



UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE CUENCA
CARRERA DE INGENIERÍA AUTOMOTRIZ

**ESTIMACIÓN DE FACTORES DE EMISIÓN EN VEHÍCULOS HÍBRIDOS MEDIANTE EL
USO DE APRENDIZAJE AUTOMÁTICO EN LA CIUDAD DE CUENCA**

Trabajo de titulación previo a la obtención del
título de Ingeniero Automotriz

AUTORES: JACKSON STEEVEN VIDAL SUÁREZ

WALTER JOSUÉ SEMIGLIA PINEDA

TUTOR: ING. NÉSTOR DIEGO RIVERA CAMPOVERDE, MSc.

Cuenca - Ecuador

2024

CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Nosotros, Jackson Steeven Vidal Suárez con documento de identificación N° 0705344422 y Walter Josué Semiglia Pineda con documento de identificación N° 0705077972 manifestamos que:

Somos los autores y responsables del presente trabajo; y, autorizamos a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Cuenca, 29 de enero del 2024

Atentamente,



Jackson Steeven Vidal Suárez

0705344422



Walter Josué Semiglia Pineda

0705077972

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Nosotros, Jackson Steeven Vidal Suárez con documento de identificación N° 0705344422 y Walter Josué Semiglia Pineda con documento de identificación N° 0705077972, expresamos nuestra voluntad y por medio del presente documento cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del Proyecto técnico: “Estimación de factores de emisión en vehículos híbridos mediante el uso de aprendizaje automático en la ciudad de Cuenca”, el cual ha sido desarrollado para optar por el título de: Ingeniero Automotriz, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribimos este documento en el momento que hacemos la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Cuenca, 29 de enero del 2024

Atentamente,



Jackson Steeven Vidal Suárez

0705344422



Walter Josué Semiglia Pineda

0705077972

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Néstor Diego Rivera Campoverde con documento de identificación N° 0103898995, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: ESTIMACIÓN DE FACTORES DE EMISIÓN EN VEHÍCULOS HÍBRIDOS MEDIANTE EL USO DE APRENDIZAJE AUTOMÁTICO EN LA CIUDAD DE CUENCA, realizado por Jackson Steeven Vidal Suárez con documento de identificación N° 0705344422 y por Walter Josué Semiglia Pineda con documento de identificación N° 0705077972, obteniendo como resultado final el trabajo de titulación bajo la opción Proyecto técnico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Cuenca, 29 de enero del 2024

Atentamente,



Ing. Néstor Diego Rivera Campoverde, MSc.

0103898995

DEDICATORIA

Con profundo aprecio, dedico este proyecto de investigación a mis padres, Wilmer Vidal y Melva Suarez, quienes son los dos pilares esenciales en mi existencia. Su constante esfuerzo, dedicación y sabios consejos han sido mi guía inquebrantable, infundiéndome la fortaleza necesaria para alcanzar cada una de mis metas. En los intrincados senderos de la vida, su presencia ha sido mi razón para perseverar, cosechando así los frutos de mi arduo esfuerzo.

A mis respetados tíos, José Vidal y Luz Luna, les expreso mi gratitud por extender siempre sus manos en momentos adversos, brindándome la oportunidad de revelar mi verdadero carácter. Su enseñanza sobre la valentía y el coraje, alentándome a superar el temor a tropezar y equivocarme, ha dejado una huella imborrable en mi ser.

A Joaquín, quien asumió el papel de abuelo sin compartir la misma sangre, volviéndose un ser querido más en mi círculo familiar; le dedico un especial reconocimiento. Su constante preocupación por la integridad de mis padres y la mía en momentos

críticos de la vida ha sido una manifestación palpable de su compromiso, cumpliendo así con mi promesa de la infancia.

En última instancia, mi agradecimiento se extiende a toda mi familia y amigos que, en diversos momentos, han brindado su apoyo desde múltiples perspectivas, contribuyendo de manera significativa a mantener mi enfoque educativo y alcanzar la culminación exitosa de mi carrera.

Jackson Steeven Vidal Suarez

DEDICATORIA

Este proyecto técnico es producto de un arduo trabajo y dedicación, impulsado por el compromiso con la excelencia. Quiero dedicar este proyecto a mis padres: Walter Antonio Semiglia y Ketty María Pineda. Por su amor y apoyo incondicional, siendo pilar fundamental durante toda mi vida y más aún durante estos 4 años en mi etapa universitaria. Quienes creyeron en mí y en mis capacidades para lograr cada objetivo que me proponga.

Con la misma importancia quiero dedicar este proyecto a mi hermano Pablo, por acompañarme durante todo este tiempo y apoyarme cuando lo he necesitado.

También, a toda mi familia por siempre tenerme presente y estar pendientes de mí a pesar de la distancia, y en cada momento oportuno darme ánimos, un buen consejo o unas palabras llenas de sabiduría y cariño.

Walter Josué Semiglia Pineda

AGRADECIMIENTO

En primer lugar, agradecerle a Dios por permitirme adquirir conocimientos y experiencias suficientes a lo largo de mi etapa universitaria, sirviendo de beneficio para mi proyecto de titulación

Agradezco a mis padres por respaldarme constantemente en mis decisiones, nunca abandonarme y ofrecerme el apoyo incondicional que han brindado a lo largo de toda mi vida.

A mis compañeros y amigos con los que camine durante estos cuatro arduos años, quienes con su apoyo constante lograron agilizar el proceso y permitir disfrutarlo.

De la misma manera, mi sincero agradecimiento al Ing. Néstor Rivera, nuestro tutor, por depositar su confianza, amistad, conocimiento y tiempo necesario, a fin de culminar el proyecto de manera exitosa.

Jackson Steeven Vidal Suarez

AGRADECIMIENTO

Quisiera agradecer en primer lugar a Dios por darme la vida, fortaleza y sabiduría para afrontar todos los obstáculos que se presentaron a lo largo de esta etapa universitaria.

A mis padres por haberme dejado la mejor herencia que se puede dejar a un hijo como lo es la educación.

Que ahora se está haciendo realidad lo que en algún momento fue un anhelo el cursar y culminar una carrera universitaria. A mi familia en general por ayudarme en los momentos difíciles y estar pendientes de mi bienestar en todo momento

También quiero expresar mi más sincero agradecimiento a nuestro tutor Ing. Nestor Rivera por su invaluable asesoría y disposición durante todo el proceso de desarrollo de mi tesis. Su dedicación, conocimientos y apoyo incondicional fueron fundamentales para llevar a cabo cada etapa de este proyecto con éxito.

Walter Josué Semiglia Pineda

RESUMEN

Este proyecto técnico presenta un método para la estimación de factores de emisión en vehículos híbridos mediante el uso de aprendizaje automático en la ciudad de Cuenca, haciendo uso de tres tipos de vehículos (Sedan, Crossover y SUV). La finalidad de este proyecto se basa en dar a conocer el uso de técnicas de aprendizaje automático como herramienta asertiva para estimar las emisiones de gases contaminantes emitidas por estos vehículos durante pruebas en conducción real. El desarrollo del proyecto se divide en tres etapas con el fin de lograr los resultados deseados.

La primera etapa se enfoca en llevar a cabo una revisión e investigación bibliográfica exhaustiva como punto de partida para el proyecto, con el objetivo de adquirir conocimiento sobre las definiciones que abarcan los factores de emisión y la estimación de gases contaminantes en vehículos híbridos, con la finalidad de obtener resultados de alta confiabilidad.

En la segunda etapa se realiza la adquisición de datos necesarios para el estudio. Para la adquisición de datos se hace uso de un dispositivo llamado OBDlink Mx que se conecta al puerto DLC del vehículo para obtener los parámetros de funcionamiento del vehículo en tiempo real, también se hace uso de un analizador de gases portátil conectado al tubo de escape de los vehículos y a su vez conectado a una computadora para la recolección de los valores de gases contaminantes emitidos por los vehículos. Para esta etapa se realizan pruebas de conducción en tiempo real para cada tipo de vehículo seleccionado para el estudio.

La tercera etapa procede a analizar los datos adquiridos y resultados obtenidos por medio de técnicas estadísticas y destrezas ligadas al uso de aprendizaje automático con el fin de generar bases para futuras tomas de decisiones por parte de la sociedad.

Palabras Claves: *Aprendizaje automático, estimación, factores de emisión, vehículos híbridos.*

ABSTRACT

This technical project presents an estimation of emission factors in hybrid vehicles through the use of machine learning in the city of Cuenca, employing three types of vehicles (Sedan, Crossover, and SUV). The purpose of this project is to highlight the use of machine learning techniques as an assertive tool for estimating emissions of pollutant gases emitted by these vehicles during real driving tests. The project's development is divided into three stages to achieve the desired results.

The first stage focuses on conducting a thorough literature review and research as a starting point for the project, aiming to acquire knowledge about the definitions that encompass emission factors and the estimation of pollutant gases in hybrid vehicles, ultimately seeking highly reliable results.

In the second stage, the necessary data for the study is acquired. The OBDlink Mx device is used to connect to the vehicle's DLC port, obtaining real-time operating parameters of the vehicle. Additionally, a portable gas analyzer is connected to the vehicles' exhaust pipe and, in turn, connected to a computer for collecting values of pollutant gases emitted by the vehicles. Real-time driving tests are conducted for each type of vehicle selected for the study during this stage.

Finally, in the third stage, the acquired data and results from the project are analyzed using statistical techniques and skills associated with the use of machine learning. The goal is to provide a basis for future decision-making by society.

Keywords: *Machine learning, estimation, emission factors, hybrid vehicles.*

ÍNDICE GENERAL

INTRODUCCIÓN	1
PROBLEMA	2
Antecedentes	3
Importancia y alcances	5
Delimitación	5
OBJETIVOS	7
Objetivo general	7
Objetivos Específicos	7
CAPÍTULO I: MARCO TEÓRICO REFERENCIAL Y ESTADO DEL ARTE	8
Marco teórico referencial	8
Aprendizaje automático	8
Señales PID's	8
Emisiones de gases contaminantes	9
Monóxido de carbono - CO	10
Dióxido de Carbono - CO₂	10
Óxidos de nitrógeno - NO_x	11
Hydrocarburos – HC	11
Factor de emisión	12

Métodos directos para calcular factores de emisión	12
Métodos indirectos para calcular factores de emisión	13
Prueba en ciclos reales de conducción (RDE)	14
Vehículos híbridos	15
Euro 6 – RDE	19
Kane live	21
OBDlink Mx	22
Estado del arte	23
CAPITULO II: METODOLOGÍA UTILIZADA PARA LA OBTENCIÓN DE DATOS EN VEHÍCULOS HÍBRIDOS	33
Factores de inferencia durante la obtención de datos	33
VARIABLES DE RUIDO	34
VARIABLES DE BLOQUEO	35
VARIABLES DE ENTRADA	35
VARIABLES DE SALIDA	36
Planificación de rutas para la obtención de parámetros de funcionamiento	37
Ruta RDE del vehículo Tipo Sedán	38
Ruta RDE del vehículo Tipo Crossover	39
Ruta RDE del vehículo Tipo SUV	40

Proceso experimental	41
Vehículos asignados a prueba	41
Protocolo de adquisición de datos.....	45
Matrices y vectores de estudio.....	47
Filtración de variables.	49
Método de ajuste de mínimos cuadrados de Savitzky-Golay	50
Pendientes de los vehículos durante rutas RDE	51
Determinación de las aceleraciones de cada vehículo en rutas RDE.....	52
Determinación de factores de emisión de cada vehículo en rutas RDE.	103
Correlación de variables	53
 CAPITULO III: PROCESAMIENTO DE SEÑALES, ENTRENAMIENTO DE RED	
NEURONAL Y ANÁLISIS DE ESTIMACIONES DE LOS FACTORES DE EMISIÓN... 60	
Inclusión de vector de velocidad y aceleración.	61
Asignación de variables en redes neuronales artificiales (RNA).	63
Estrategias estadísticas en incremento de coeficientes de determinación	67
Variable clasificatoria de entrada para el tipo de vehículo.	69
Entrenamientos de las redes neuronales artificiales (RNA)	70
Histogramas de errores en procesos de entrenamiento, validación y testeó.	75
Comportamientos de los MSE durante las épocas de entrenamiento.	81

Gradientes del periodo de entrenamiento de las distintas RNA.	84
Coefficientes de determinación (R) en cada red neuronal.	87
Resultados de estimación para el consumo de combustible y gases contaminantes.	93
Factores de emisión estimados	103
Conclusiones	108
Recomendaciones	111
Bibliografía	112
Anexos	114

ÍNDICE DE FIGURAS

Figura 1	Delimitación geográfica del proyecto	6
Figura 2	Configuración en serie.....	16
Figura 3	Configuración en paralelo	17
Figura 4	Configuración mixta o serie-paralelo	18
Figura 5	Configuración compleja	19
Figura 6	Software Kane live	22
Figura 7	OBDlink Mx.....	23
Figura 8	Factores de inferencia.....	¡Error! Marcador no definido.
Figura 9	Ruta del vehículo Toyota Corolla (Sedán)	38
Figura 10	Ruta del vehículo Toyota CHR (Crossover).....	39
Figura 11	Ruta del vehículo Toyota Corolla CROSS (SUV).....	40
Figura 12	Vehículo Corolla Sedán	41
Figura 13	Vehículo Toyota CH-R	43
Figura 14	Toyota Corolla Cross.....	44
Figura 15	Dispositivos vinculados en la adquisición de datos	46
Figura 16	Flujograma de adquisición de datos	47
Figura 17	Comparación de variable no filtrada vs filtrada	50
Figura 18	Pendientes calculadas vehículo tipo Sedán	51
Figura 19	Aceleración vehículo tipo SUV	53
Figura 20	Matriz de correlación - Consumo.....	55
Figura 21	Matriz de correlación - CO, CO2	57

Figura 22	Matriz de correlación - HC, NOx.....	58
Figura 23	Comparación del vector "VSS" de cada tipo de vehículo	62
Figura 24	Comparación de RPM real vs normalizada.....	68
Figura 25	Arquitectura - Estructura de la primera RNA (Consumo).....	71
Figura 26	Arquitectura - Estructura de la segunda RNA (CO).....	72
Figura 27	Arquitectura - Estructura de la tercera RNA (CO2)	72
Figura 28	Arquitectura - Estructura de la cuarta RNA (HC)	73
Figura 29	Arquitectura - Estructura de la quinta RNA (NOx).....	73
Figura 30	Histograma de errores - RNA (Consumo).....	76
Figura 31	Histograma de errores - RNA (CO).....	77
Figura 32	Histograma de errores - RNA (CO2).....	78
Figura 33	Histograma de errores - RNA (HC).....	79
Figura 34	Histograma de errores - RNA (NOx)	80
Figura 35	Comportamiento del error cuadrático medio - RNA (Consumo).....	81
Figura 36	Comportamiento del error cuadrático medio - RNA (CO).....	82
Figura 37	Comportamiento del error cuadrático medio - RNA (CO2).....	82
Figura 38	Comportamiento del error cuadrático medio - RNA (HC).....	83
Figura 39	Comportamiento del error cuadrático medio - RNA (NOx).....	84
Figura 40	Gradiente de entrenamiento RNA - Consumo.....	85
Figura 41	Gradiente de entrenamiento RNA - CO	85
Figura 42	Gradiente de entrenamiento RNA - CO2	86
Figura 43	Gradiente de entrenamiento RNA - HC	86

Figura 44	Gradiente de entrenamiento RNA - NO _x	86
Figura 45	Coefficientes de determinación implicados en RNA (Consumo).....	87
Figura 46	Coefficientes de determinación implicados en RNA (CO).....	88
Figura 47	Coefficientes de determinación implicados en RNA (CO ₂).....	89
Figura 48	Coefficientes de determinación implicados en RNA (HC).....	90
Figura 49	Coefficientes de determinación implicados en RNA (NO _x)	91
Figura 50	Comparación del consumo real vs estimado mediante VSS	93
Figura 51	Gráfico por puntos del consumo real vs estimado	94
Figura 52	Comparación del consumo real vs estimado mediante VSS	95
Figura 53	Gráfico por puntos del CO real vs estimado	96
Figura 54	Comparación del CO ₂ real vs estimado mediante VSS	97
Figura 55	Gráfico por puntos del CO ₂ real vs estimado	98
Figura 56	Comparación del HC real vs estimado mediante VSS	99
Figura 57	Gráfico por puntos del HC real vs estimado	100
Figura 58	Comparación del NO _x real vs estimado mediante VSS.....	101
Figura 59	Gráfico por puntos del NO _x real vs estimado	102
Figura 60	Proceso de adquisición de datos.....	114
Figura 61	Instrumentación del vehículo	115

ÍNDICE DE TABLAS

Tabla 1	Variables de ruido.....	34
Tabla 2	Variables de bloqueo	35
Tabla 3	Variables de entrada.....	36
Tabla 4	Variables de salida.....	36
Tabla 5	Especificaciones del ciclo de pruebas RDE.....	37
Tabla 6	Especificaciones mecánicas y eléctricas del Toyota Corolla tipo Sedán	42
Tabla 7	Especificaciones mecánicas y eléctricas del Toyota CH-R.....	43
Tabla 8	Especificaciones mecánicas y eléctricas del Toyota Corolla Cross	44
Tabla 9	Variables de relevancia para el proyecto	48
Tabla 10	Factores de emisión total - Vehículo tipo Sedán	104
Tabla 11	Factores de emisión total - Vehículo tipo Crossover	105
Tabla 12	Factores de emisión total - Vehículo tipo SUV	105
Tabla 13	Factores de emisión por secciones RDE - Vehículo tipo Sedán.....	106
Tabla 14	Factores de emisión por secciones RDE - Vehículo tipo Crossover	106
Tabla 15	Factores de emisión por secciones RDE - Vehículo tipo SUV.....	107
Tabla 16	Variables influyentes en el consumo de combustible.....	55
Tabla 17	Variables más influyentes en CO y CO2	57
Tabla 18	Variables más influyentes en HC y NOx.....	59
Tabla 19	Variables involucradas en el primer entrenamiento de RNA	64
Tabla 20	Variables involucradas en el segundo entrenamiento de RNA.....	64
Tabla 21	Variables involucradas en el tercer entrenamiento de RNA.....	65

Tabla 22	Variables involucradas en el cuarto entrenamiento de RNA.....	66
Tabla 23	Variables involucradas en el quinto entrenamiento de RNA.....	66
Tabla 24	Proporción de datos para las etapas de procesamiento en las RNA.....	70
Tabla 25	Especificaciones de entrenamiento en las redes neuronales.	74
Tabla 26	Factores de emisión estimados	107

INTRODUCCIÓN

La transición hacia una movilidad más sostenible ha llevado al surgimiento de vehículos híbridos como una alternativa prometedora en el panorama automotriz especialmente para países en vías de desarrollo. Estos vehículos, que combinan motores de combustión interna con sistemas de propulsión eléctrica, presentan un potencial significativo para reducir las emisiones de gases contaminantes y así mejorar la eficiencia del consumo de combustible. Sin embargo, la evaluación precisa de los factores de emisión asociados a estos vehículos híbridos se ha convertido en un desafío esencial para comprender el verdadero impacto ambiental de los mismos.

El presente proyecto se centra en la estimación de factores de emisión en vehículos híbridos mediante el uso de técnicas de aprendizaje automático. A medida que la complejidad de la interacción entre los motores de combustión y los sistemas eléctricos aumenta, la aplicación de enfoques convencionales de medición y modelado se vuelve limitada. En cambio, la adopción de métodos de aprendizaje automático ofrece una perspectiva innovadora y precisa para abordar esta problemática. El estudio explora las aplicaciones específicas de técnicas de aprendizaje automático, como redes neuronales, en la estimación de factores de emisión de los vehículos híbridos. A través de la recopilación y análisis de datos (parámetros de funcionamiento, porcentajes de gases de escape), se busca proporcionar una comprensión más profunda de los patrones de emisión en diferentes modos de operación de este tipo de vehículos, contribuyendo así a la optimización de su rendimiento ambiental.

Los resultados del estudio no solo contribuirán al crecimiento del conocimiento científico en este campo, sino que también tendrán implicaciones significativas en la promoción de tecnologías de vehículos más limpias y sostenibles.

