trabajo						
30	29	2	1	0	470EE3	11	TRACTOR E Villahermi	Centro	Tabas	27 004 00	México	México	Dist	09 015 00	W113	CAMION H	1999	DIESEL	0	2		5068	PLATAN PLATANI	1200	PZ			PIEZAS	
31	30	2	1	0	A		AUTOMOV	Oteapan	Oteapan	Verac	30 120 00	Acayucan	Acayucan	Verac	30 003 00	C401	AUTOMOV	2006	GASOLIN	2	0	T	Trabajo						
32	31	2	1	0	D9508	7	CAMION DI Coatzaco	Coatzaco	Verac	30 039 00	Veracruz	Veracruz	Verac	30 193 00	W106														
33	32	2	1	0	081AJ3	9	TRACTOR E Cancún	Benito Juárez	Quint	23 005 00	Toluca	Toluca	Méxic	15 106 00	W121	CAMION F	2003	DIESEL	0	1		7391	MOTOC/MOTOS	40	PZ			PIEZAS	

Figura 1. Vista parcial del archivo original de pesaje dinámico correspondiente a la estación Zacatal (2011), antes del proceso de limpieza de datos.



2.2 Clasificación vehicular por tipo

Una vez depurado el conjunto de datos, fue necesario identificar la configuración vehicular de cada registro, es decir, asignar a cada fila una clase que represente el tipo de vehículo observado. Esta información no se encuentra estructurada en los datos originales del programa EECAN, por lo que fue indispensable realizar una clasificación manual adecuada que sirviera como base para el entrenamiento del modelo de aprendizaje supervisado.

Para garantizar un modelo robusto, es fundamental contar con un conjunto de datos etiquetado correctamente, amplio y representativo del parque vehicular nacional. En este trabajo, se realizó una depuración minuciosa de los registros utilizando parámetros clave como el número de ejes, el peso bruto vehicular (PBV) y patrones comunes en las descripciones textuales. Por ejemplo, expresiones genéricas como "tractor de 2 ejes con semirremolque de 2 ejes remolque" o "tractor de 3 ejes con semirremolque de 2 ejes remolque" fueron transformadas a clasificaciones técnicas estandarizadas como T2-S2-R2 y T3-S2-R4.

En muchos casos, la información venía incompleta o mal etiquetada, por lo que se recurrió a un análisis combinado entre los pesos por eje y el total del vehículo para realizar la asignación correcta. Para facilitar este proceso, se desarrolló un programa en Python que permitió visualizar los registros, analizar valores atípicos, y reasignar etiquetas de forma ágil y validada. Este conjunto, clasificado de manera manual, fue utilizado para entrenar un modelo basado en el algoritmo Random Forest, con variables como el número total de ejes, los pesos individuales y el PBV.

Esta etapa fue crucial, ya que tanto la calidad como la cantidad del conjunto de entrenamiento tienen un impacto directo en el desempeño del modelo. Como lo señala Domingos (2012), "los mejores resultados se obtienen al combinar grandes volúmenes de datos de alta calidad con un modelo bien elegido" [2].

Random Forest es un algoritmo de clasificación por ensamble que construye múltiples árboles de decisión utilizando subconjuntos aleatorios de los datos y de las variables disponibles. Cada árbol emite una predicción y el modelo final toma la decisión más votada, lo cual le permite ser robusto ante el sobreajuste (overfitting) y manejar eficientemente conjuntos de datos ruidosos o con valores atípicos [3].

Una vez entrenado, el modelo fue aplicado a los datos de la estación Zacatal para realizar la clasificación vehicular automática, tal como se ve en la Figura 2, lo que permitió continuar con la identificación estructural de cada eje.

	A	B	C	D	E	F	G	H	I	J	K
1	VEHICULO	PBV	Eje 1	Eje 2	Eje 3	Eje 4	Eje 5	Eje 6	Eje 7	Eje 8	Eje 9
2	C2	7662	3425	4237	0	0	0	0	0	0	0
3	C2	7145	2898	4247	0	0	0	0	0	0	0
4	C2	6765	1783	4982	0	0	0	0	0	0	0
5	C2	5866	2147	3719	0	0	0	0	0	0	0
6	C2	7612	2847	4765	0	0	0	0	0	0	0
7	C2	11286	3285	8001	0	0	0	0	0	0	0
8	C2	6992	2724	4268	0	0	0	0	0	0	0
9	C2	5692	1910	3782	0	0	0	0	0	0	0
10	C2	12270	4537	7733	0	0	0	0	0	0	0
11	C2	19543	10827	8716	0	0	0	0	0	0	0
12	C2	5793	2019	3774	0	0	0	0	0	0	0
13	C2	6872	2808	4064	0	0	0	0	0	0	0
14	C2	9334	3602	5732	0	0	0	0	0	0	0
15	C2	10139	4336	5803	0	0	0	0	0	0	0
16	C2	9176	3084	6092	0	0	0	0	0	0	0
17	C2	11472	3959	7513	0	0	0	0	0	0	0
18	C2	6743	1850	4893	0	0	0	0	0	0	0
19	C2	6252	3088	3164	0	0	0	0	0	0	0
20	C2	5443	1736	3707	0	0	0	0	0	0	0
21	C2	6218	2426	3792	0	0	0	0	0	0	0
22	C2	13830	5218	8612	0	0	0	0	0	0	0