PROBLEMA

El campo automotriz desde la perspectiva tecnológica, se ha mantenido en constante desarrollo desde sus inicios, tanto así que en las últimas dos décadas se vienen implementando nuevos prototipos que requieren de energía eléctrica y reducen considerablemente el uso de fuentes no renovables. La eficiencia y los índices de gases contaminantes son ramas automotrices en las que los vehículos con nuevas tecnologías (híbridos y eléctricos) ejercen una clara ventaja sobre los de combustión; independientemente de su fuente de combustible. (Huang et al., 2019)

Mediante diferentes revistas científicas de alto prestigio a lo largo de los últimos años se ha notado una relevante fusión del aprendizaje automático en el ámbito de los automóviles. La convergencia entre la tecnología de aprendizaje automático y la industria de los vehículos ha producido avances notorios que tienen un efecto directo en la eficacia operativa y medioambiental de los automóviles. Un ejemplo es el proyecto denominado “A deep neural network based model for the prediction of hybrid electric vehicles carbon dioxide emissions” con el objetivo de hacer uso del aprendizaje automático para estimar un índice contaminante del vehículo híbrido. (Maino et al., 2021)

En la ciudad de Cuenca, provincia del Azuay durante el último año se ha presenciado un considerable crecimiento de vehículos eléctricos e híbridos para la sociedad bajo un mercado individualista. Sin embargo, las organizaciones del sector público y privado se rigen bajo tendencias y se encuentran incorporando flotas únicamente de la línea eléctrica para la comunidad de usuarios, debido a la falta de conocimiento e información acerca de los puntos positivos y negativos tanto de los prototipos de la línea eléctrica como de la línea híbrida.

Se conoce que ninguna ciudad del Ecuador se encuentra cien por ciento apta para una implementación eficaz de vehículos eléctricos de manera masiva refiriéndose a las condiciones de

infraestructura (Buenaño et al., 2023). Los vehículos híbridos no cuentan con esa limitación y en términos energéticos estos poseen mejores características referentes a las necesidades de corporaciones públicas. Por lo tanto, se vuelve necesario el estudio desde la perspectiva medioambiental relacionada con los gases contaminantes.

Antecedentes

El desarrollo del proyecto tiene como propósito analizar los porcentajes de factores de emisión de los vehículos híbridos en la ciudad de Cuenca, otorgando conocimientos a diversos grupos de la sociedad acerca de las ventajas y desventajas de inducir o incrementar flotas de esta nueva tecnología en órganos públicos y privados; teniendo presente de manera circunstancial el enfoque socio-ambiental.

El plan de estudio generará información patentada con bases y fundamentos a la comunidad dedicada a investigaciones académicas y científicas en las líneas de eficiencia energética - contaminación ambiental, transporte - movilidad. Además, se evaluará el comportamiento de las emisiones de gases contaminantes provenientes de vehículos híbridos dentro de la ciudad de Cuenca, mediante el uso de arquitecturas de aprendizaje automático previamente entrenadas en base a las variables y parámetros más significativos que otorguen los ensayos durante diferentes ciclos reales de conducción.

En relación al objetivo 12 del plan de creación de oportunidades del Ecuador (Secretaría Nacional de Planificación, 2021), el proyecto en cuestión se encuentra asociado a una de las metas fijadas para el año 2025, específicamente identificada como la meta 12.3.3. Esta meta tiene como propósito principal incrementar el ahorro de combustibles fósiles a través de mejoras en la eficiencia energética. De esta manera, se establece una conexión directa con la idea de aumentar

la presencia de vehículos que incorporan nuevas tecnologías en el parque automotor de la ciudad de Cuenca.

La razón del proyecto está relacionada con los objetivos de desarrollo sostenible 11, “Ciudades y comunidades sostenibles”; 13, “Acción por el clima” (ONU, 2023), porque induce estrategias para fomentar y promover el desarrollo de una ciudad centrada en la movilidad sostenible, mediante el proyecto de investigación: “Caracterización de modelos de movilidad sostenible mediante la aplicación de arquitecturas de Machine Learning a las señales PID’s obtenidas a través de OBD II para el estudio de las emisiones contaminantes sobre la ciudad de Cuenca”; tomando el presente proyecto a desarrollar como un enfoque con solución hacia los inconvenientes entre el crecimiento poblacional y la crisis ambiental. A pesar de la incorporación de la electrificación en la mecánica de los vehículos híbridos, el margen de emisiones sigue siendo considerable. Esto se debe a que, condicionalmente, estos vehículos continúan utilizando un motor de combustión interna a lo largo del tren propulsor. La razón se debe a que los automóviles híbridos cuentan con dos o más mecanismos para almacenar energía, los cuales desempeñan la función de suministrar potencia al sistema de propulsión, ya sea de manera conjunta o independiente. (Gregorio & Sancan, 2017)

La evaluación de la eficiencia y los niveles de emisión de gases contaminantes constituye un componente fundamental en el ámbito automotriz. En este contexto, los vehículos que incorporan tecnologías innovadoras, tales como la hibridación y electrificación, exhiben una marcada superioridad respecto a los vehículos de combustión interna, independientemente de su fuente de combustible. La relevancia de estos aspectos ha motivado la generación de artículos académicos y científicos que buscan demostrar y compartir conocimientos y experimentos relacionados con los vehículos híbridos.

Adicionalmente, diversos estudios relacionados con la hibridación de vehículos se enmarcan en el ámbito de la eficiencia energética. Estos estudios destacan las ventajas de la hibridación al proporcionar una distribución más efectiva de par y potencia en comparación con los vehículos convencionales. Esta línea de investigación no solo busca avanzar en la comprensión de los aspectos técnicos de los vehículos híbridos, sino también mejorar la eficiencia general de la movilidad vehicular con miras a mitigar los impactos ambientales asociados a la movilidad convencional.

Importancia y alcances

En la actualidad, se observa una inclinación hacia la incorporación de nuevas tecnologías en vehículos destinados a flotas de servicio público y privado. Este fenómeno se orienta hacia la obtención de beneficios asociados con las líneas de "electrificación e hibridación". El propósito del análisis de los factores de emisión en vehículos híbridos es proporcionar conocimientos sustanciales a las autoridades locales, fabricantes de vehículos y la comunidad en general. Este enfoque busca facilitar futuras tomas de decisiones, especialmente desde la perspectiva medioambiental, en relación con las crecientes emisiones contaminantes.

Desde un punto de vista adicional se pretende enfatizar la conexión esencial entre la inteligencia artificial (IA) y la tecnología informática en las diversas disciplinas vinculadas a la industria automotriz. El propósito fundamental radica en fomentar y facilitar investigaciones que conduzcan a estudios capaces de generar beneficios significativos para la sociedad.


Delimitación

Este proyecto se llevará a cabo en la ciudad de Cuenca, ubicada en la provincia de Azuay, al sur de Ecuador. Esta localidad se encuentra a una altitud de 2500 metros sobre el nivel del mar, abarca

una superficie de 70.59 kilómetros cuadrados y tiene una población estimada de aproximadamente 810.000 habitantes.

Figura 1

Delimitación geográfica del proyecto



Nota: Adaptado de Google Maps. Fuente: (Google Maps, 2023)

OBJETIVOS

Objetivo general

Estimar los factores de emisión de vehículos híbridos mediante el uso de aprendizaje automático para analizar su impacto en la ciudad de Cuenca.

Objetivos Específicos

- Revisar el estado del arte de las emisiones contaminantes generadas por el campo automotriz y las destrezas del aprendizaje automático a través de indagaciones bibliográficas.
- Diseñar y ejecutar el plan experimental para la recolección de datos que incluye variables, parámetros y señales PID's mediante la conducción por rutas RDE y aleatorias en la ciudad de Cuenca y bajo el uso de equipos automotrices portátiles.
- Analizar los datos adquiridos y resultados obtenidos por medio de técnicas estadísticas y destrezas ligadas al uso de aprendizaje automático con el fin de generar bases para futuras tomas de decisiones por parte de la sociedad.

CAPÍTULO I: MARCO TEÓRICO REFERENCIAL Y ESTADO DEL ARTE

Marco teórico referencial

Aprendizaje automático

El aprendizaje automático, también conocido como machine learning en inglés, constituye una vertiente de la inteligencia artificial que se dedica a la creación de algoritmos y modelos capaces de posibilitar que los sistemas adquieran conocimientos y tomen decisiones fundamentadas en datos, prescindiendo de la necesidad de una programación explícita para cada escenario particular. En lugar de ello, el sistema es sometido a un proceso de entrenamiento mediante datos pertinentes, los cuales utiliza para discernir patrones y llevar a cabo predicciones o tomar decisiones. (Farahzadi & Kioumars, 2023)

Señales PID's

Las señales PID (Parámetros de Identificación de Datos) constituyen representaciones físicas o eléctricas de información, abarcando diversos tipos de señales que encuentran aplicación en una amplia gama de contextos. Estas señales desempeñan un papel crucial en los modos de funcionamiento del OBD (On-Board Diagnostics), donde cada modo se designa para cumplir funciones específicas. (Molina Campoverde, 2020)

Las señales PID, que se refieren a los Parámetros de Identificación de Datos, son representaciones físicas o eléctricas de información con aplicaciones variadas en diversos contextos. Estas señales juegan un papel crucial en los modos de funcionamiento del sistema de Diagnóstico a Bordo (OBD), donde cada modo está diseñado con funciones específicas.

Específicamente, el Modo 1 del OBD se concentra en la obtención de datos en tiempo real, proporcionando información sobre valores analógicos o digitales de las salidas y entradas conectadas a la Unidad de Control del Motor (ECU). Conocido también como "flujo de datos",

este modo facilita una comprensión dinámica de la operación del vehículo y permite la supervisión en tiempo real de parámetros clave.

Es esencial resaltar que la información suministrada por las señales PID, especialmente en el contexto del Modo 1, no solo ofrece una instantánea de la funcionalidad del vehículo, sino que también se utiliza para diagnósticos en tiempo real. Esto contribuye a detectar de manera temprana posibles problemas o irregularidades en el sistema del vehículo. Este enfoque proactivo resulta fundamental para llevar a cabo un mantenimiento preventivo y optimizar el rendimiento del vehículo. (Rivera et al., 2022)

Emisiones de gases contaminantes

La emisión de sustancias contaminantes está estrechamente ligada al proceso de combustión de combustibles fósiles, tales como el carbón y los derivados del petróleo, utilizados en la generación de energía. Durante esta fase, se libera una cantidad significativa de dióxido de carbono (CO₂), el cual constituye uno de los principales gases responsables del fenómeno del efecto invernadero.

Estos gases, al ser liberados a la atmósfera, contribuyen al incremento de la temperatura global del planeta. La principal fuente de emisiones de dióxido de carbono proviene de la quema de carbón, petróleo y gas en instalaciones como centrales eléctricas, vehículos automotores y complejos industriales (Oceana, 2020).

En el caso específico de las emisiones contaminantes generadas por los vehículos, estas resultan de diversos procesos, siendo uno de los más frecuentes la combustión de combustible y la liberación a través del sistema de escape. Entre los contaminantes más perjudiciales se encuentran el monóxido de carbono (CO), los óxidos de nitrógeno (NO_x), los hidrocarburos (HC), los óxidos de azufre (SO_x), los compuestos orgánicos volátiles (COV) y las partículas en suspensión (PM). Además, se emiten gases de efecto invernadero como el dióxido de carbono (CO₂), el cual, aunque

no afecta directamente la salud humana, tiene un impacto significativo en el cambio climático. (Velepucha-Sánchez & Sabando-Piguabe, 2021)

En el conjunto de emisiones contaminantes emitidas por vehículos de arquitecturas híbridas se destacan las siguientes:

Monóxido de carbono - CO

El monóxido de carbono (CO) constituye un gas incoloro e insípido generado por la combustión incompleta en motores de combustión interna, señalando su presencia cuando no se dispone de oxígeno suficiente para la completa oxidación del hidrocarburo (combustible). Factores determinantes en la emisión de CO abarcan la proporción aire-combustible, la temperatura de la combustión y la eficiencia del motor del vehículo.

Este gas acarrea efectos adversos para la salud humana, manifestándose mediante síntomas como cefalea, vértigo, náuseas e incluso, en situaciones extremas, la mortalidad. En términos de su repercusión ambiental, el CO contribuye de manera indirecta al cambio climático al influir en la concentración de otros gases, como el metano.

Dióxido de Carbono - CO₂

el dióxido de carbono (CO₂) se manifiesta como un gas sin color ni olor, siendo mayormente liberado durante procesos de combustión, como la quema de gasolina o diésel en vehículos. Diversos factores, como la eficiencia de los motores de combustión interna, la calidad del combustible y las características dimensionales y de peso de los vehículos, inciden en las emisiones de CO₂. Aunque en concentraciones bajas o habituales no presenta toxicidad, su aumento en la atmósfera debido a actividades humanas ha generado un incremento significativo, contribuyendo al cambio climático.

En este sentido, resulta imperativo realizar una transición hacia tecnologías más ecológicas y reducir las emisiones de CO₂ para hacer frente a los desafíos asociados con la mitigación del cambio climático.

Óxidos de nitrógeno - NO_x

Los óxidos de nitrógeno (NO_x) son una clase de gases contaminantes emitidos por vehículos con motores de combustión interna, compuestos principalmente por óxido nítrico (NO) y dióxido de nitrógeno (NO₂). Estos compuestos se producen durante la combustión a altas temperaturas, en presencia de oxígeno y nitrógeno del aire. Este proceso tiene importantes consecuencias ambientales, ya que los NO_x contribuyen a la formación de smog y afectan negativamente la calidad del aire, exacerbando problemas respiratorios en la salud humana.

Para reducir las emisiones de NO_x, se han establecido directrices que incluyen la implementación de tecnologías clave, como la válvula de recirculación de gases de escape (EGR), la cual controla la liberación directa de estos gases al medio ambiente.

Hidrocarburos – HC

Los hidrocarburos son compuestos orgánicos compuestos principalmente de átomos de carbono e hidrógeno. La emisión de gases contaminantes por parte de los vehículos se refiere a la liberación de hidrocarburos que no se han quemado por completo durante el proceso de combustión en los motores de combustión interna. La cantidad de estos hidrocarburos liberados está estrechamente relacionada con la eficiencia del motor y la calidad del combustible utilizado. Los efectos adversos para la salud relacionados con estos hidrocarburos incluyen problemas respiratorios y efectos tóxicos a largo plazo. Además, su impacto ambiental se manifiesta en la formación de smog y tiene consecuencias directas en la calidad del aire.

Factor de emisión

Los factores de emisión hacen referencia a la relación cuantitativa entre las emisiones de gases contaminantes liberados en la atmósfera y los datos asociados con una actividad específica. Estos factores se expresan en unidades de masa del gas contaminante emitido por la distancia recorrida por un vehículo. En términos generales, estos indicadores indican la proporción de la masa del contaminante en relación con una unidad de peso, volumen, distancia o duración.

La liberación de gases contaminantes a través del escape de los vehículos está condicionada por diversos factores, incluyendo las características tecnológicas, los sistemas de control de emisiones, el mantenimiento, la distancia recorrida, las propiedades del combustible y las condiciones geográficas de la zona. Los factores de emisión pueden ser determinados mediante métodos diversos, ya sean directos o indirectos. (*METODOLOGÍAS PARA LA ESTIMACIÓN DE EMISIONES DE TRANSPORTE URBANO DE CARGA Y GUÍAS PARA LA RECOPIACIÓN Y ORGANIZACIÓN DE DATOS*, 2013)

Métodos directos para calcular factores de emisión

Los métodos directos representan la emisión de gases contaminantes en condiciones reales de conducción. Dentro de los métodos principales son:

- Medición a bordo:

Este método de medición a bordo implica la utilización de un analizador portátil para registrar las emisiones de gases mientras un vehículo está en movimiento, considerando factores relevantes como velocidad, carga, aceleración, entre otros, en tiempo real. Para llevar a cabo este proceso de manera eficiente, es esencial una planificación cuidadosa que incluya la determinación del tiempo de medición, la selección del tipo de vehículo, la elección de la ruta para la recopilación de datos, y la consideración de aspectos específicos del vehículo, como la temperatura del motor. Este

método proporciona información detallada sobre el desempeño de un vehículo en condiciones reales de conducción.

- Pruebas en dinamómetro:

Las evaluaciones efectuadas en un dinamómetro se llevan a cabo en ambientes controlados, donde los vehículos son sometidos a una carga conocida que imita su funcionamiento normal. Los resultados se cuantifican en gramos por unidad de energía (g/kWh o g/bhp-hr) para determinar los factores de emisión. A pesar del alto costo inicial asociado con la adquisición del dinamómetro, una vez instalado, los gastos de mantenimiento son relativamente bajos.

Métodos indirectos para calcular factores de emisión

Los métodos indirectos se basan en modelos distintos modelos internacionales que utilizan información de los métodos directos ajustada a diferentes condiciones teóricas de cada modelo. Dentro de estos modelos indirectos los principales son los siguientes que se detallan a continuación:

- MOBILE 6:

Este procedimiento ha sido concebido por la Agencia de Protección Ambiental de los Estados Unidos (US-EPA). Facilita la estimación de diversos contaminantes, tales como hidrocarburos (HC), monóxido de carbono (CO), óxidos de nitrógeno (NOx), dióxido de azufre (SO₂), entre otros.

En este método, los parámetros de entrada posibilitan la obtención de los factores de emisión correspondientes a diferentes valores de velocidad.

- MOVES

Este modelo también creado por la US-EPA reemplaza al modelo Mobile 6, además permite el cálculo de los factores de emisión en diferentes escalas como: regional, local y como proyecto. En función de la escala en la que se desee trabajar se necesitará información para poder modelar los escenarios propuestos.

- IVE

El modelo IVE fue desarrollado por el Centro Internacional de Investigación en Sistemas Sustentables (ISSRC). Fue creado con el propósito de utilizar información existente o datos de recolección sencilla para generar un inventario de emisiones confiable, adaptado a las condiciones específicas de cada zona de estudio. En el caso de disponer de factores de emisión particulares, estos pueden integrarse a las bases de datos del modelo.

- COPERT IV

El COPERT IV fue creado por el Centro de Investigación Conjunta de la Comisión Europea, tiene como objetivo calcular las emisiones contaminantes provenientes del sector del transporte. Este modelo se centra en evaluar tecnologías que se adhieran a la clasificación europea EURO.

Prueba en ciclos reales de conducción (RDE)

La llamada RDE (Real Driving Emissions) se traduce como un test en donde se equipa a un vehículo con equipos de medición y durante un determinado tiempo se recorre una serie de kilómetros en sector urbano, rural y autopista. En donde las mediciones se realizan en diferentes condiciones como: temperatura, densidad de tráfico, altitud, carga en el vehículo, etc. (euro 6, 2017)

Una prueba de un ciclo de conducción Real Driving Emissions (RDE) implica que un vehículo, equipado con instrumentación específica y especializada, circule durante un intervalo de tiempo

predeterminado a lo largo de variadas vías públicas que abarquen itinerarios urbanos, interurbanos y/o autopistas. Posteriormente, se procede a validar la información recabada mediante la aplicación de conocimientos técnicos.

Vehículos híbridos

Un vehículo eléctrico híbrido (VEH) es un tipo de automóvil que fusiona un sistema de propulsión convencional que incorpora un motor de combustión interna (MCI), junto con un sistema de propulsión eléctrica. La incorporación del tren motriz eléctrico persigue la mejora de la eficiencia en el consumo de combustible en comparación con los vehículos convencionales, logrando así un rendimiento general superior. La configuración y funcionalidad de los VEH puede variar, afectando su capacidad para operar como vehículos eléctricos en función de su tipo.

En la actualidad, se encuentran disponibles diversos modelos de vehículos eléctricos híbridos, que abarcan categorías como scooters, automóviles, camionetas, camiones y autobuses. A un auto se le denomina "híbrido" cuando es impulsado por dos motores que pueden ser de distinta naturaleza: por ejemplo, un motor de combustión interna y un (hasta dos) motor eléctrico (Kebriaei et al., 2016). Un auto híbrido puede aprovechar ambas fuentes para obtener energía y moverse de forma económica y con un excelente rendimiento. Cabe mencionar que los vehículos híbridos pueden circular tanto en combinación de ambos motores o en forma puramente eléctrica. (Volkswagen de México, 2022)

Los vehículos híbridos hicieron su debut inicial en la exposición de automóviles de París en 1899. En sus primeras etapas de desarrollo, se diseñaron con el objetivo de mejorar la eficiencia del rendimiento automotriz. Henri Pieper construyó el primer vehículo de arquitectura híbrida, que incorporaba un motor de combustión interna de pequeño tamaño refrigerado por aire, complementado por un motor eléctrico y baterías de plomo-ácido.

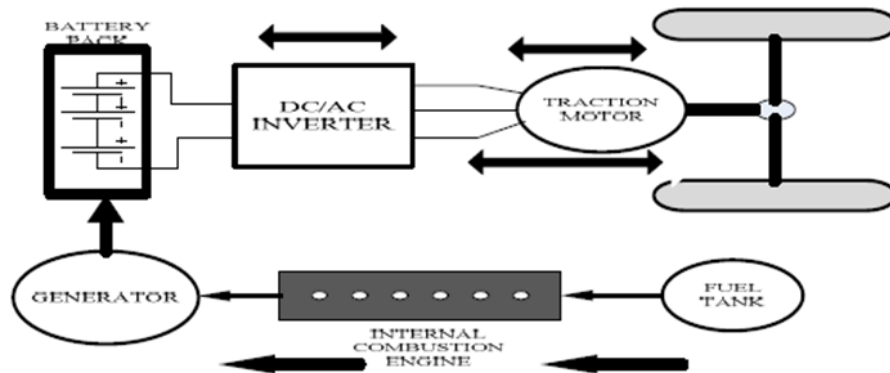
Estos vehículos se pueden clasificar de acuerdo a su arquitectura/configuración de su tren de potencia que se caracterizan por la eficiencia energética y autonomía proporcionada. A continuación, se detalla las configuraciones:

- **Vehículo híbrido serie**

En el diseño de configuración en serie, la energía destinada a impulsar las ruedas se origina a partir de un motor eléctrico alimentado por la combinación de un motor de combustión y un motor generador que utiliza la energía almacenada en las baterías de alta tensión. Algunos vehículos híbridos en configuración en serie incorporan motores eléctricos individuales en cada rueda para proporcionar tracción. No obstante, la adopción de esta disposición conlleva un aumento en el peso del vehículo, resultando en una disminución del rendimiento global debido a la carga adicional.

Figura 2

Configuración en serie



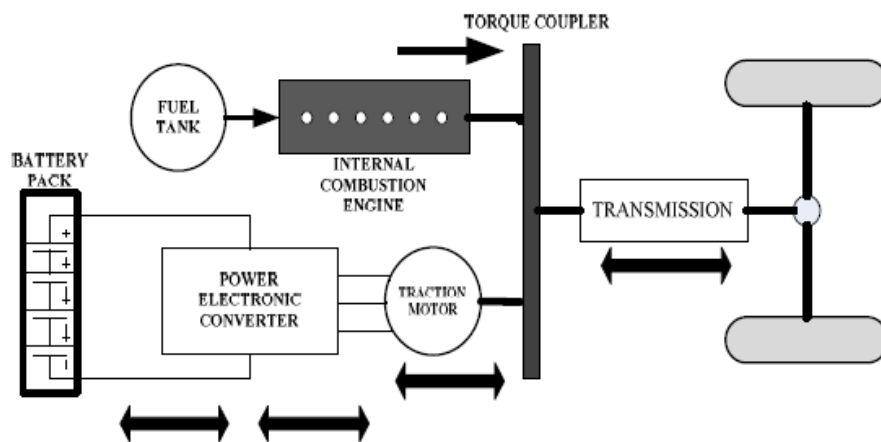
Nota: Configuración en serie - VEH. Fuente: (Vipul Agarwal & Mayank Dev, 2013)

- **Vehículo híbrido en paralelo**

Es una configuración de vehículo híbrido que combina la potencia mecánica de un motor de combustión interna (ICE) y la energía eléctrica de un motor eléctrico en paralelo para impulsar la transmisión del vehículo. En esta configuración, dos fuentes de energía están conectadas mecánicamente entre sí para impulsar las ruedas, de forma similar a cómo funciona un vehículo tradicional con motor de combustión interna. Esta configuración utiliza diferentes estrategias de control para coordinar el funcionamiento de los dos motores. Si la potencia necesaria para conducir el vehículo supera la del motor de combustión interna, el motor eléctrico se activa para proporcionar potencia adicional a la caja de cambios. Por otro lado, si la potencia requerida es menor que la potencia del motor de combustión interna, la potencia restante se utiliza para cargar la batería del vehículo realizando una regeneración durante el frenado. (Çağatay Bayindir et al., 2011)

Figura 3

Configuración en paralelo




Nota: Configuración en paralelo - VEH. Fuente: (Vipul Agarwal & Mayank Dev, 2013)

- **Vehículo híbrido mixto**

Los vehículos híbridos mixtos son una configuración especial que integra características tanto de sistemas híbridos en serie como en paralelo, con el propósito de aprovechar las ventajas inherentes de ambos para mejorar la eficiencia energética del vehículo. Este sistema de tren de potencia posee la capacidad de operar en diversos modos de funcionamiento, ajustándose a las condiciones de conducción específicas. Durante velocidades bajas, el sistema puede operar predominantemente como un híbrido en serie, donde el motor de combustión interna (ICE) se encarga de cargar la batería. Luego, la energía almacenada en la batería alimenta un motor eléctrico encargado de propulsar las ruedas. Este modo de operación es eficaz en situaciones de baja velocidad, contribuyendo a la reducción de emisiones de gases contaminantes en entornos urbanos. Conforme la velocidad aumenta y el tren de potencia en serie exhibe una eficiencia decreciente, el sistema puede cambiar al modo híbrido en paralelo. Donde, el motor de combustión interna y el motor eléctrico colaboran para suministrar la potencia requerida para la tracción.

Figura 4

Configuración mixta o serie-paralelo



Nota: Configuración serie/paralelo - VEH. Fuente: (Vipul Agarwal & Mayank Dev, 2013)

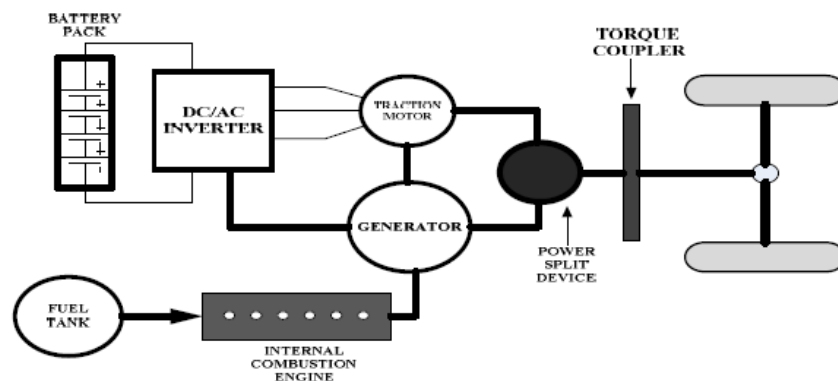
- **Vehículo híbrido complejo**

La configuración del tren de potencia de un vehículo híbrido complejo posee dos o más motores eléctricos en donde el consumo de energía y rendimiento es optimizado.

Esta configuración parece ser idéntica a la serie-paralelo o mixta. Sin embargo, la diferencia se encuentra en el flujo de potencia bidireccional de la energía, mientras que en la arquitectura mixta el flujo de energía es unidireccional. Como característica podemos mencionar que el acoplador eléctrico se mueve hacia las baterías y se aumenta un convertidor de potencia.

Figura 5

Configuración compleja



Nota: Configuración compleja - VEH. Fuente: (Vipul Agarwal & Mayank Dev, 2013)

Euro 6 – RDE

La norma europea Euro 6 - RDE (Real Driving Emissions) es una normativa medioambiental que establece criterios precisos para limitar las emisiones de gases contaminantes producidas por vehículos equipados con motores de combustión interna mientras se encuentran en carretera. Esta normativa no solo se aplica a vehículos con motores exclusivamente de combustión interna, sino también a vehículos híbridos y vehículos híbridos enchufables.

El principal objetivo de esta norma radica en asegurar el cumplimiento de los límites de emisión de contaminantes atmosféricos, tales como óxidos de nitrógeno (NOx), hidrocarburos no quemados, y otros gases perjudiciales para la salud, durante situaciones reales de conducción en carretera. Este enfoque contrasta con las pruebas convencionales realizadas en entornos de laboratorio, ya que se enfoca en las emisiones reales que se generan en diversas condiciones de conducción, proporcionando así una representación más precisa del impacto ambiental de los vehículos en el entorno real.

Esta normativa establece los parámetros a considerar al momento de hacer un planteamiento de las rutas para el diseño experimental. En el punto 6.4 dice: “En áreas rurales, los vehículos típicamente operan a velocidades entre 60 km/h y 90 km/h. Sin embargo, para los vehículos de la categoría N2 que están equipados con un dispositivo de limitación de velocidad según la Directiva 92/6/CEE, restringiendo la velocidad máxima a 90 km/h, en estas zonas rurales, las velocidades están comprendidas entre 60 km/h y 80 km/h”. (euro 6, 2017)

El punto 6.5 establece: “En autopistas, los vehículos suelen circular a velocidades de más de 90 km/h. Sin embargo, para los vehículos de la categoría N2 que están equipados con un dispositivo de limitación de velocidad conforme a la Directiva 92/6/CEE, el límite de velocidad en autopistas es de 80 km/h”. (euro 6, 2017)

En el punto 6.8 dice que: “La velocidad promedio, considerando las detenciones, durante la parte del viaje en área urbana debe estar en el rango de 15 a 40 km/h. Las detenciones se definen como periodos en los que la velocidad del vehículo es inferior a 1 km/h, y deberían constituir entre el 6 y el 30 % del tiempo total de funcionamiento en área urbana. Durante el trayecto en área urbana pueden ocurrir múltiples detenciones de al menos 10 segundos cada una. No obstante, ninguna

detención puede durar más de 300 segundos consecutivos; de lo contrario, se considerará que el trayecto no ha sido válido”. (euro 6, 2017)

El punto 6.9 dice que: “El rango de velocidades aceptable para conducir en autopista debe comprender desde 90 km/h hasta al menos 110 km/h. El vehículo deberá mantener una velocidad superior a 100 km/h durante al menos 5 minutos”. (euro 6, 2017)

Mientras que el punto 6.11 establece que: “La diferencia en la altitud sobre el nivel del mar entre los puntos de inicio y finalización de un recorrido no excederá los 100 metros. Además, la ganancia acumulada de altitud positiva, proporcional a lo largo de todo el trayecto y en la parte urbana del mismo, conforme al punto 4.3, será menor a 1,200 metros por cada 100 kilómetros, según se especifica en el apéndice 7b”. (euro 6, 2017)

Kane live

Es un software que simplifica la visualización y el registro de datos en tiempo real de unidades compatibles, facilitando el seguimiento y análisis de los parámetros medidos. Este software permite la conexión de unidades compatibles a una computadora personal (PC) de forma inalámbrica. El software es capaz de configurar automáticamente la pantalla según el producto Kane seleccionado, lo que facilita al usuario la visualización de lecturas en tiempo real en su PC.

El software proporciona una representación de los datos en forma digital o gráfica, lo que permite al usuario realizar un seguimiento de los parámetros a lo largo del tiempo a medida que cambian. Además, ofrece la capacidad de guardar y almacenar los datos en vivo en la PC en formato .CSV, que es un formato estándar para importar y exportar datos. (Kane, 2023)

Dependiendo de la unidad compatible con la que se esté trabajando, el software puede ofrecer otras características adicionales, como la capacidad de imprimir datos, actualizar información de

usuario, activar o desactivar una bomba, y la posibilidad de guardar y descargar datos, además de la creación de gráficos personalizados.

Figura 6

Software Kane live



Nota: Software Kane live. Fuente: (Kane, 2023)

OBDlink Mx

El OBDLink MX es un dispositivo diseñado para la adquisición de datos en tiempo real mediante la comunicación directa con los módulos de control del vehículo. Su función principal es permitir la recolección de datos a través de señales PID's para el monitoreo y análisis del rendimiento del vehículo.

Este dispositivo se conecta al vehículo a través del puerto DLC (Conector de Enlace de Datos) que generalmente se encuentra en la cabina del conductor. Utiliza una conexión Bluetooth para establecer una comunicación inalámbrica con dispositivos móviles Android, facilitando así el monitoreo en tiempo real y el escaneo de los datos recopilados. (OBDlink, 2023)

La conexión Bluetooth permite una comunicación eficiente entre el OBDLink MX y el dispositivo móvil, brindando una interfaz de usuario intuitiva para visualizar y analizar los datos del vehículo.

Es importante destacar que este dispositivo cumple con los estándares OBD-II legislados y tiene la capacidad de acceder a redes avanzadas de vehículos, como MS-CAN y SW-CAN, proporcionando una cobertura amplia y detallada para la adquisición de datos.

Figura 7

OBDlink Mx



Nota: Dispositivo OBDlink Mx. Fuente: (OBDlink, 2023)

Estado del arte

Evanthia A. Nanaki, Christopher J. Koroneos (2013) realizaron un estudio titulado “Análisis económico y ambiental comparativo de vehículos convencionales, híbridos y eléctricos, caso de estudio de Grecia”, realizado en Grecia. Los autores de esta investigación realizan una comparación económica y ambiental entre un vehículo convencional, híbrido y eléctrico que se encuentran disponibles en el mercado griego con el objetivo de proporcionar información válida y necesaria para una propuesta de desarrollo de un sistema de transporte sostenible que posea emisiones cercanas a cero. Para este análisis los autores plantean tres escenarios de generación de electricidad que son: alto, medio y bajo contenido de carbono. A su vez, para el análisis económico se toman en consideración aspectos como: precio del vehículo seleccionado, costos de combustible, autonomía. Y para el impacto ambiental se estudian y analizan dos etapas:

producción del vehículo y uso de combustible. La metodología empleada en esta investigación se basó en el uso de datos de ventas y un análisis de ciclo de vida de los vehículos (ACV) para evaluar el impacto ambiental que estos tienen. Los resultados de este artículo muestran que los vehículos híbridos y eléctricos tienen ventajas sobre los convencionales. (Nanaki & Koroneos, 2013)

Jacek Pielecha, Kinga Skobiej and Karolina Kurtyka (2020) desarrollaron la investigación titulada “Análisis de Emisiones de Escape y Consumo de Energía de Vehículos Convencionales, Híbridos y Eléctricos en Ciclos de Conducción Reales”. Los autores de este artículo realizaron una evaluación comparativa del consumo de energía y las emisiones de escape de vehículos de pasajeros con diferentes tipos de motores, incluyendo convencionales, híbridos y eléctricos, en condiciones reales de conducción. Los autores buscaron identificar los cambios en estos factores ambientales que han ocurrido con el avance tecnológico de los vehículos, y contribuir a la clasificación de vehículos y a la identificación de las ventajas de los últimos avances en tecnologías de vehículos convencionales, híbridos y eléctricos. En donde, se utilizaron vehículos con motores convencionales de diferentes estándares de emisiones (euro 6), así como vehículos híbridos modernos (HEV, PHEV) y un vehículo eléctrico. Las pruebas se llevaron a cabo en la Universidad de Tecnología de Poznan, y se siguieron los requisitos de la Comisión Europea para la medición de emisiones de escape en condiciones reales de operación. El estudio se centró en la comparación del consumo de energía y las emisiones bajo diferentes condiciones de tráfico, con énfasis en un ciclo urbano y la prueba completa de emisiones en condiciones reales de conducción (RDE, por sus siglas en inglés). Los resultados que se obtuvieron en este artículo mostraron que el consumo total de energía en condiciones reales de tráfico es menor en los vehículos eléctricos en comparación con los vehículos híbridos y los vehículos con motores de combustión interna. Específicamente, el consumo de energía más bajo se asoció con los vehículos eléctricos, seguido

por los vehículos híbridos enchufables con motor de gasolina, y finalmente, los vehículos con motores de combustión interna. Además, se identificaron diferencias significativas en las emisiones de escape y el consumo de energía entre los diferentes tipos de vehículos y en diferentes condiciones de tráfico, lo que destaca la importancia de evaluar el rendimiento de los vehículos en condiciones reales de conducción. Los autores concluyeron que los resultados obtenidos proporcionan información valiosa sobre el rendimiento ambiental y energético de los vehículos convencionales, híbridos y eléctricos en condiciones reales de conducción, lo que puede ser útil para los fabricantes de automóviles, los responsables políticos y los consumidores en la toma de decisiones relacionadas con la elección de vehículos y la reducción de las emisiones de gases de efecto invernadero y otros contaminantes del aire. (Pielecha et al., 2020)

Claudio Maino, Daniela Misul, Alessandro Di Mauro, Ezio Spessa (2021) desarrollaron la investigación titulada “Predicción de emisiones de dióxido de carbono de vehículos híbridos eléctricos utilizando un modelo basado en redes neuronales profundas”. Los autores en este artículo proponen un modelo basado en redes neuronales profundas para la predicción de las emisiones de dióxido de carbono de los vehículos híbridos eléctricos. El modelo consiste en una serie de redes neuronales destinadas a capturar las correlaciones entre los parámetros de diseño de la arquitectura de un vehículo híbrido y los principales resultados del algoritmo de programación dinámica, es decir, la viabilidad del tren motriz y las emisiones de CO₂ del tubo de escape. El enfoque de gestión de datos para introducir los datos en el modelo de predicción lo realizaron mediante la generación de una base de datos de vehículos híbridos eléctricos (HEV) basada en los parámetros de diseño de diferentes arquitecturas HEV. Los autores utilizaron un enfoque de Diseño de Experimentos (DoE) para generar un solo Volumen de Línea (VL) para tres arquitecturas paralelas de HEV y procesarlo mediante un algoritmo de Programación Dinámica

(DP). Una vez completadas las simulaciones, generaron un conjunto de datos que comprende las especificaciones de diseño para cada arquitectura y se introdujo en el modelo de redes neuronales profundas (DNNs-PM). El modelo realizó dos pasos: primero, la discriminación entre diseños viables/no viables (una tarea de clasificación); luego, la predicción de las emisiones de CO₂ del tanque a la rueda de los diseños admisibles (una tarea de regresión). Para lograr una predicción de doble naturaleza, desarrollaron un pipeline de dos redes neuronales. Los resultados obtenidos de esta investigación y modelo radican en el rendimiento de la red neuronal de clasificación aumentó con el número de diseños empleados en el procedimiento de entrenamiento, con los mejores resultados obtenidos para un conjunto de datos específico, La red neuronal de regresión mostró predicciones de CO₂ comparables a los valores objetivo, con un error promedio inferior al 0.5% para cualquier diseño viable, El modelo puede integrarse en operaciones de optimización del diseño de flotas de vehículos híbridos eléctricos, identificando regiones de bajas emisiones de CO₂ comparables a las obtenidas por un algoritmo de optimización global. Los autores concluyen y resaltan la capacidad del modelo para predecir la viabilidad de las configuraciones y las emisiones de CO₂. (Maino et al., 2021)