Figura 2. Archivo limpio con clasificación vehicular y distribución de carga por eje individual

2.3 Identificación del tipo de eje

Con la clase vehicular ya estimada para cada registro, la API infiere automáticamente la configuración de ejes de cada vehículo y clasifica individualmente cada uno como sencillo, dual, tandem o tridem. Esta clasificación estructural es indispensable para construir espectros de carga diferenciados y evaluar el impacto específico de cada tipo de eje sobre el pavimento.

El proceso se realiza de forma automatizada tras la clasificación vehicular, y permite organizar los resultados de manera jerárquica. Los archivos generados se almacenan dentro de una carpeta principal denominada espectros de carga de acuerdo con la Figura 3, que contiene subcarpetas individuales para cada tipo de eje. En cada una de ellas se encuentra un archivo Excel con el análisis completo, además de la gráfica del espectro de carga, la curva de ajuste log-normal multimodal, un gráfico de dispersión con la clasificación de cargas según el algoritmo KMeans, una gráfica de pastel que muestra la proporción de cargas baja, media y alta; y una imagen resumen con los estadísticos clave por grupo (mínimo, máximo, media, desviación estándar y número de registros).

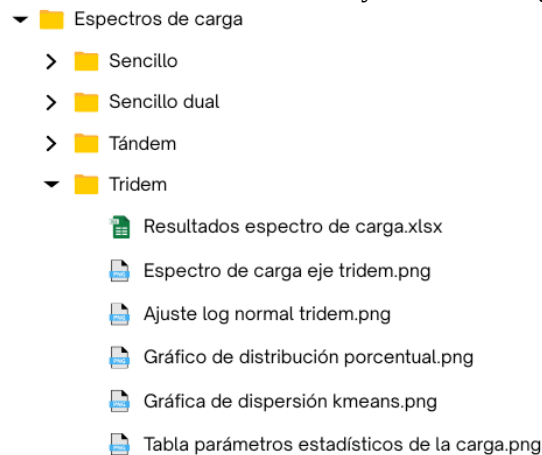


Figura 3. Archivos generados para el análisis de espectros de carga

2.4 Segmentación en cargas baja, media y alta

Una vez completada la limpieza de datos y la clasificación vehicular, se procede al análisis del comportamiento general de las cargas por eje mediante el algoritmo de aprendizaje no supervisado K-Means. Este algoritmo es ampliamente utilizado para tareas de agrupamiento (clustering), y su función principal es dividir un conjunto de datos en k grupos de elementos con características similares, minimizando la variabilidad interna de cada grupo y maximizando la diferencia entre ellos [4].

En el contexto del análisis de espectros de carga, K-Means permite clasificar automáticamente las cargas de cada tipo de eje (sencillo, dual, tandem o tridem) en tres categorías representativas:

- Carga baja
- Carga media
- Carga alta

La variable utilizada para el agrupamiento es el valor numérico de la carga por eje, y el número de clústeres se define como $k = 3$, lo cual se justifica por su utilidad práctica en el análisis estructural de pavimentos, ya que permite distinguir entre cargas típicamente operativas, cargas promedio y aquellas que representan condiciones de sobrecarga.



El algoritmo funciona de manera iterativa: asigna inicialmente cada punto a un clúster, calcula los centroides (medias de cada grupo), y reagrupa los puntos con base en la distancia euclidiana mínima respecto a dichos centroides. Este proceso se repite hasta que no se detectan cambios significativos en la asignación de grupos. Como ventaja, el algoritmo no requiere etiquetas previas ni suposiciones sobre la distribución de los datos, lo que lo hace especialmente útil en contextos de alta variabilidad, como el tránsito de carga pesada. El resultado de esta segmentación se presenta en tres productos visuales y estadísticos:

- Un gráfico de dispersión, donde cada punto representa una carga clasificada por color según su categoría, tal como se muestra en la Figura 4.
- Una tabla resumen estadística, con la media, desviación estándar, valor mínimo, máximo y número de registros por grupo, según lo representado en la Tabla 1.
- Un gráfico de pastel que muestra la proporción porcentual de cada categoría de carga respecto al total, de acuerdo a la Figura 5.