Haibo Zhai, H. Christopher Frey, Nagui M. Roupail (2011) desarrollaron la investigación titulada “Desarrollo de un modelo de emisiones modales para un vehículo eléctrico híbrido”. Los autores se plantearon como objetivo desarrollar un modelo de emisiones modales para un vehículo eléctrico híbrido (HEV) específico, el Toyota Prius HEV del año 2001. La importancia de este modelo radica en la necesidad de estimar con precisión el uso de energía y las emisiones de los HEV, que presentan características operativas únicas, como el apagado y encendido del motor de combustión interna (ICE). El estudio se centra en cuantificar los criterios asociados con el arranque y apagado del motor ICE y desarrollar un modelo de emisiones de escape modal bajo condiciones

estabilizadas en caliente. Los autores utilizaron el concepto de potencia específica del vehículo (VSP) como base para modelar las emisiones. El método que propusieron se basa en variables observables externamente, lo que lo hace compatible con los datos disponibles en los modelos de transporte. El enfoque metodológico incluye el desarrollo de algoritmos para las reglas de operación del motor ICE y la calibración de un modelo de emisiones modales basado en VSP utilizando datos de pruebas en dinamómetro. Los autores consideraron que el desarrollo de un modelo de emisiones modales para vehículos eléctricos híbridos (HEV) es de gran importancia debido a la necesidad de estimar con precisión el uso de energía y las emisiones de estos vehículos, que presentan características operativas únicas. Los HEV, al utilizar tanto un motor de combustión interna (ICE) como un motor eléctrico, experimentan episodios de encendido y apagado del motor, lo que plantea desafíos únicos para la estimación de emisiones a escala micro y la asignación de emisiones a lo largo del tiempo y el espacio en una red de transporte. Por lo tanto, el desarrollo de un modelo de emisiones modales específicamente adaptado a las características operativas de los HEV es fundamental para respaldar la estimación de emisiones y la planificación de inventarios de emisiones. Los resultados de la investigación indican que el modelo de emisiones modales desarrollado para el Toyota Prius HEV del año 2001 es capaz de predecir con precisión las emisiones de CO, NO_x y HC para ciclos de conducción individuales y para el promedio de múltiples ciclos. El modelo se basa en el concepto de potencia específica del vehículo (VSP) y utiliza algoritmos para las reglas de operación del motor ICE. Se encontró que el motor ICE se apaga por debajo de ciertos umbrales de demanda de potencia que dependen de la velocidad y la aceleración del vehículo. Los autores concluyeron que el modelo de emisiones modales desarrollado en esta investigación es una herramienta valiosa para estimar con precisión el uso de energía y las emisiones de los HEV, lo que es fundamental para la planificación de inventarios de

emisiones y la evaluación del impacto ambiental de los vehículos. Además, destacan la importancia de considerar las características operativas únicas de los HEV al desarrollar modelos de emisiones modales para estos vehículos. (Zhai et al., 2011)

S. Bagheri, Y. Huang, P.D. Walker, J.L. Zhou, N.C. Surawski (2021) desarrollaron la investigación titulada “Estrategias para mejorar el rendimiento de emisiones de vehículos híbridos eléctricos”. Los autores realizaron esta investigación con el objetivo de realizar una revisión de la literatura existente sobre las emisiones de vehículos convencionales e híbridos, con el fin de identificar las disparidades en las emisiones entre estos dos tipos de vehículos y proponer estrategias para mejorar el rendimiento de las emisiones de los vehículos híbridos (HEV). Los autores una vez revisaron el estado del arte en base a este tema, se centraron en los problemas de los arranques en frío de alta potencia en los vehículos híbridos. Los autores detallan que una de las incertidumbres que están presentes en los factores de emisión de estos vehículos es el enfriamiento del convertidor catalítico cuando el motor térmico se apaga, otro de los factores que detallan son las que las mezclas aire/combustible no son homogéneas cuando se pone en marcha el motor térmico. Los autores plantean ciertas estrategias para poder mejorar el rendimiento de las emisiones en vehículos híbridos (HEV) las cuales son: control de gestión térmica, opciones de calibración del motor, opciones de control post tratamiento. Adicional a esas estrategias se plantearon opciones de control del motor, como aumentar la velocidad de ralentí, retardos en el encendido y proporcionar inyecciones estratificadas durante el reinicio del motor térmico para acelerar el proceso de calentamiento del convertidor catalítico. (Bagheri et al., 2021)

Yuhan Huang, Nic C. Surawski, Bruce Organ, John L. Zhoua, Oscar H.H. Tang, Edward F.C. Chan (2019) desarrollaron la investigación titulada “Comparación del consumo de combustible y emisiones de vehículos híbridos y convencionales en condiciones de conducción real”. Los autores

llevaron a cabo esta investigación haciendo una comparación del rendimiento de consumo de combustible y emisiones de vehículos híbridos y convencionales en condiciones de conducción real. Se probaron dos pares de vehículos híbridos y convencionales del mismo modelo, utilizando un novedoso modo de convoy que eliminó el efecto de diversas condiciones de conducción. Cada par de vehículos se probó simultáneamente en la misma ruta utilizando dos sistemas portátiles de medición de emisiones, lo que permitió una comparación justa del rendimiento. En los resultados que obtuvieron se mostraron que, aunque el consumo de combustible en condiciones reales fue mayor que en las pruebas de laboratorio, los vehículos híbridos lograron ahorrar entre un 23% y un 49% de combustible en comparación con sus contrapartes de motor de combustión interna convencionales. Además, se observó que los vehículos híbridos mostraron emisiones de CO más altas en comparación con los vehículos convencionales, lo que podría atribuirse a paradas y arranques frecuentes del motor híbrido, así como a la reducción de la temperatura de los gases de escape y la eficacia reducida del catalizador de oxidación. Por último, los autores concluyen que los vehículos híbridos pueden ser una tecnología efectiva para reducir el consumo de combustible en condiciones de conducción urbana con tráfico denso y paradas frecuentes, pero también destacan la necesidad de mejorar la eficacia de los sistemas de gestión de energía y los sistemas de tratamiento posterior para reducir las emisiones de CO. (Huang et al., 2019)

BRANISLAV ŠARKAN, JOZEF GNAP, MONIKA KIKTOVÁ (2019) desarrollaron el artículo titulado “La importancia de los vehículos híbridos en el tráfico urbano en términos de impacto ambiental”. Los autores desarrollaron esta investigación con el objetivo de analizar la importancia de los vehículos híbridos en el tráfico urbano en términos de impacto ambiental. Centrándose en la reducción de emisiones de CO₂, HC y NO_x durante la operación urbana de los vehículos híbridos en comparación con los vehículos convencionales. Esta investigación la desarrollaron

mediante pruebas prácticas en un vehículo híbrido en condiciones de tráfico urbano. Se midieron las emisiones de CO₂, HC y NO_X utilizando un analizador de gases de escape comercialmente disponible y se registraron datos seleccionados del control del motor a través de diagnósticos OBD. El vehículo utilizado en las pruebas fue un Toyota RAV4 con transmisión CVT y tracción en las cuatro ruedas, impulsado por un motor de gasolina VVT-i de 2.494 cm³ y dos motores eléctricos con una potencia combinada de 145 kW. Los resultados que obtuvieron en la investigación muestran que el uso de vehículos híbridos en entornos urbanos puede reducir significativamente las emisiones de CO₂, HC y NO_X en comparación con los vehículos convencionales. Durante la operación urbana, el vehículo híbrido utilizado en las pruebas fue impulsado principalmente por motores eléctricos, lo que resultó en una disminución significativa de estas emisiones. Además, se destaca la importancia de la introducción y desarrollo de fuentes de energía renovable en el transporte y la promoción de modos de transporte no motorizados y respetuosos con el medio ambiente para reducir el impacto ambiental del transporte por carretera. Los autores luego de desarrollar esta investigación concluyen que los vehículos híbridos tienen un papel importante que desempeñar en la reducción de las emisiones de gases de efecto invernadero y otros contaminantes en entornos urbanos. La capacidad de estos vehículos para alternar entre la propulsión eléctrica y la de combustión interna permite una mayor eficiencia en el consumo de combustible y una reducción general de las emisiones, lo que contribuye a mejorar la calidad del aire en entornos urbanos. (Šarkan et al., 2019)

Maria Vittoria Prati, Maria Antonietta Costagliola, Rocco Giuzio, Corrado Corsetti, Carlo Beatrice (2021) desarrollaron la investigación titulada “Comportamiento emisivo y energético de un automóvil híbrido enchufable en pruebas de emisiones de conducción real”. Los autores de este artículo realizaron un análisis del comportamiento emisivo y energético de un automóvil híbrido

enchufable durante pruebas de emisiones en condiciones reales de conducción. Se examinaron las emisiones de CO, CO₂, NO_x y los parámetros principales del motor eléctrico en rutas urbanas, rurales y de autopista en Nápoles, Italia, cumpliendo con la legislación europea de emisiones de conducción real. Se observó que el estado de carga de la batería, el modo híbrido, la pendiente de la carretera y el aire acondicionado del vehículo influyeron en las emisiones de escape y el consumo de energía. Se encontró una ventaja general en términos de emisiones de CO₂ y consumo de combustible cuando la batería estaba completamente cargada y se utilizaba el modo de agotamiento de carga. Esta investigación la llevaron a cabo mediante pruebas de emisiones en condiciones reales de conducción en Nápoles, Italia. Se utilizaron instrumentos portátiles para monitorear las emisiones de escape y el consumo de energía en rutas urbanas, rurales y de autopista, cumpliendo con la legislación europea de emisiones de conducción real. Se analizó el impacto del estado de carga inicial de la batería, el modo híbrido, la pendiente de la carretera y el aire acondicionado del vehículo en el comportamiento emisivo y la estrategia eléctrica del automóvil híbrido enchufable. Los resultados que obtuvieron mostraron que el estado de carga inicial de la batería, el modo híbrido, la pendiente de la carretera y el aire acondicionado del vehículo influyeron significativamente en las emisiones de escape y el consumo de energía del automóvil híbrido enchufable. Los autores observaron una ventaja general en términos de emisiones de CO₂ y consumo de combustible cuando la batería estaba completamente cargada y se utilizaba el modo de agotamiento de carga. A su vez, destacaron que la conducción puramente eléctrica garantiza cero emisiones en pendientes pronunciadas urbanas cuando la batería estaba completamente cargada. (Prati et al., 2021)

Yachao Wang, Chunxiao Hao, Yunshan Ge, Lijun Hao, Jianwei Tan, Xin Wang, Pengyu Zhang, Yuan Wang, Weidong Tian, Zhiqi Lin, Jian Li (2020) desarrollaron la investigación titulada “Rendimiento de consumo de combustible y emisiones de vehículos convencionales/híbridos de servicio ligero en diferentes ciclos de prueba y pruebas de conducción real”. Los autores llevaron a cabo esta investigación mediante pruebas en un dinamómetro, donde evaluaron el rendimiento de dos vehículos de la misma serie, uno convencional y el otro híbrido en diferentes ciclos de prueba como: CLTC, WLTC y RDE. En esas pruebas midieron el consumo de combustible y las emisiones de CO, NOx y Particulado en cada ciclo de prueba, también analizaron la distribución de carga del motor y velocidad y de lambda durante los RDE. Los resultados que obtuvieron los autores indicaron que los vehículos híbridos poseen un mejor rendimiento en cuanto a consumo de combustible y también existe menos emisión de gases contaminantes que los vehículos convencionales. Encontraron que el consumo de combustible del vehículo híbrido es 20,23% menor que el del vehículo convencional en el ciclo WLTC, observaron que el ciclo CLTC la discrepancia entre las pruebas efectuadas en laboratorio y conducción en tiempo real en China no disminuye. En cuanto a las emisiones de gases contaminantes, el vehículo híbrido emite menos cantidad de NOx que el vehículo convencional porque la carga del motor es menor y el enriquecimiento de la mezcla también es menor. (Wang et al., 2020)

CAPITULO II: METODOLOGÍA UTILIZADA PARA LA OBTENCIÓN DE DATOS EN VEHÍCULOS HÍBRIDOS

En este capítulo se detalla cada uno de los métodos para obtener datos de emisiones contaminantes y variables de operación en los diferentes vehículos híbridos que se poseen previo al análisis ejecutado bajo destrezas de aprendizaje automático. Se utilizan equipos automotrices portátiles con el fin de ejecutar de manera más flexible y precisa, el proceso de recopilación de información. Las herramientas de obtención y análisis de datos integran, una aplicación móvil para recolectar parámetros de funcionamiento por medio del puerto DLC y bajo la conexión enlazada con el equipo OBDLink MX, un equipo dedicado a medir diferentes gases contaminantes a través de una sonda y un analizador vinculado al software KANE LIVE, un dispositivo FREEMATICS ONE+ con la finalidad de contar con datos relacionados a la ubicación geográfica en tiempo real durante las diferentes rutas. Con un enfoque estadístico se plantea analizar el comportamiento de las señales PID's de cada uno de los vehículos híbridos.

El proceso de recolección de parámetros de cada uno de los vehículos se dio bajo la conducción por dos rutas previamente establecidas dentro de los límites geográficos de la ciudad de Cuenca. Para el planteamiento de estos trayectos se tomaron los lineamientos que se especifican en la norma Euro 6 RDE 1154 (respetando lo decretado en factores como: velocidad, tiempo y distancias de manejo). La norma se especifica en contexto en el capítulo I – marco teórico referencial del proyecto de titulación presente.


Factores de inferencia durante la obtención de datos

Durante el periodo de obtención de datos existe la presencia de factores de inferencia en el proceso; estos usualmente se clasifican en cuatro bloques: variables de entrada, variables de bloqueo, variables de ruido y variables de salida. Estos factores afectan directa e indirectamente en la lectura

de datos de señales PID's, índices contaminantes y ubicaciones geográficas. (Molina Campoverde et al., 2021)

Figura 8

Factores de inferencia



Nota: Diagrama de factores de inferencia. Fuente: Autores

Variables de ruido

En la medida que se aplica el proceso respectivo de recolección de datos en diferentes trayectos de la ciudad de Cuenca, existe la presencia de variables complejas de controlar por los diferentes investigadores de campo. De esta manera dichos factores al no mantener valores estables o fijos, como consecuencia ejercen variabilidad en los resultados finales.

Tabla 1

Variables de ruido

Variables de ruido	Símbolo	Valores	Unidad
Humedad relativa del aire	H_{rel}	65 - 75	[%]
Presión atmosférica	P_{atm}	70 – 80	[KPa]
Temperatura del aire	T_{aire}	15 – 25	[°C]

Nota: Variables que se consideran de ruido. Fuente: Autores

Variables de bloqueo

Factores sobre los que sí se puede llevar un control bajo acciones del analista a cargo del proceso experimental. Por consiguiente no influyen de ninguna manera en los parámetros finales o de salida. En estas variables se coloca una medición promedio y continua para los demás estudios o ensayos que se realicen posteriormente. (Néstor Diego et al., 2021)

Tabla 2

Variables de bloqueo

Variables de bloqueo	Símbolo	Valores	Unidad
Temperatura del refrigerante	T_{ref}	80 – 95	[°C]
Masa del vehículo	m_{veh}	1400 1458 1850	[kg]
Temperatura del lubricante	T_{lub}	90 – 105	[°C]

Nota: Tabla que especifica las variables de bloqueo. Fuente: Autores

Variables de entrada

Las conocidas variables de estudio influyen directamente en los valores resultantes que emiten las variables de salida luego del proceso experimental.

Entre variables de entrada la relación debe ser independiente una de otra; de esta manera si se modifica el valor de un parámetro no afecta en otro pese a pertenecer al mismo grupo de variables o parámetros.

En la tabla 3 se detalla cada una de las variables de entrada involucradas.

Tabla 3*Variables de entrada*

Variables de entrada	Símbolo	Unidad
Régimen de giro del motor	n	[rpm]
Flujo másico del aire	MAF	[g/s]
Velocidad del vehículo	VSS	[km/h]
Tipo de vehículo	[Sedan, SUV, Crossover]	[-]
Ruta	d	[Km]

*Nota: Tabla que especifique las variables de entrada. Fuente: Autores***Variables de salida**

Las variables de este grupo son los resultados que emite el proceso experimental, conocidas como de respuesta. Estas varían en función de los tres grupos anteriormente mencionados por ser dependientes directamente de tales parámetros. En la tabla 4 se detalla cada una de las variables

Tabla 4*Variables de salida*

Variables de salida	Símbolo	Unidad
Consumo de combustible	Consumo	L/100 km
Monóxido de carbono	CO	[%]
Dióxido de carbono	CO ₂	[%]
Hidrocarburos no combustionados	HC	[ppm]
Óxidos de nitrógeno	NO _x	[ppm]

Nota: Tabla que especifica las variables de bloqueo. Fuente: Autores

Planificación de rutas para la obtención de parámetros de funcionamiento.

Dada la necesidad de abarcar las emisiones de gases contaminantes de los vehículos híbridos en la ciudad de Cuenca, por consecuente la movilidad de los mismos.

Es necesario plantear rutas que abarquen las diversas zonas por donde se presenta la conducción de los vehículos híbridos tipo M1 (sedán, SUV, crossover o hatchback, camionetas, entre otras). De esta manera se planifican dos rutas a seguir por cada uno de los vehículos incorporados en el proceso experimental.

La primera ruta sigue los lineamientos y condiciones que detalla el ciclo de pruebas RDE (Real Driving Emissions), desde los parámetros de funcionamiento vehicular (ejemplo: velocidad) hasta los de altitud y longitud.

A continuación, en la tabla 5 se especifica a detalle la norma vigente EURO 6 RDE 1154.

Tabla 5

Especificaciones del ciclo de pruebas RDE

Zona de conducción	Longitud	Porcentaje del recorrido
Urbana	16 km	[34 %]
Rural	16 km	[33 %]
Autopista	16 km	[33 %]

Nota: Tabla de especificaciones - RDE. Fuente: Autores

En el planteamiento de la segunda ruta se busca seguir condiciones menos rigurosas, tomando una planificación ligera en la que el conductor tiene libertad de seguir una trayectoria totalmente aleatoria dentro de la ciudad; únicamente considerando los siguientes aspectos generalizados:

- Durante el trayecto, el vehículo debe movilizarse por pendientes considerables
- La longitud que se debe trazar en la ruta debe ser mayor a 30 km de manera continua.
- Mínimo deben manejar el vehículo dos pilotos con el fin de buscar inferencias en el estudio.


Ruta RDE del vehículo Tipo Sedán.

El recorrido que tuvo durante la prueba de obtención de parámetros de funcionamiento y emisiones el vehículo Toyota Corolla Tipo Sedán recorre direcciones y sectores, tales como:

- Av. De las Américas y Av. Héroes de Verdeloma
- Centro histórico de la ciudad de Cuenca
- Sector Sucre y Hospital Regional
- Av. 12 de abril y Av. 24 de mayo

Figura 9

Ruta del vehículo Toyota Corolla (Sedán)



Nota: Ruta RDE que realiza el vehículo Toyota Corolla (Sedán) para la adquisición de datos


Ruta RDE del vehículo Tipo Crossover.

De la misma manera se define los sectores que atravesó el vehículo Toyota CH-R con la finalidad de concluir la obtención de datos y el cumplimiento de los lineamientos que se dictan en la norma EURO 6:

- Av. 12 de octubre y Control Sur
- Centro histórico de la ciudad
- Autopista – Sector Mall del Rio

Figura 10

Ruta del vehículo Toyota CHR (Crossover)



Nota: Ruta RDE que realiza el vehículo Toyota CH-R (Crossover) para la adquisición de datos


Ruta RDE del vehículo Tipo SUV

Cerrando con las diferentes categorías de vehículos puestos a pruebas de ruta, se tiene al Toyota Corolla CROSS, vehículo que por sus características técnicas y constructivas asimila más pertenecer a un SUV que a uno de categoría Crossover. De igual manera siguió los parámetros y lineamientos que otorga la ruta RDE cruzando por los siguientes sectores y carreteras:

- Av. Gil Ramírez Dávalos y Av. Huayna Cápac
- Sector Universidad Politécnica Salesiana
- Av. Hurtado de Mendoza – Sector Totoracocha
- Av. 24 de mayo

Figura 11

Ruta del vehículo Toyota Corolla CROSS (SUV)



Nota: Ruta RDE que realiza el vehículo Toyota Corolla Cross (SUV) para la adquisición de datos.

Proceso experimental

Se describen todos los equipos y módulos utilizados durante el proceso de recolección de datos y parámetros de funcionamiento. Estas especificaciones se vuelven imprescindibles para estudiar el comportamiento de algunas señales o factores de entrada previo a la estimación en el software de ingeniería bajo las diferentes destrezas de aprendizaje automático.

Vehículos asignados a prueba

Se busca incorporar tres vehículos que representen distintas clasificaciones o tipos de vehículos híbridos que se encuentren usualmente en el parque automotriz. Siendo así de énfasis las categorías: Sedán, Crossover, SUV (Sport Utility Vehicle).

- Automóvil Tipo Sedán

El vehículo que se utiliza en el estudio como parte de la categoría Sedán es un Corolla de la marca Toyota, a continuación, se muestra una imagen referencial del móvil asignado a prueba:

Figura 12

Vehículo Corolla Sedán



Nota: Vehículo de prueba Toyota Corolla

De la misma manera en la siguiente tabla se detallan las especificaciones del vehículo, tanto mecánicas como eléctricas (con cierto enfoque en la batería y motores eléctricos):

Tabla 6

Especificaciones mecánicas y eléctricas del Toyota Corolla tipo Sedán

Especificación	Valor
Motor	4 cilindros en línea
Cilindrada	1798 cc
Relación de compresión	13:1
Tipo de combustible	Gasolina Super
Transmisión	Automática
Número de velocidades	5 velocidades
Potencia máxima	97 HP
Torque máximo	142 Nm
Tipo (Batería)	Níquel metal hidruro
Capacidad (Batería)	6,5 Ah
Voltaje (Batería)	207,2 V

Nota: Tabla de especificaciones mecánicas y eléctricas del vehículo Toyota Corolla tipo Sedán

- Automóvil Tipo Crossover

El CH-R de la misma marca Toyota es de los crossovers más reconocidos por la fiabilidad que ofrece a los usuarios. El diseño de este tipo de vehículos está enfocado a un estilo “SPORT”.

Figura 13

Vehículo Toyota CH-R



Nota: Vehículo de prueba Toyota CH-R

En la siguiente tabla se detallan las especificaciones del vehículo:

Tabla 7

Especificaciones mecánicas y eléctricas del Toyota CH-R

Especificación	Valor
Motor	4 cilindros en línea
Cilindrada	1798 cc
Relación de compresión	13:1
Tipo de combustible	Gasolina Super
Transmisión	Automática
Número de velocidades	5 velocidades
Potencia máxima	94 HP
Torque máximo	142 Nm
Tipo (Batería)	Níquel metal hidruro
Capacidad (Batería)	6,5 Ah
Voltaje (Batería)	201,6 V

Nota: Tabla de especificaciones mecánicas y eléctricas del vehículo Toyota CH-R

- Automóvil Tipo SUV

El vehículo que se utiliza en el estudio como parte de la categoría SUV es un Corolla CROSS de la marca Toyota. Es una versión plus del prototipo Sedán Corolla, diseñado para satisfacer necesidades de mayor demanda entorno a trabajo o exigencias de conducción.

A continuación, se muestra una imagen referencial del móvil asignado a prueba:

Figura 14

Toyota Corolla Cross



Nota: vehículo de prueba Toyota Corolla Cross

En la siguiente tabla se detallan las especificaciones del vehículo, tanto mecánicas como eléctricas (con enfoque en la batería y motores eléctricos):

Tabla 8

Especificaciones mecánicas y eléctricas del Toyota Corolla Cross

Especificación	Valor
Motor	4 cilindros en línea
Cilindrada	1798 cc

Relación de compresión	13:1
Tipo de combustible	Gasolina Super
Transmisión	Automática
Número de velocidades	5 velocidades
Potencia máxima	122 HP
Torque máximo	142 Nm
Tipo (Batería)	Níquel metal hidruro
Capacidad (Batería)	6,5 Ah
Voltaje (Batería)	297,2 V

Nota: Tabla de especificaciones mecánicas y eléctricas del vehículo Toyota Corolla Cross


Protocolo de adquisición de datos

Una vez descritos cada uno de los vehículos y sus especificaciones técnicas, rutas realizadas para la adquisición de datos, se continua con el protocolo de adquisición donde estos vehículos se equiparon con diferentes dispositivos portátiles como: analizador de gases + computadora (software kane live), antena GPS Freematics conectada al puerto de alimentación energética de 12V y por último el dispositivo OBDlink Mx conectado al puerto DLC del vehículo vinculado vía Bluetooth a un teléfono celular con la aplicación OBDLink.

El analizador de gases portátil KANE se conecta y vincula con la computadora para la transmisión de datos en tiempo real a través del software KANE LIVE. Para adquirir las coordenadas geográficas del vehículo en cada instante durante todo el trayecto se conecta el Freematics ONE+ a la entrada de la cigarrera del vehículo; previo a adaptar el mismo para la respectiva entrada de energía y con un interruptor que permite el control de encendido/apagado en las intersecciones entre diferentes rutas RDE.

Figura 15

Dispositivos vinculados en la adquisición de datos




Nota: Diagrama de los dispositivos vinculados al vehículo para la adquisición de datos

Se busca lograr una adquisición precisa con un margen de error mínimo, lo cual implica la necesidad de llevar a cabo una serie de procesos de manera eficiente. Este protocolo proporciona una descripción concisa de las acciones actividades que deben llevarse a cabo en cada fase del proceso experimental, garantizando así la integridad y exactitud de la adquisición de datos. A continuación, se presenta el flujograma que detalla el procedimiento:

Figura 16

Flujograma de adquisición de datos



Nota: Flujograma del proceso a seguir para la adquisición de datos. Fuente: Autores

Desde una base teórica, el flujograma anterior permite agilizar el análisis en la etapa de procesamiento de estimación; puesto que brinda rangos de índices estadísticos de calidad con bajos márgenes de error.

Matrices y vectores de estudio

Una vez finalizada la etapa de adquisición de datos, se procede a introducir los mismos en el software de ingeniería (MATLAB) bajo formatos de matrices y vectores. Se hace uso de las matrices generales para poder inducir en primeras instancias los valores de cada una de las variables; por consiguiente, separando las mismas con etiquetas, se forman los vectores. A continuación, se describen el total de variables con las que se trabajará:

Tabla 9*Variables de relevancia para el proyecto*

Número	Descripción de la variable	Abreviación	Unidad
1	Tiempo	Tiempo	[s]
2	Latitud	Lat	[deg]
3	Longitud	Long	[deg]
4	Velocidad del vehículo	VSS	[Km/h]
5	Carga calculada	Carga_Cal	[%]
6	Temperatura del refrigerante	ECT	[°C]
7	Régimen de giro	RPM	[RPM]
8	Temperatura de la entrada de aire	IAT	[°C]
9	Flujo másico	MAF	[g/s]
10	Apertura de la mariposa	TPS	[%]
11	Carga absoluta	Carga_abs	[%]
12	Voltaje de batería eléctrica de tracción	Volt_HV	[V]
13	Corriente de batería eléctrica de tracción	Cur_HV	[A]
14	Altitud	Alt	[m]
15	Velocidad del GPS	VSSgps	[Km/h]
16	Consumo tomado en instantes	Consumo_inst	[l/100 Km]
17	Consumo total	Consumo_total	[l/100 Km]
18	Velocidad de combustible	Fuel_vel	[l/h]
19	Tasa de combustible del motor	Fuel_rate_motor	[g/s]
20	Tasa de combustible del vehículo	Fuel_rate_vehi	[g/s]

Nota: Tabla de las variables de mayor relevancia para el proyecto técnico. Fuente: Autores

El proyecto presente reúne parámetros de funcionamiento de cada vehículo a través de tres equipos distintos, debido a esto es difícil que la extensión de datos sea semejante.

Por lo tanto, se busca igualar el tamaño de los vectores al que tiene mayor número de datos; de esta manera se tiene como resultado una buena cantidad unitaria que permite trabajar de forma flexible y precisa en el software “Matlab” (teniendo en cuenta que el número de datos es fundamental para realizar estimaciones de cualquier tipo).

El software tiene restricciones en la lectura de datos, formato de texto o caracteres no numéricos los reemplaza por “NaN”; ante tal acontecimiento es necesario generar un código para sustituir esos valores por “0” con la finalidad de una mejor adaptabilidad del código general de estimación.

Filtración de variables.

Cuando se trabaja con variables que representan parámetros de funcionamiento de un vehículo o similares, es necesario filtrar o procesar las mismas por las siguientes razones:

- **Ruido y datos erróneos:** Si los datos son provenientes de sensores es probable que contenga ruido o errores. Filtrar los mismos ayuda a eliminar ciertos efectos no deseados y mejorar la calidad del conjunto de variables
- **Valores atípicos:** Si hablamos de la creación o uso de modelos con los datos que contengan valores atípicos afectaría negativamente la precisión del modelo.
- **Optimización de rendimiento:** Existen casos en que el software no rinde de manera eficiente por la cantidad de datos extraños existentes, bajo filtración mejoraría y optimizaría el funcionamiento.

Método de ajuste de mínimos cuadrados de Savitzky-Golay

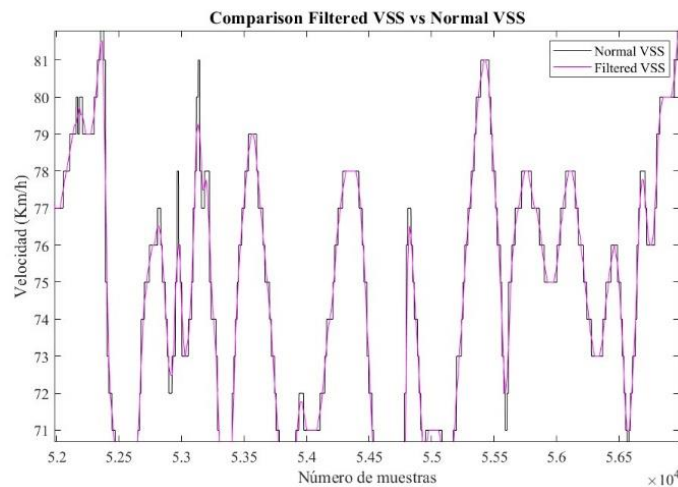
Es de los métodos más usados para filtrar variables previo al estudio bajo uso de software, por su sencillez en comparación a otros métodos que involucran ajustes de curvas a todo el conjunto de datos. La finalidad es de suavizar un grupo de datos con presencia de ruidos al ajustar polinomios de bajo grado a pequeñas ventanas de datos consecutivas.

De esta manera el método de ajuste de mínimos cuadrados es una técnica de suavizado que utiliza la convolución de coeficientes de filtro derivados mediante el ajuste de polinomios locales. En el proyecto aplicamos a la mayoría de variables la filtración; a excepción de unas cuantas como el “Tiempo” que al ser una variable lineal no tiene sentido aplicar filtro. (Molina Campoverde et al., 2021)

Demostración de la diferencia entre una variable filtrada y una que no lo está de los parámetros de los vehículos que se obtuvieron en la adquisición de datos:

Figura 17

Comparación de variable no filtrada vs filtrada



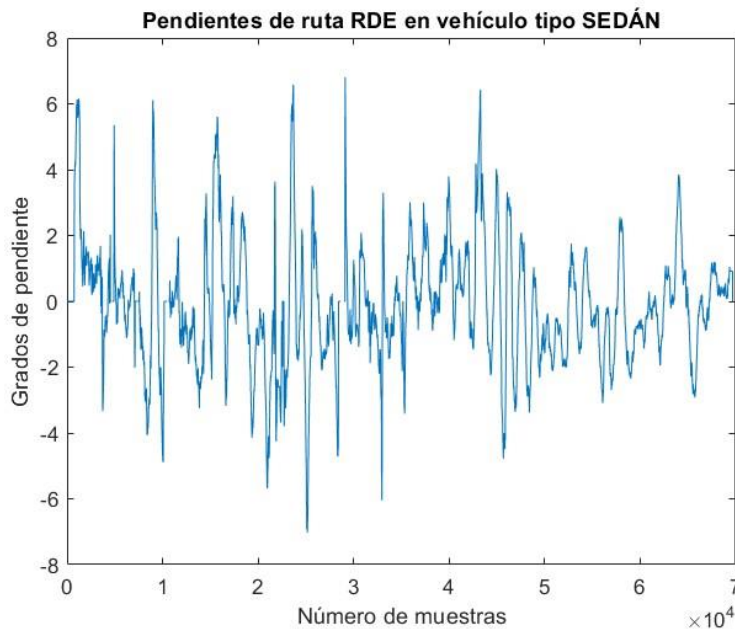
Nota: Gráfico de comparación entre una variable no filtrada vs filtrada.

Pendientes de los vehículos durante rutas RDE

El hecho de conocer en valores numéricos las pendientes por las cuales atraviesa el vehículo de estudio durante su ruta normalizada es imprescindible para delimitar las variables y constantes que tendrán influencia en las entradas y en las salidas de la red neuronal; la cual tiene como finalidad la estimación de factores de emisión de los gases contaminantes. Por simple lógica se induce una teoría de correlación entre las pendientes y las emisiones del vehículo. A mayores pendientes, el vehículo necesita vencer la fuerza de inclinación (la cual incrementa a medida que el ángulo de pendiente es mayor), para lograr eso es inevitable no generar mayor tracción y potencia a la vez que incrementan las RPM, y si se revoluciona de más el motor por ende la tasa de emisiones se dispara a diferencia de mantener un relieve plano durante las rutas.

Figura 18

Pendientes calculadas vehículo tipo Sedán



Nota: Gráfico que muestra las pendientes calculadas en la ruta que realiza el vehículo tipo Sedán.

Estos valores de pendientes fueron calculados bajo integración por el método trapezoidal, buscando valores más precisos y efectivos a la hora de su ingreso en la red neuronal. Cabe recalcar que el mismo método se aplicó para las pendientes de los tres tipos de vehículos: SEDAN, CROSSOVER y SUV.

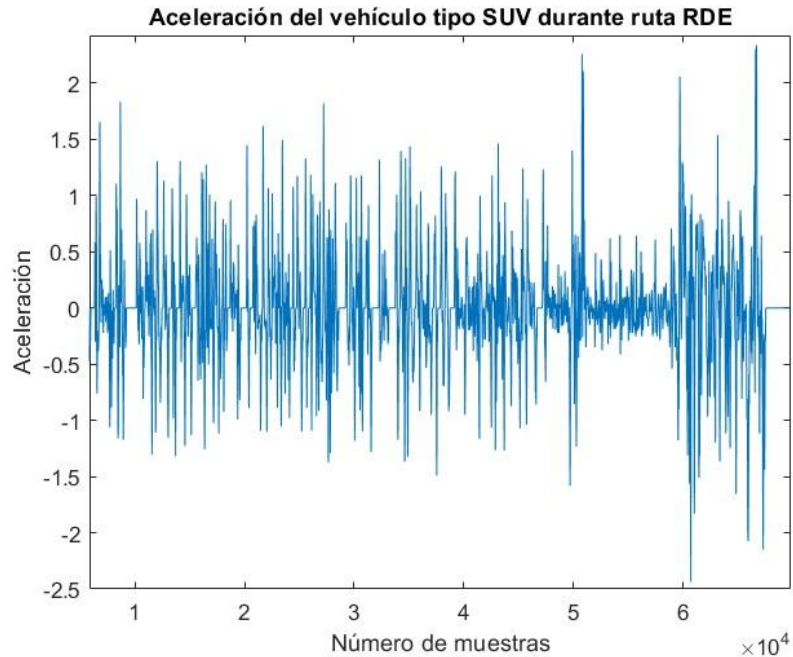
Determinación de las aceleraciones de cada vehículo en rutas RDE

Siguiendo el mismo principio de ir determinando nuevas variables para el entrenamiento de la red neuronal. Se agrupan funciones con el fin de obtener las aceleraciones que emiten los diferentes vehículos durante los trayectos o recorridos durante las rutas RDE. Retomando la lógica de intuición se sabe que, a mayor aceleración, el vehículo le exige al motor más potencia y torque elevando las RPM y todo esto volvería a desencadenar un incremento de factores de emisión. Sin embargo, más adelante se demostrará la teoría con índices estadísticos que generen los ensayos.

La aceleración al presentar una severa cantidad de picos durante estrechos periodos de tiempo, es importante filtrar dicho vector al igual que los parámetros de funcionamiento del vehículo. Con el fin de disminuir y suavizar errores de oscilación en el tiempo.

Figura 19

Aceleración vehículo tipo SUV



Nota: Gráfico que muestra la aceleración que tiene el vehículo SUV durante su distancia recorrida.

Correlación de variables

Al contar con un número alto de variables dentro de un estudio, como es el caso del presente proyecto que describe más de 20 parámetros de funcionamiento y variables geográficas como: latitud, altitud y longitud, se vuelve imprescindible hacer uso de la destreza de correlación de variables mediante matrices; con el fin de llegar a saber cuáles de estas son las más influyentes en el caso de estudio.

De manera previa a generar las matrices se hizo una selección de qué variables serían las menos influyentes en las salidas deseadas, para de esta manera desde primeras instancias ir reduciendo el

número de variables y lograr obtener valores considerables del grado de relación lineal entre dos variables conocido como factor de Pearson “R”.

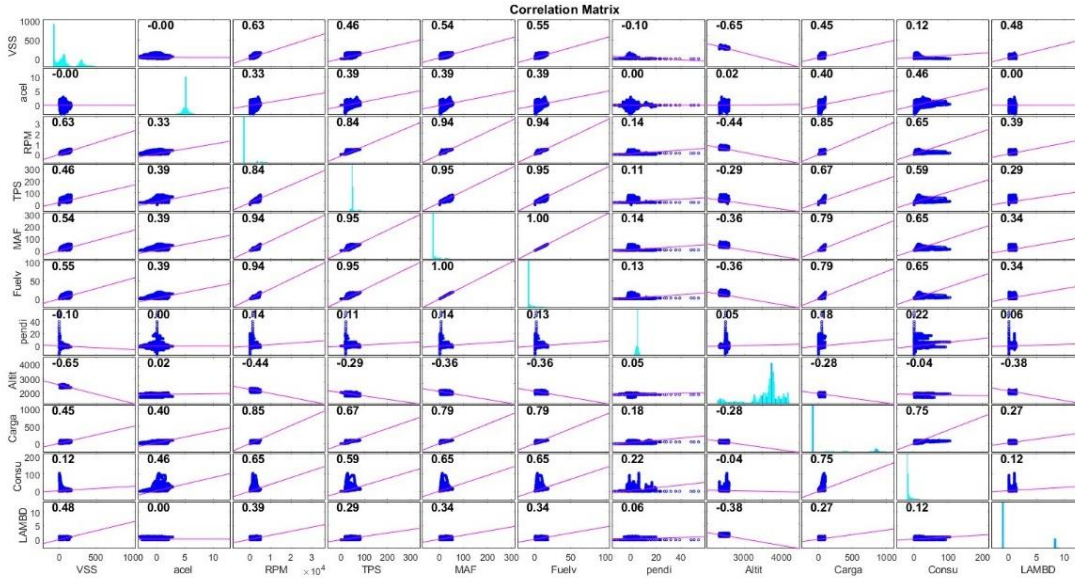
Cuando se lleva a cabo el análisis se pueden obtener un sin número de valores de correlación entre las variables, a continuación, se explica el significado dentro del rango (-1 a 1):

- Próximo a 1: indica una correlación perfecta positiva (las variables aumentan juntas linealmente).
- Próximo -1: indica una correlación perfecta negativa (una variable aumenta mientras la otra disminuye linealmente).
- Próximo a 0: indica falta de correlación lineal, por ende, debe ser dejada la variable de lado para el próximo estudio.

En primera instancia se analiza el consumo de combustible relacionando las variables más propensas a ser influyentes (en teoría). Como resultado se puede representar la siguiente matriz más compacta; identificando un menor número de variables, pero con valores de “R” próximos a la exactitud (1 o -1).

Figura 20

Matriz de correlación - Consumo



Nota: En la matriz se muestran las correlaciones entre todas las variables en un conjunto de datos., en donde se tomará las más influyentes en el consumo de combustible

Analíticamente hablando se observa en la matriz que el consumo de combustible instantáneo se ve directamente afectado por las variables de: RPM, TPS, MAF, Carga, Aceleración, Velocidad del combustible y Pendientes.

Tabla 10

Variables influyentes en el consumo de combustible.

Variable de estudio (entrada)	Valor “R”
RPM	[0.75]
Aceleración	[0.46]
TPS	[0.78]

MAF	[0.81]
Carga	[0.78]
Velocidad de combustible	[0.81]
Pendientes	[0.35]

Nota: En la tabla se presentan las variables más influyentes en el consumo de combustible con su respectivo valor de R.