Esta segmentación facilita la comprensión visual de la severidad de las cargas vehiculares y permite identificar claramente las zonas de mayor riesgo estructural dentro del espectro analizado.

En el caso de Zacatal (2011), se muestra el análisis del eje tridem tras su identificación. El algoritmo clasificó automáticamente las cargas en los tres grupos mencionados. Esta información aporta un diagnóstico inmediato de la distribución real de cargas en operación y revela la proporción de ejes que operan en condiciones críticas o sobredimensionadas.




Figura 4. Clasificación de cargas del eje tridem en categorías baja, media y alta

Tabla 1. Distribución porcentual de las categorías de carga para el eje tridem

Categoría de carga	count	min	max	mean	std
Carga baja	381	5.981	17.347	10.787	1.952
Carga media	198	17.817	27.942	24.209	2.869
Carga alta	128	28.070	40.842	31.702	2.832




Figura 5. Distribución porcentual de las categorías de carga para el eje tridem.

2.5 Generación de la hoja de cálculo

El archivo Excel generado está organizado en hojas temáticas que permiten un análisis técnico claro y eficiente de los resultados. A continuación, se describe el contenido de este archivo:

- Hoja 1 – Espectro de carga, contiene la información completa del espectro para el tipo de eje analizado. Se incluye:
 - El peso bruto del eje junto con el vehículo del cual proviene
 - Los límites de clase
 - Frecuencia absoluta
 - Frecuencia normalizada
 - Distribución ajustada con función log-normal
 - Diferencias entre datos reales y ajustados
- Hoja 2 – Parámetros del ajuste log-normal multimodal. Se listan las tres medias, tres desviaciones estándar y tres pesos que definen el modelo estadístico ajustado a los datos, además del error cuadrático medio y coeficiente de correlación del ajuste, de acuerdo a la Tabla 2.

Tabla 2. Parámetros del ajuste log-normal multimodal para el eje tridem.

c) Parámetro	Valor
Media 1	3.139
Desviación estándar 1	0.347
Peso 1	0.253
Media 2	2.325
Desviación estándar 2	0.139
Peso 2	0.493
Media 3	3.322
Desviación estándar 3	0.118
Peso 3	0.254
Diferencias al cuadrado	0.00148
Coeficiente de correlación	0.988



- c) Hoja 3 – Métricas globales, como se representa en la Tabla 3. Resume los indicadores clave del espectro, incluyendo:

- El Factor del Espectro de Carga (LSF)
- ESALs (Ejes Equivalentes)
- Número total de ejes

Tabla 3. Indicadores globales del espectro de carga para el eje tridem

Propiedad	Valor
LSF	1.089
ESALs	771
Número total de ejes	707

- d) Hoja 4 – Ejes legales (menores o iguales al límite permitido). Presenta los ejes clasificados como legales de acuerdo con la carga máxima permitida definida por el usuario.

- e) Hoja 5 – Ejes ilegales (mayores al límite permitido). Muestra únicamente aquellos ejes que exceden la carga máxima normativa, identificados como ilegales.

- f) Hoja 6 – Estadísticos del grupo legal, tal como se muestra en la Tabla 4. Incluye métricas descriptivas del subconjunto de cargas legales:

- LSF del grupo
- Número de ejes
- Media, desviación estándar
- Valores mínimos, máximos
- Cuartiles (P25, P50, P75)

Tabla 4. Parámetros estadísticos de los ejes legales

Parámetro	Valor
LSF	0.084
count	439
mean	12.05
std	3.76
min	5.981
25%	9.601
50%	10.805
75%	12.625
max	22.954

- g) Hoja 7 – Estadísticos del grupo ilegal, como se observa en la Tabla 5. Presenta los mismos parámetros estadísticos que la hoja anterior, pero para el subconjunto de cargas clasificadas como ilegales.

Tabla 5. Parámetros estadísticos de los ejes ilegales

Parámetro	Valor
LSF	1.005
count	268
mean	28.6173396
std	3.6883202
min	23.068
25%	25.755
50%	27.859
75%	31.3005
max	40.842

2.6 Visualización gráfica de resultados

Como parte del análisis automatizado, la API genera una serie de gráficos que permiten visualizar de manera clara el comportamiento de las cargas vehiculares.