Una vez se declara las variables más influyentes sobre la salida de consumo de combustible, se procede a realizar el análisis en los gases contaminantes que emite el mismo vehículo híbrido puesto a prueba durante la ruta RDE. Seccionamos el estudio de los gases para evitar una congestión de datos en la matriz diseñada por el software de Matlab, disminuyendo el riesgo de saturación informática.

A continuación, se identifican los gases altamente perjudiciales para el medio ambiente y la comunidad, específicamente los óxidos de carbono (CO) y los dióxidos de carbono (CO₂). Estos compuestos gaseosos, ampliamente reconocidos por su impacto negativo, son objeto de atención destacada debido a la creciente demanda de análisis e investigación en los ámbitos automotriz y ambiental.

Este interés se deriva de la necesidad de generar conciencia sobre los riesgos asociados y, en el mejor de los escenarios, proporcionar soluciones para mitigar las consecuencias adversas de su emisión.

Figura 21

Matriz de correlación - CO, CO2



Nota: En la matriz se muestran las correlaciones entre todas las variables en un conjunto de datos., en donde se tomará las más influyentes en el CO y CO2.

Las variables o parámetros de funcionamiento del vehículo, que en primeras instancias representan más relación con los gases CO y CO2 son los siguientes: VSS, RPM, TPS, MAF y carga.

Tabla 11

Variables más influyentes en CO y CO2


Variable de estudio (entrada)	Variable de respuesta (salida)	Valores “R”
VSS	CO - CO2	[0.37 - 0.53]
RPM	CO - CO2	[0.57 - 0.82]
TPS	CO - CO2	[0.61 - 0.89]
MAF	CO - CO2	[0.64 - 0.90]
Carga	CO	[0.40]

Nota: En la tabla se presentan las variables mas influyentes en el CO y CO2 con su respectivo valor de R.

Al finalizar la aplicación nos centramos en el estudio de las partículas de oxígeno, los hidrocarburos y los óxidos nitrosos; en la matriz introducimos las mismas variables de entrada que fueron para la variable de salida “Consumo de combustible”, con la finalidad de identificar variables de relación entre todas las salidas y en base a eso agrupar las semejantes como un solo grupo de entrada; Así ajustando un modelo de estimación general para los factores de emisión de los vehículos híbridos (previo al entrenamiento de la red neuronal).

Figura 22

Matriz de correlación - HC, NOx



Nota: En la matriz se muestran las correlaciones entre todas las variables en un conjunto de datos., en donde se tomará las más influyentes en HC y NOx.

La correlación entre los parámetros y variables relevantes se muestra a través de la matriz de correlación, identificando las influencias más significativas en las emisiones de hidrocarburos no combustionados y óxidos nitrosos.

En el análisis de hidrocarburos (HC), se observa que, aunque algunos parámetros no alcanzan valores elevados de coeficiente de correlación (R), ciertas variables como RPM, MAF, TPS y Carga tienen un mayor peso en las emisiones de HC.

En cuanto a los óxidos nitrosos, se destaca que las variables más relevantes son VSS, RPM, TPS, MAF y Carga, con valores significativamente altos de coeficiente de correlación en el rango de [0.44 a 0.80].

En la siguiente tabla los resultados del análisis de relación entre variables que otorgó la matriz de correlación:

Tabla 12

Variables más influyentes en HC y NOx

Variable de estudio (entrada)	Variable de respuesta (salida)	Valores “R”
RPM	HC – NOx	[0.49 - 0.74]
TPS	HC – NOx	[0.44 - 0.89]
MAF	HC – NOx	[0.50 - 0.80]
Carga	HC - NOx	[0.45 - 0.58]

Nota: En la tabla se presentan las variables mas influyentes en HC y NOx con su respectivo valor de R.

CAPITULO III: PROCESAMIENTO DE SEÑALES, ENTRENAMIENTO DE RED NEURONAL Y ANÁLISIS DE ESTIMACIONES DE LOS FACTORES DE EMISIÓN

Una vez se verificaron los datos conseguidos durante las diferentes pruebas de rutas RDE en los tres tipos de vehículos híbridos; se llevó a cabo un análisis minucioso del comportamiento de las variables destinadas a ser incorporadas en los entrenamientos de las prósperas redes neuronales, relacionando los conceptos y conocimientos teóricos con los índices estadísticos adquiridos en el campo práctico del presente proyecto experimental; contribuyendo a su vez a la mejora del rendimiento y la precisión del procesamiento de dichas técnicas asociadas al aprendizaje automático.

Teniendo en cuenta los diferentes valores de grados de relación obtenidos en las matrices de correlación de los parámetros de funcionamiento con las salidas, se logra observar que los los gases contaminantes mantienen una buena relación con diferentes parámetros obtenidos en recorridos normalizados dentro de la ciudad de Cuenca. Buscando el mejor camino se optó por desarrollar un entrenamiento de red neuronal por cada salida de estudio; distintos entre: “Consumo de Combustible”, “Monóxido de Carbono”, “Dióxido de Carbono”, “Hidrocarburos” y “Óxidos Nitrosos”.

De esta manera se evita inducir el margen de error existente en el procesamiento de estimación o predicción de una red en específico, en otra dedicada a una salida distinta (debido a que el coeficiente de determinación de algunas redes puede llegar a ser excelentes, mientras que en otras diferir su rendimiento entre notable a regular).

Inclusión de vector de velocidad y aceleración.

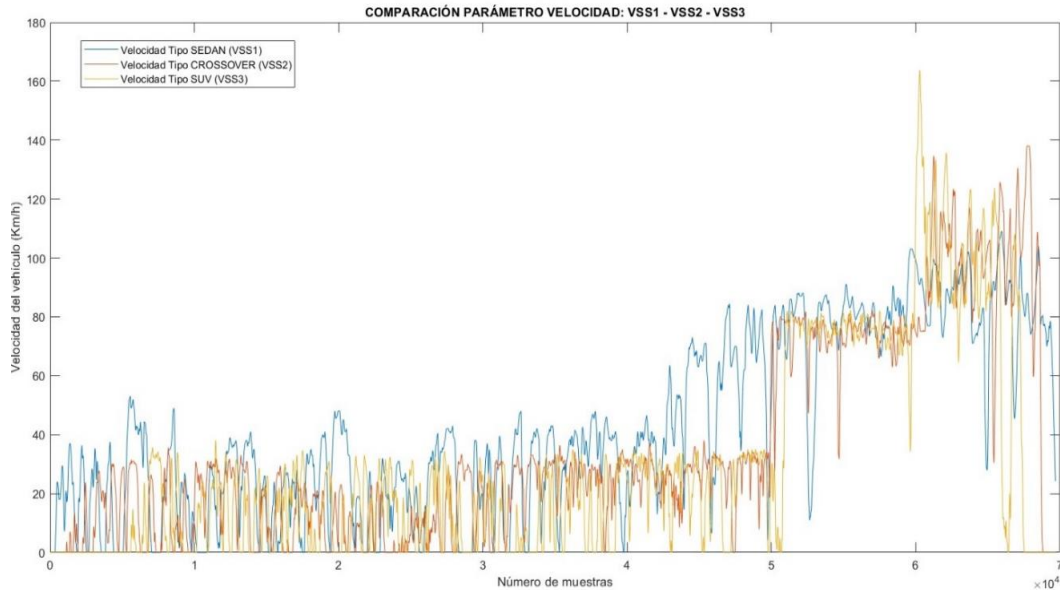
Los vectores de velocidad (VSS) y aceleración (acel), en primeras instancias, guiándose por el grado de relación con las variables de salida “R” en la matriz de correlación, no demuestran influencia o importancia como para tener estos mismos parámetros en la matriz de entrada de los diferentes entrenamientos de las redes neuronales artificiales. Sin embargo, realizando un análisis profundo a detalle y ligando conceptos automotrices basados en la relación existente entre el funcionamiento del motor con los factores de emisión, se reconoce que siempre va a estar fuertemente ligada la aceleración y la velocidad con los gases contaminantes que emita un vehículo.

En el marco de la etapa de investigación de campo, el error de la existencia de un deficiente grado de relación para el vector de velocidad con las diferentes salidas de cada una de las matrices de correlación (simulando una clara discrepancia en la conexión de entradas con salidas) se debe a las siguientes circunstancias:

- El vehículo tipo SEDAN durante la prueba de ruta RDE (en el cual se adquieren los parámetros de funcionamiento, incluidos velocidad y matemáticamente aceleración) no supera los 109 Km/h como velocidad máxima a diferencia de los vehículos tipo CROSSOVER Y SUV que mostraron valores de 138 Km/h y 164 Km/h, respectivamente.
- En las zonas de trayecto urbano y rural, las velocidades del SEDAN se encuentran oscilando muy por encima del resto de vehículos, marcando un rango de diferencia notable desde la perspectiva gráfica. Sin duda dicha discrepancia de rangos afecta de manera severa en la correlación de datos y la predicción de las redes neuronales, sabiendo que el vector “VSS” es constante en cada una de las matrices de entrada.

Figura 23

Comparación del vector "VSS" de cada tipo de vehículo



Nota: En la gráfica se presenta una comparación de la velocidad de los tres tipos de vehículos en sus respectivas rutas RDE.

En primeras instancias, se reconoce que la aceleración constituye una expresión matemática relacionada con la velocidad. Por ende, cualquier discrepancia detectada por el vector de velocidad en el contexto de la matriz de correlación y durante el proceso de entrenamiento de la red se verá reflejada en la aceleración. En este sentido, es crucial destacar que este fenómeno resalta la interdependencia entre ambas variables, evidenciando cómo las imprecisiones en la velocidad pueden incidir directamente en la determinación de la aceleración.

Analizando desde la configuración híbrida del tren propulsor vehicular, se tiene en consideración cuatro aspectos que describen perfectamente el fenómeno del bajo y débil grado de relación entre la aceleración con el consumo y las emisiones contaminantes relacionadas con la partícula química del carbono (Monóxido de Carbono y Dióxido de Carbono):

- Modos de funcionamiento del motor: Los vehículos híbridos tienen diferentes modos de funcionamiento por parte del motor independientemente de la configuración que posea (serie – paralelo – mixto). En situaciones baja de carga el MCI puede apagarse mientras el vehículo se desplaza mediante la energía que provee las baterías eléctricas de alto voltaje. Como resultado el parámetro de aceleración vehicular marcaría un ascenso mientras que las emisiones se mantendrían bajas o nulas por no estar el MCI funcionando o encendido.
- Recuperación de energía: Actualmente el MCI no es únicamente utilizado para la tracción del vehículo, sino también para cargar las baterías mediante la frenada regenerativa. Por lo tanto, la carga del motor no estará directamente vinculada a la aceleración.
- Gestión del sistema híbrido: Con las nuevas tecnologías de los vehículos, se tiene ahora una gestión autónoma hablando del motor de MCI. La gestión de estos sistemas puede hacer que el motor se apague y encienda independientemente de la demanda de la aceleración.
- Condiciones de conducción: En tráfico urbano con presencia de paradas y arranques, el sistema híbrido y su gestión autónoma puede accionar el uso y modo del motor eléctrico, afectando de esta manera la correlación entre el vector de aceleración y las emisiones de gases contaminantes.

Asignación de variables en redes neuronales artificiales (RNA).

Previo al desarrollo del primer entrenamiento de la red neuronal; el cual está dirigido a la primera salida de estudio (Consumo de Combustible). Basándose ampliamente en los resultados otorgados por la matriz de correlación; además de las consideraciones analizadas anteriormente acerca de los vectores de velocidad y aceleración... se agruparon las siguientes variables en una matriz de entrada para el entrenamiento correspondiente:

Tabla 13*Variables involucradas en el primer entrenamiento de RNA*

Matriz parámetros (entrada)	Matriz de salida
Tipo de vehículo	Consumo de combustible
VSS	Consumo de combustible
RPM	Consumo de combustible
Aceleración	Consumo de combustible
MAF	Consumo de combustible
Altitud	Consumo de combustible

Nota: En la tabla se nombran las entradas en el primer entrenamiento de la red neuronal (Consumo). Fuente: Autores

Desde el segundo entrenamiento de red neuronal artificial, comienza el enfoque dedicado a los gases contaminantes. A continuación, se presentan la asignación de variables del CO:

Tabla 14*Variables involucradas en el segundo entrenamiento de RNA*

Matriz parámetros (entrada)	Matriz de salida
Tipo de vehículo	CO
VSS	CO
RPM	CO
TPS	CO
MAF	CO
Carga	CO

Nota: En la tabla se nombran las entradas en el segundo entrenamiento de la red neuronal (CO).

Fuente: Autores

La asignación de parámetros de funcionamiento de los vehículos en la matriz de entradas de la tercera red neuronal es idéntica a la segunda. Pues en la matriz de correlación se evidencia la similitud entorno a la relación de variables. Bajo esa consideración, se evidencian las siguientes matrices dedicadas a la red con propósito de estimar Dióxidos de Carbono (CO2):

Tabla 15

Variables involucradas en el tercer entrenamiento de RNA

Matriz parámetros (entrada)	Matriz de salida
Tipo de vehículo	CO2
VSS	CO2
RPM	CO2
TPS	CO2
MAF	CO2

Nota: En la tabla se nombran las entradas en el segundo entrenamiento de la red neuronal (CO2).

Fuente: Autores

Las matrices de entrada y salida de la cuarta y quinta red neuronal artificial, cuentan con un leve cambio en las variables asignadas; puesto que se introducen variables sometidas a procesos de normalización (con el fin de generar un mejor coeficiente de determinación en la etapa del entrenamiento correspondiente a cada una de ellas). Por lo tanto, las matrices de la RNA dedicada a estimar los Hidrocarburos (HC) dependientes de múltiples parámetros de funcionamiento vehicular; se muestra de la siguiente manera:

Tabla 16*VARIABLES INVOLUCRADAS EN EL CUARTO ENTRENAMIENTO DE RNA*

Matriz parámetros (entrada)	Matriz de salida
Tipo de vehículo	HC
RPM_nor	HC
Aceleracion_nor	HC
TPSnor	HC
MAF_nor	HC
Carga_nor	HC

Nota: En la tabla se nombran las entradas en el segundo entrenamiento de la red neuronal (HC).

Fuente: Autores

Para la quinta red neuronal, se mantiene el lineamiento de asignar variables normalizadas para la matriz de entrada como para la matriz de salida. El enfoque de esta RNA está dirigido al CO₂:

Tabla 17*VARIABLES INVOLUCRADAS EN EL QUINTO ENTRENAMIENTO DE RNA*

Matriz parámetros (entrada)	Matriz de salida
Tipo de vehículo	NOx
Aceleracion_nor	NOx
RPM_nor	NOx
TPS_nor	NOx
MAF_nor	NOx
Carga_nor	Nox

Nota: En la tabla se nombran las entradas en el segundo entrenamiento de la red neuronal (NOx).

Fuente: Autores

Estrategias estadísticas en incremento de coeficientes de determinación

Existe una amplia variedad de métodos y habilidades vinculadas a los fundamentos del ámbito estadístico, que se emplean de manera habitual en el preprocesamiento de datos bajo aplicaciones de aprendizaje automático, como redes neuronales o árboles de clasificación. El objetivo principal es incrementar la correlación entre las variables de entrada y las de salida, o en términos generales, mejorar la calidad de los resultados estimados o predichos, creando una aproximación alta hacia los datos de gases contaminantes reales obtenidos mediante los ensayos cinéticos.

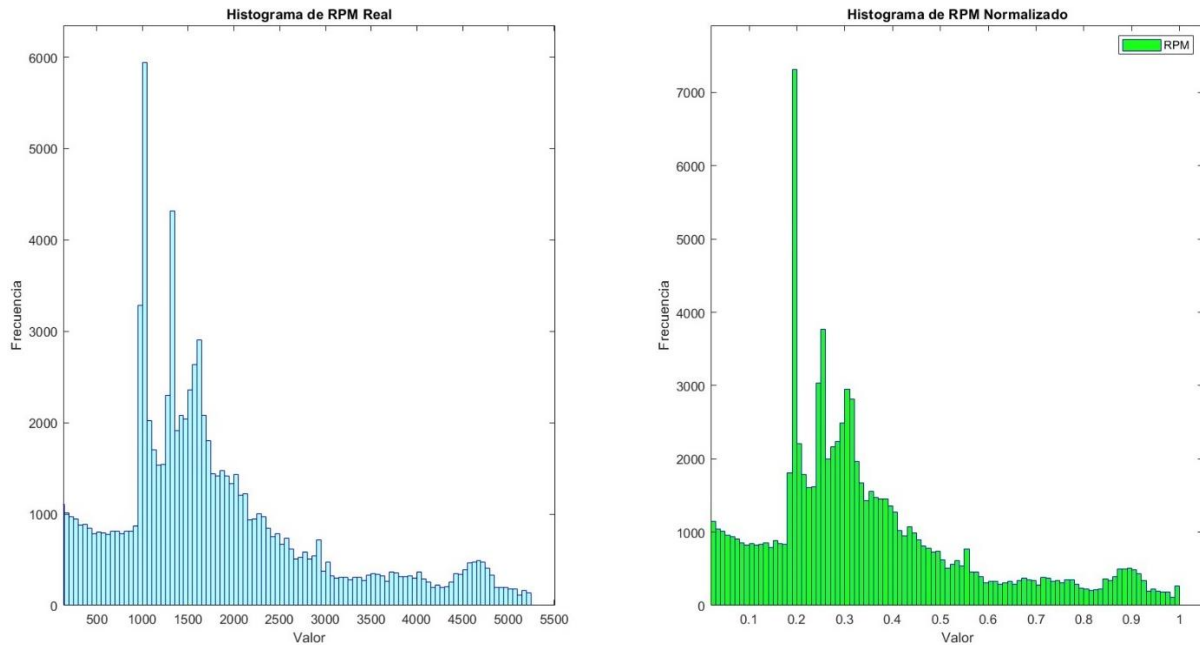
Durante el primer, segundo y tercer entrenamiento de la Red Neuronal Artificial (RNA), se empleó una técnica casera que implicó la exclusión de las primeras capturas de datos de cada parámetro de funcionamiento del motor y vehículo en las señales PID generadas por instrumentos de medición automotrices (OBDLink MX, Freematics ONE+, KANE LIVE). Justificando que, al ser equipos de naturaleza inalámbrica y alto margen de error en relación a la sensibilidad de las calibraciones, se argumenta que era necesario establecer un periodo inicial de reposo para posteriormente comenzar a obtener índices de datos más cercanos a la realidad.

En contraste, previo a realizar el proceso del cuarto y quinto entrenamiento de RNA, se implementó la estrategia conocida como "normalización al máximo". Esta metodología se enfoca en identificar, para cada variable o parámetro de entrada-salida del entrenamiento, su valor o cifra máxima. Posteriormente, se procede a dividir cada dato por dicho valor máximo. Este enfoque tiene como resultado que el rango de valores en toda la serie estadística se sitúe entre [0 - 1], lo que mejora la eficacia y precisión del procesamiento de datos al estimar o validar los resultados obtenidos.

En la siguiente figura se muestra una comparación clara entre los datos reales con los normalizados bajo la habilidad de la división por el máximo, descrita en el último párrafo:

Figura 24

Comparación de RPM real vs normalizada



Nota: En la figura se presenta una comparación entre una variable (RPM) real vs normalizada.

La gráfica compete a la variable de RPM ya que es simplemente una muestra y representación bajo histogramas de la normalización que se llevó a cabo en cada una de las variables de entrada y salida de la cuarta y quinta red neuronal artificial.

En la mayoría de histogramas (de datos reales vs normalizados) el valor que más números de muestras compete es cero, debido a los tiempos de parada asociados con diversas situaciones durante las rutas RDE: los semáforos, tráfico vehicular y actos de ceder el paso. Sin embargo, este valor no se muestra con el afán de observar de mejor manera el resto de barras estadísticas.

Al normalizar por este método estadístico se guarda en un vector los valores máximos de cada una de las variables dispuestas aplicar dicha estrategia; con el fin de volver a multiplicar por el mismo

una vez se realiza el proceso de “entrenamiento – validación – estimación” para conseguir como resultados valores acordes al rango natural tomado durante la adquisición de datos.

Variable clasificatoria de entrada para el tipo de vehículo.

En las matrices de entrada de los entrenamientos de las redes neuronales, una variable es dedicada a ubicar el tipo de vehículo del cual se piensa estimar los gases contaminantes deseadas. En la mayoría de los estudios, análisis y proyectos que se centran en la clasificación vehicular, suelen emplear un solo vector para diferenciar los diversos tipos de vehículos. No obstante, con el objetivo de lograr una clasificación automática más precisa durante las fases de entrenamiento o validación, se ha decidido adoptar una medida teóricamente confiable basada en los principios estadísticos. Esta elección se sustenta en la búsqueda de una mayor exactitud y fiabilidad en el proceso de clasificación, reconociendo la importancia de considerar aspectos estadísticos para mejorar la robustez y precisión del modelo.

Se usó una clasificación binaria en la cual se crearon tres vectores para que cada uno represente una clase de vehículo dentro de la tipología descrita durante el proceso de adquisición de datos. El primer vector se liga al tipo de automóviles SEDAN, independientemente de la cilindrada del motor MCI (basándose mayormente en su forma de carrocería). El segundo vector se destina a interactuar con la tanda de datos pertenecientes al tipo de vehículos CROSSOVER, el cual es una clase nueva en el mercado de los últimos años y es la combinación de especificaciones técnicas y físicas entre un SEDAN y SUV (o bien entre un SEDAN y HATCHBACK); mientras que el tercer y último vector representa al tipo de vehículos SUV, el cual posee características más robustas y de mayor dimensionamiento.

En esta clasificación los únicos valores que toman las tres variables son cifras de (0) y (1). En cada procesamiento de validación solo existirá un vector con valores de (1) entre los tres clasificadores,

determinando o ubicando de esta manera el tipo de vehículo del cual se está haciendo el análisis y estudio bajo lineamientos referentes al aprendizaje automático.

Entrenamiento de las redes neuronales artificiales (RNA)

Los datos destinados a los procesos de las diversas redes neuronales se distribuyen en tres fases arbitrariamente designadas: entrenamiento, validación y prueba. La distribución de datos mantiene proporciones similares en todas las redes neuronales; debido a que, los porcentajes en cada fase de procesamiento han sido seleccionados de manera óptima con el fin de garantizar su integridad. Esta proporción de datos se optó bajo el objetivo de optimizar el rendimiento y la calidad de cada red neuronal, garantizando así resultados coherentes y confiables en todo el proceso de análisis. A continuación, se presentan las cifras tabuladas correspondientes a cada una de estas etapas de procesamiento:

Tabla 18

Proporción de datos para las etapas de procesamiento en las RNA

Etapas de procesamiento	Porcentaje de datos (%)
Entrenamiento de la RNA	70
Validación de datos	15
Testeo o prueba de resultados	15


Nota: En la tabla se evidencia la proporción de datos que se usan en las etapas de procesamiento de las redes neuronales artificiales.

Los diseños bases y generalizados de redes neuronales artificiales, árboles clasificadores o algoritmos usan la proporción de datos descrita anteriormente; estos son valores que siempre otorgan un procesamiento de calidad y alto nivel con una positiva relación en los resultados entre

la eficacia y la eficiencia. De igual manera se atribuye tres conjuntos de capas en la arquitectura de la red neuronal, la de entrada, salida y las ocultas. Con el formal avance de las investigaciones bajo el uso de aprendizaje automático se conoce que el incremento del número de neuronas en las capas ocultas dentro de una RNA o destrezas similares, mejora directa o indirectamente la precisión y eficacia a la hora de estimar, más aún cuando existe un número grande de entradas como en el presente estudio que se cuenta nueve de ellas (comprendidas por parámetros de funcionamiento y los clasificadores del tipo de vehículo); además de captar de mejor manera el comportamiento no lineal entre la entrada y la salida. Las estructuras de las redes neuronales artificiales presentes del estudio varían en el número de variables o parámetros de entrada, salida, capas ocultas y neuronas implicadas en las mismas. La primera RNA cuenta con una única capa oculta en su diseño, en la siguiente figura se muestra la arquitectura de la red para una mejor interpretación de la relación e interacción entre capas y neuronas:

Figura 25

Arquitectura - Estructura de la primera RNA (Consumo)




Nota: En la figura se presenta un diagrama de la primera red neuronal (Consumo). Fuente:

Autores

La segunda y tercera RNA son similares entorno al número de capas ocultas y variables involucradas en la matriz de entrada. Cuentan con dos capas ocultas, en las cuales cada una de ellas registra una cifra de 20 neuronas. Su enfoque se da directamente a los gases CO y CO2.

Figura 26


Arquitectura - Estructura de la segunda RNA (CO)



Nota: En la figura se presenta un diagrama de la segunda red neuronal (CO). Fuente: Autores

Figura 27

Arquitectura - Estructura de la tercera RNA (CO2)

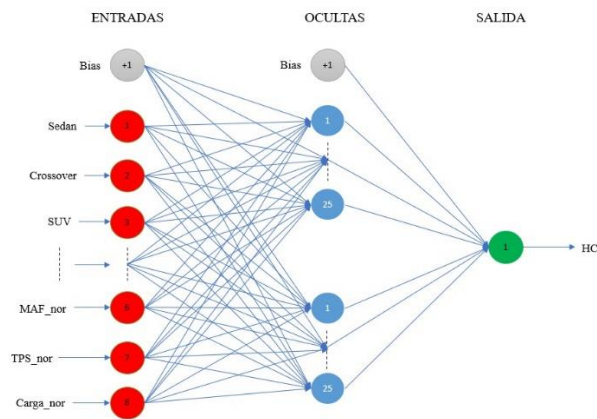


Nota: En la figura se presenta un diagrama de la tercera red neuronal (CO2). Fuente: Autores

Las dos redes neuronales finales que se presentan a continuación están dedicadas a estimar los Hidrocarburos (HC) y Óxidos Nitrosos (NOx). El comportamiento de estos gases contaminantes depende de una gran cantidad de factores. Las RNA elevan a 25 las neuronas en las capas ocultas.

Figura 28


Arquitectura - Estructura de la cuarta RNA (HC)



Nota: En la figura se presenta un diagrama de la cuarta red neuronal (HC). Fuente: Autores

Figura 29

Arquitectura - Estructura de la quinta RNA (NOx)



Nota: En la figura se presenta un diagrama de la quinta red neuronal (NOx). Fuente: Autores

La relevancia de los parámetros o atributos de procesamiento en cada Red Neuronal Artificial (RNA) se destaca debido a su impacto significativo en los resultados obtenidos. Estos factores abarcan aspectos como la partición de datos, el tipo de entrenamiento, los rendimientos y los cálculos realizados.

En la tabla adjunta, se detallan los métodos y las categorías de características empleados por las cinco redes neuronales que se aplicarán en el proyecto vinculado al estudio de gases contaminantes, proporcionando una visión más completa de su funcionalidad y aplicabilidad en este contexto específico.

Tabla 19

Especificaciones de entrenamiento en las redes neuronales.

Especificaciones de entrenamiento	Descripción
Data Division	Random
Training	Levenberg - Marquardt
Performance	MSE – Mean Squared Error
Calculations	MEX

Nota: En la tabla se presentan las especificaciones del entrenamiento de las redes neuronales.

Fuente: Autores

Describiendo el contexto de la tabla 19 se menciona que la división de datos se realiza mediante una selección aleatoria (Random) con las proporciones mencionadas anteriormente. El tipo de entrenamiento se da por el método Levenberg – Marquardt, el cual actualiza los valores de peso y sesgo de acuerdo con la optimización de Levenberg-Marquardt.

Este entrenamiento es, con frecuencia, el algoritmo de entrenamiento más rápido, a pesar de que requiere más memoria que otras técnicas. (N. D. Rivera-Campoverde et al., 2021)

El rendimiento de la RNA se mide a través del comportamiento del error cuadrático medio (MSE) durante las épocas de procesamiento hasta encontrar su punto óptimo de estabilización (señalando un modelo eficaz y preciso). Los cálculos se desarrollan a través de MEX por ser una estrategia eficiente en memoria al tratar con un entrenamiento robusto. (Néstor Diego et al., 2021)

Una vez se completa el entrenamiento de cada una de las redes neuronales artificiales, se comienza a analizar las figuras resultantes que emite el software (concernientes a las especificaciones vistas en la tabla 19); por lo tanto en los próximos gráficos se presentan diferentes análisis relacionados con los histogramas de errores en procesos de entrenamiento, comportamientos en curvas de los errores medios cuadráticos junto a la curva de disminución gradual de cada uno de los gradientes y por último las regresiones lineales que determinan los coeficientes de determinación R.

Histogramas de errores en procesos de entrenamiento, validación y testeo.

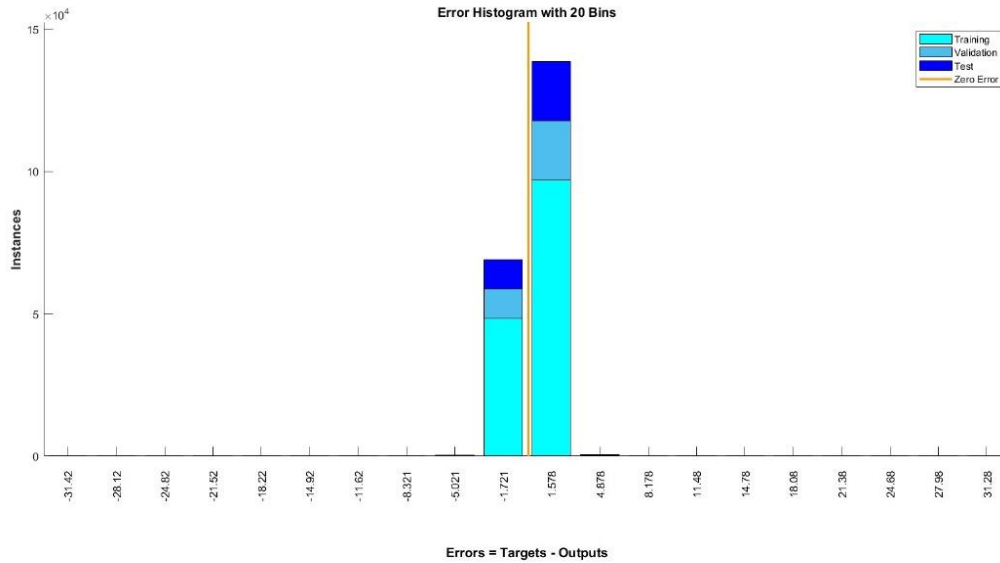
La representación gráfica que muestra la distribución de errores a lo largo del entrenamiento desempeña un papel crucial en la evaluación de la eficacia y convergencia del modelo.

Los histogramas representan en el eje horizontal el valor o cifra de error, mientras que en el eje vertical se ubican las instancias, frecuencias o número de veces que se repite dicho valor.

Se grafican en cada barra los errores presentes en las etapas de: entrenamiento, validación y prueba; además de ubicar en una constante la línea de error nulo o cero.

Figura 30

Histograma de errores - RNA (Consumo)




Nota: En la figura se observa un histograma de errores de la primera red neuronal (Consumo).

Durante el primer entrenamiento, con el Consumo de Combustible como variable de salida, se evidencia una distribución de errores donde las frecuencias más altas se concentran en valores cercanos a cero, particularmente en el intervalo de [-1.721, 1.578].

Además, se observa que los errores que se apartan más significativamente de cero están limitados a un rango aproximado de [-5.021, 4.878]. Es relevante señalar que esta tendencia se mantiene consistente tanto en los conjuntos de datos de entrenamiento como en los conjuntos de validación y prueba, lo que sugiere una estabilidad en el comportamiento del modelo a lo largo de diferentes conjuntos de datos.

Figura 31

Histograma de errores - RNA (CO)




Nota: En la figura se observa un histograma de errores de la segunda red neuronal (CO).

En la segunda red neuronal presentada, se observa que la frecuencia más alta de errores, alcanzando un valor de 18×10^4 , se concentra en valores cercanos a -0.00202 y -0.003722.

Es crucial destacar que este número de instancias o frecuencia de errores abarca todas las etapas del proceso generalizado, incluyendo el entrenamiento de la red neuronal, la validación de su desempeño y la evaluación final mediante pruebas. Este hallazgo señala la importancia de abordar específicamente estos rangos de valores durante el diseño y ajuste de la red neuronal, con el objetivo de optimizar su rendimiento global en diferentes fases del proceso analítico.

Figura 32

Histograma de errores - RNA (CO2)




Nota: En la figura se observa un histograma de errores de la tercera red neuronal (CO2).

Continuando con el enfoque en la red neuronal relacionada con los niveles de Dióxido de Carbono (CO₂), se observa que la frecuencia más alta alcanza los 15×10^4 (aproximadamente) para errores cercanos a -0.2526. En contraste con otros histogramas, el presente muestra una distribución no singular de errores con frecuencia alta. Se identifica un rango de errores con un número significativo de muestras, que oscila entre -1.455 y 1.551.

Un análisis adicional revela que los valores de los errores se desvían del índice nulo (error cero), indicando claramente un rendimiento notable en el entrenamiento de la red neuronal, en contraposición al desempeño de otras RNA. Esta divergencia de los errores del valor nulo sugiere un proceso de entrenamiento más efectivo y una mayor capacidad de la red para capturar la complejidad de los datos relacionados con el CO₂.

Figura 33

Histograma de errores - RNA (HC)

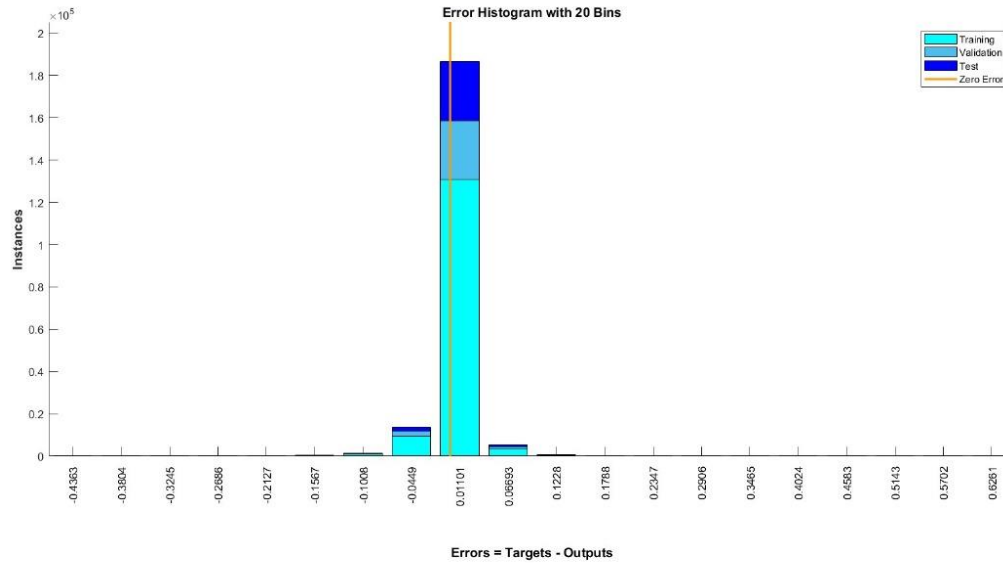


Nota: En la figura se observa un histograma de errores de la cuarta red neuronal (HC).

La cuarta iteración de la red neuronal diseñada para la estimación de Hidrocarburos (HC) incorpora matrices de variables normalizadas tanto para la entrada como para la salida de datos. Esta estrategia contribuye a la estabilización del comportamiento de los errores de esta red. Se observa una frecuencia máxima de errores de aproximadamente 16×10^4 , concentrándose principalmente alrededor del valor de -0.02753. Además, el análisis revela un rango general de errores dentro del intervalo [-0.08749 , 0.09239]. Este histograma de errores representa la disparidad entre los valores reales de HC y las predicciones generadas por la red neuronal artificial.

Figura 34

Histograma de errores - RNA (NOx)



Nota: En la figura se observa un histograma de errores de la quinta red neuronal (Nox)


La quinta red muestra su frecuencia más alta de 2×10^5 en errores cercanos al 0.01101; este número de instancias o frecuencia compete a todo el proceso generalizado. Cabe recalcar que al tener la mayoría de instancias erróneas agrupadas en cifras similares al cero, predice un buen rendimiento del entrenamiento. El intervalo general de errores producidos durante el entrenamiento de toda la red con salida de estudio en relación a los Óxidos Nitrosos (NOx) se aproximan a un rango de [-0.0449 , 0.06693].

Comportamientos de los MSE durante las épocas de entrenamiento.

El error cuadrático medio (MSE) evoluciona a medida que el entrenamiento de la red realiza su procesamiento. Es importante analizar puntos donde comienza a estabilizarse o volverse constante este parámetro para determinar con ello si la RNA es de calidad y útil para experimentos de campo.

Figura 35

Comportamiento del error cuadrático medio - RNA (Consumo)

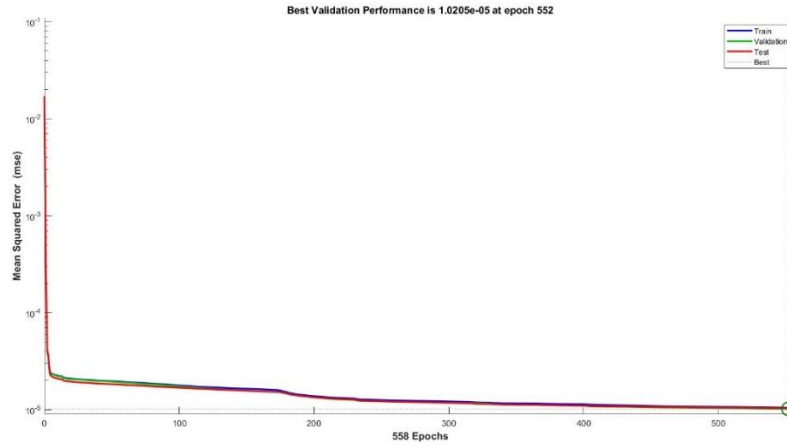


Nota: En la gráfica se observa el comportamiento del error cuadrático medio en RNA (Consumo).

Se presentan tres curvas de comportamiento del Error Cuadrático Medio (MSE, por sus siglas en inglés "Mean Squared Error") a lo largo de 507 épocas de entrenamiento. Cada curva corresponde a una etapa diferente del procesamiento. Se observa que el MSE alcanza un estado estable después de la época 400, indicando que la red neuronal ha alcanzado un nivel de eficiencia y efectividad notable en sus estimaciones. El punto de mayor rendimiento de validación, alcanzado en la época 501, se registra con un valor de 0.68282, lo que sugiere un desempeño destacado en la capacidad de generalización del modelo. Este dato resalta la capacidad de la red neuronal para ajustarse adecuadamente a los datos de validación, lo que es crucial para su aplicabilidad en entornos del mundo real.

Figura 36

Comportamiento del error cuadrático medio - RNA (CO)

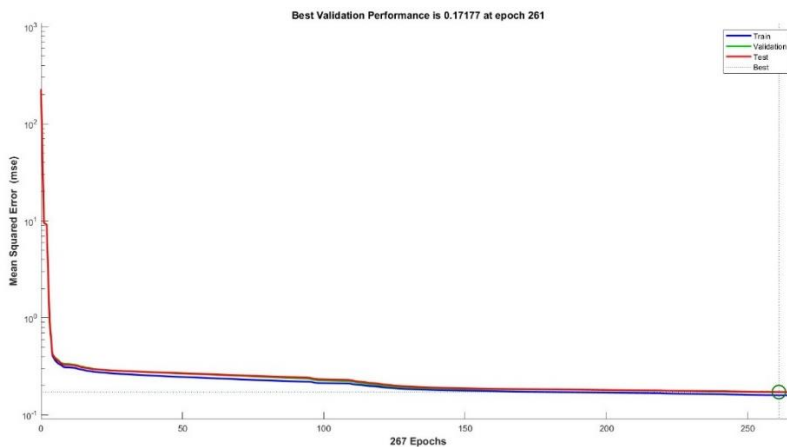


Nota: En la gráfica se observa el comportamiento del error cuadrático medio en RNA (CO).