La gráfica del espectro de carga, que muestra la frecuencia de los pesos por eje agrupados en intervalos. Esta figura permite identificar concentraciones de tránsito en ciertos rangos de carga y evaluar su distribución general. Un ejemplo se muestra en la Figura 6, correspondiente al eje tridem.

La gráfica de ajuste log-normal multimodal, donde se superpone el modelo estadístico ajustado sobre los datos reales normalizados. Esta visualización facilita la validación visual del modelo propuesto y la identificación de los modos principales dentro del espectro. La Figura 7 presenta el ajuste correspondiente al eje tridem.




Figura 6. Espectro de carga para el eje tridem




Figura 7. Ajuste log-normal multimodal del espectro de carga para el eje tridem

Las gráficas y resultados presentados anteriormente corresponden únicamente al eje tridem y se muestran con fines ilustrativos. Sin embargo, la API genera el mismo conjunto de análisis: archivos Excel, espectros, ajustes log-normales, clasificaciones por carga y gráficas para cada tipo de eje: sencillo, sencillo dual, tándem y tridem, de forma automatizada y ordenada. Esta capacidad permite obtener una visión estructurada y completa del comportamiento de las cargas vehiculares, eje por eje, facilitando tanto el análisis técnico como su integración en reportes y sistemas de apoyo a decisiones en infraestructura vial.

Este caso evidencia la eficiencia y aplicabilidad de la API en bases de datos reales como las del EECAN, logrando procesar y organizar toda la información en setenta segundos, para la estación del ejemplo, aunque esto puede variar según la cantidad de datos que contenga. Al integrarse en una plataforma web, el tiempo puede aumentar ligeramente, sin comprometer su funcionalidad.

3 Conclusiones

La API desarrollada automatiza exitosamente el análisis de espectros de carga vehicular, procesando grandes volúmenes de datos. Esto representa una mejora significativa frente a los métodos manuales en hojas de cálculo, los cuales pueden tardar varias horas y son altamente propensos a errores humanos. En el caso de la estación Zacatal tardó setenta segundos.

El uso de técnicas de Machine Learning, como Random Forest para la clasificación vehicular y KMeans para la segmentación de cargas, permite una caracterización más precisa del comportamiento del tránsito pesado, capturando su variabilidad y complejidad de forma estadísticamente robusta.

El caso práctico con datos reales de la estación Zacatal (2011) demuestra la eficacia de la herramienta al manejar y limpiar un archivo originalmente compuesto por 30,287 filas y 42 columnas (más de 1.2 millones de datos), reduciéndolo a 7,849 filas útiles y organizadas para su análisis técnico. La API genera salidas técnicas completas y estructuradas automáticamente, incluyendo:

- Espectros por tipo de eje (sencillo, dual, tándem, tridem),
- Parámetros estadísticos del ajuste log-normal (medias, desviaciones estándar y pesos),
- Segmentación por severidad de carga (baja, media, alta),
- Clasificación legal/ilegal según el umbral normativo,
- Gráficos exportables (dispersión, pastel, espectros, ajustes log-normales),



- Archivos Excel con resultados detallados y organizados por hojas.

La estructura de carpetas generada facilita la interpretación visual y técnica de los resultados, lo que permite a los usuarios acceder rápidamente a los análisis por eje, integrar las gráficas en reportes, y tomar decisiones de diseño o mantenimiento con mayor información y menor incertidumbre.

La herramienta representa una solución eficiente y escalable frente al análisis tradicional, donde un operador manual podría tardar horas o incluso días en completar una evaluación comparable, con un mayor riesgo de inconsistencias o errores de cálculo.

El sistema ofrece un soporte riguroso para la evaluación de tecnologías de pavimentación innovadoras, como las mezclas recicladas, al brindar un análisis realista del comportamiento de carga, superando las limitaciones de los métodos simplificados basados solo en ejes equivalentes.

Su implementación en plataformas técnicas de análisis vial puede optimizar la planificación de mantenimiento, reducir costos, aumentar la vida útil de las estructuras y apoyar estrategias de infraestructura más sostenibles y ambientalmente responsables.

4 Referencias

- [1] Instituto Mexicano del Transporte (2023). Consulta del EECAN. <https://www.imt.mx/micrositios/seguridad-y-operacion-del-transporte/estadisticas/consulta-del-eeacan.html>.
- [2] Domingos, P. (2012). A Few Useful Things to Know About Machine Learning. Communications of the ACM.
- [3] Breiman, L. (2001). Random Forests. Machine Learning.
- [4] MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability. University of California Press.