La segunda iteración de la red neuronal artificial requirió un ciclo de 552 épocas para alcanzar su óptimo desempeño. En este punto, se identifica un valor de Precisión de Validación del Modelo (PVM) de 0.0000102, lo que indica una mejora significativa en la capacidad predictiva del modelo.

Figura 37

Comportamiento del error cuadrático medio - RNA (CO₂)



Nota: En la gráfica se observa el comportamiento del error cuadrático medio en RNA (CO₂).


Para la red neuronal focalizada para predecir los Dióxidos de Carbono (CO₂), el software emitió un periodo de 186 épocas para alcanzar un punto de equilibrio entre la eficacia y el rendimiento del modelo. Describe un coeficiente del mejor rendimiento en validación de 8.918; el cual es relativamente alto a comparación del resto de redes neuronales.

Si se sabe que mientras más próximo esté del cero absoluto, mayor calidad de procesamiento se efectuará; teniendo en cuenta esta característica en la red se induce a la presencia de un modelo no muy óptimo en relación al desarrollo del resto de RNA.

A lo largo del entrenamiento se denota que desde la época 100 comienza a estabilizarse el procesamiento de la RNA.

Figura 38

Comportamiento del error cuadrático medio - RNA (HC)




Nota: En la gráfica se observa el comportamiento del error cuadrático medio en RNA (HC).

Para este caso del comportamiento del error cuadrático medio en la red neuronal de HC se observa una similitud al modelo del aprendizaje automático. En donde, se registró la mejor validación en la época 209 alcanzando un valor de R de 0.0011315.

Figura 39

Comportamiento del error cuadrático medio - RNA (NOx)



Nota: En la gráfica se observa el comportamiento del error cuadrático medio en RNA (HC).

El último comportamiento del error medio cuadrático correspondiente a la quinta red neuronal, otorga de manera visual un buen prospecto de rendimiento por parte del modelo entrenado. A esta RNA le tomó un periodo de 331 épocas para alcanzar el menor error medio cuadrático posible, el mismo que describe un valor de 0.00065495.


Gradientes del periodo de entrenamiento de las distintas RNA.

El gradiente del entrenamiento desempeña un papel esencial en los algoritmos de optimización utilizados para modificar los parámetros de un modelo con el objetivo de reducir una función de pérdida. Indica la dirección en la cual los parámetros deben ajustarse, además de la magnitud del cambio más significativo en la función de pérdida con respecto a esos parámetros. Durante el proceso de entrenamiento de una red neuronal, se busca ajustar los pesos y sesgos de las conexiones entre las neuronas con el fin de minimizar la discrepancia entre las predicciones del modelo y las etiquetas reales de los datos de entrenamiento. La retro propagación (backpropagation) emerge como la técnica principal para llevar a cabo este ajuste. En este proceso,

el gradiente del entrenamiento es instrumental, ya que se utiliza para calcular cómo los errores en las predicciones deben retroceder a través de la red, permitiendo así ajustar los parámetros de manera eficaz. (N. Rivera-Campoverde et al., 2022). El gradiente muestra su disminución a lo largo del entrenamiento. Lo ideal dentro de este factor es que la disminución se vuelva gradual (similar). La derivada de la curva entre el MSE y el número de épocas en la red neuronal, es la variable presente denominada gradiente. A continuación se presentan las figuras correspondientes:

Figura 40


Gradiente de entrenamiento RNA - Consumo



Nota: En la gráfica se observa el gradiente relacionado al entrenamiento de la RNA (Consumo)

Figura 41


Gradiente de entrenamiento RNA - CO



Nota: En la gráfica se observa el gradiente relacionado al entrenamiento de la RNA (CO)

Figura 42


Gradiente de entrenamiento RNA - CO2



Nota: En la gráfica se observa el gradiente relacionado al entrenamiento de la RNA (CO2)

Figura 43


Gradiente de entrenamiento RNA - HC



Nota: En la gráfica se observa el gradiente relacionado al entrenamiento de la RNA (HC)

Figura 44

Gradiente de entrenamiento RNA - NOx




Nota: En la gráfica se observa el gradiente relacionado al entrenamiento de la RNA (NOx)

Coeficientes de determinación (R) en cada red neuronal.

El software de ingeniería MATLAB genera cuatro coeficientes de determinación (R) después de completar el procesamiento de la red neuronal. Se proporciona un coeficiente para cada fase del proceso (entrenamiento, validación, prueba) y uno general que representa el análisis global de la RNA (All: R). Estos coeficientes se consideran aceptables cuando alcanzan valores iguales o superiores a 0.60; a medida que aumentan, mejoran la eficacia y precisión del modelo de aprendizaje automático ajustado en el programa.

Figura 45

Coeficientes de determinación implicados en RNA (Consumo)




Nota: En la gráfica se observan los coeficientes de determinación implicados en RNA (Consumo)

En la primera red neuronal focalizada al estudio del consumo de combustible se tiene de resultante los siguientes coeficientes de determinación de 0.99566, 0.99537, 0.99546 y 0.99558 asociados a las etapas de entrenamiento, validación, prueba y global (respectivamente), se destaca y representa la robustez de la modelización estadística. Describiendo textualmente los índices estadísticos obtenidos por los diferentes procesos involucrados en el entrenamiento de la red, se consigue un excelente modelo capaz de llegar a estimar de manera precisa y con muy bajo margen de error la primera salida de estudio.

Figura 46

Coefficientes de determinación implicados en RNA (CO)




Nota: En la gráfica se observan los coeficientes de determinación implicados en RNA (CO)

En comparación con el entrenamiento inicial de la red neuronal, en esta segunda red neuronal se mantienen coeficientes de determinación con valores altos, específicamente 0.97293, 0.97381, 0.97295 y 0.97307. Estos resultados indican la solidez y viabilidad del modelo de aprendizaje automático empleado. Esto se sustenta en la literatura científica, donde numerosos estudios han establecido que valores de R alrededor de 0.97 son comunes y pueden asegurar la confiabilidad de la red neuronal en el contexto de la aplicación de redes neuronales e inteligencia artificial en el estudio de emisiones contaminantes generadas por fuentes móviles.

Figura 47

Coefficientes de determinación implicados en RNA (CO2)




Nota: En la gráfica se observan los coeficientes de determinación implicados en RNA (CO2)

En la red neuronal dedicada a la estimación y análisis de los dióxidos de carbono. Se muestran coeficientes de determinación de 0.97512, 0.97196, 0.97303 y 0.97435 asociados a las etapas de entrenamiento, validación, prueba y global. Las cifras se mantienen altas comparando con los entrenamientos de las redes neuronales anteriores.

Figura 48

Coeficientes de determinación implicados en RNA (HC)




Nota: En la gráfica se observan los coeficientes de determinación implicados en RNA (HC)

Se sabe por conceptos teóricos e investigaciones relacionadas con el mismo campo experimental del proyecto de estudio, que los hidrocarburos (HC) son de los gases más complejos para estimar con aprendizaje automático (redes neuronales). Motivo por el cual se normalizaron las variables de entrada y salida del entrenamiento; además de aumentar el número de neuronas por capa oculta. Teniendo esos lineamientos de proceso la RNA logra los coeficientes de determinación de 0.84919, 0.82076, 0.82704 y 0.84161.

Figura 49

Coefficientes de determinación implicados en RNA (NOx)



Nota: En la gráfica se observan los coeficientes de determinación implicados en RNA (NOx)

En el entrenamiento de la quinta y última red neuronal, se vuelve a alzar el promedio de coeficientes de determinación. Los valores obtenidos son: 0.94566, 0.94108, 0.93444 y 0.94333 respectivos a cada etapa del procesamiento de la RNA. Estas cifras sobrepasan el rango de 0.90 induciendo que los resultados estimados o predecidos por dicho modelo serán sólidos y eficientes, al igual que la primera y segunda red estudiada.


Este modelo que involucra la salida de estudio en factores de emisión por parte de Óxidos Nitrosos (NO_x) también usó en su arquitectura un incremento de neuronas por capa oculta y destreza de normalización al máximo para facilitar el procesamiento de la red y agilizando el entrenamiento de la misma.

Resultados de estimación para el consumo de combustible y gases contaminantes.

Una vez se cuenta con los valores estimados de las salidas de estudio respecto a los parámetros de funcionamiento de cada vehículo, se lleva a cabo un análisis comparando los índices reales con los predichos a través de una gráfica de dispersión; complementando las gráficas se induce la variable de velocidad (VSS) para identificar bajo que rango ocurren las estimaciones más precisas y/o a su vez las más deficientes con el modelo de aprendizaje automático.

Figura 50

Comparación del consumo real vs estimado mediante VSS




Nota: Se muestra una comparación del consumo real vs estimado mediante la velocidad.

Observando la gráfica de dispersión se constata los lineamientos deducidos para esta red neuronal artificial desde las gráficas previas relacionadas con el comportamiento del error medio cuadrático, histogramas de errores y coeficientes de determinación.

La variable del consumo de combustible especifica un margen de error mínimo únicamente a velocidades bajas [0 – 15] Km/h. A medida que se regula la velocidad del vehículo el consumo predicho se ajusta perfectamente al modelo real bajo aprendizaje automático.

Figura 51

Gráfico por puntos del consumo real vs estimado




Nota: El gráfico por puntos representa una comparación del consumo real vs estimado

En este gráfico por puntos es sencillo realizar este análisis porque se confirma la observación previa de que, conforme se modula la velocidad del vehículo, el consumo estimado se adecúa de manera precisa al modelo real mediante técnicas de aprendizaje automático. Otro indicio estadístico que denota que el modelo es sumamente preciso es la similitud en los rangos de las muestras por parte de las variables de Consumo Real y Consumo Estimado [0 - 50].

Figura 52

Comparación del consumo real vs estimado mediante VSS



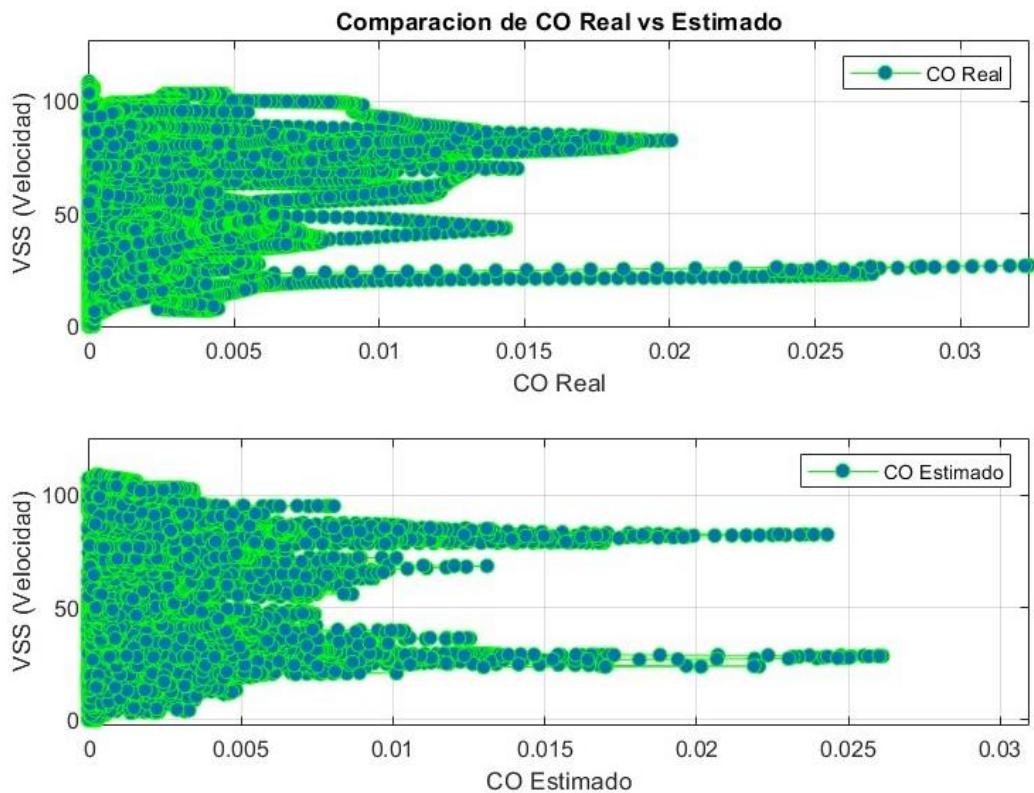
Nota: Se muestra una comparación del CO real vs estimado mediante la velocidad.

La segunda red neuronal artificial dedicada al análisis del Monóxido de Carbono (CO) revela una notable dispersión de datos, sin embargo, también indica una correspondencia significativa entre los datos reales y los datos predichos en rangos específicos de velocidades. Se destaca que el rango de los índices estimados coincide con el rango de los índices reales. Específicamente, se observa que las muestras del gas estimado exhiben una dispersión predominante en el intervalo de velocidad altas a una escala menor de las máximas [70 - 80] Km/h. A su vez, a velocidades elevadas, en el rango de [90 - 105] Km/h, se evidencia una convergencia notable entre valores reales y valores predichos, al igual que en el intervalo [40- 70] Km/h representando a la zona rural

recorrida en ruta, pues es donde se ejerce una constante velocidad y aceleración sin la presencia de repetidas paradas (por intersecciones, semáforos o tráfico) además de evitar las excesivas velocidades alcanzadas en autopistas (donde la gestion electrónica del vehículo híbrido coloca a maxima potencia el MCI).

Figura 53

Gráfico por puntos del CO real vs estimado



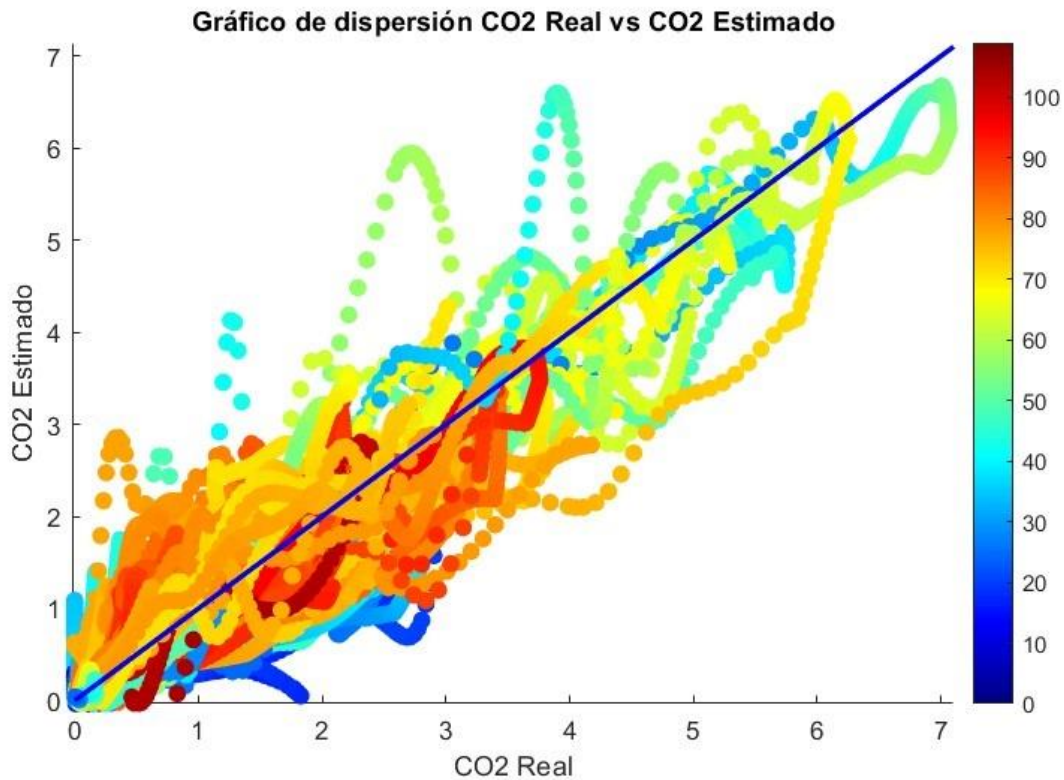
Nota: El gráfico por puntos representa una comparación del CO real vs estimado

La afirmación previa se respalda mediante el análisis del diagrama de dispersión. Este gráfico revela ligeras fluctuaciones entre los datos reales de monóxido de carbono (CO) y sus valores estimados por la red neuronal. Se observa que la precisión de la red neuronal es inferior a la de otros métodos utilizados. No obstante, en proximidades al rango [0 - 0.01%] de concentración de

CO, se aprecia una precisión considerable en las estimaciones realizadas por la red neuronal. Este detalle indica que, a pesar de su menor precisión general, la red neuronal puede ofrecer resultados confiables en condiciones específicas de concentración de CO cercanas al 0.01%.

Figura 54

Comparación del CO2 real vs estimado mediante VSS

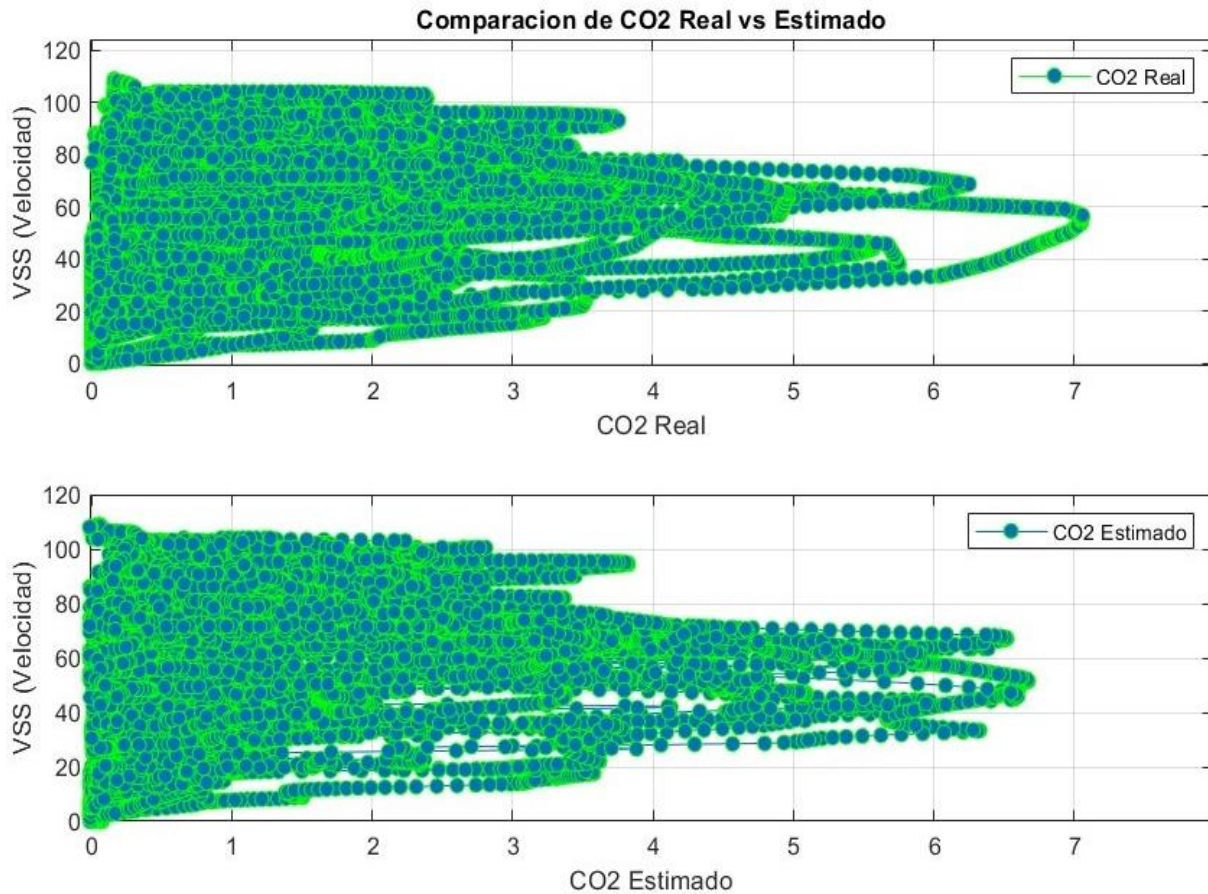


Nota: Se muestra una comparación del CO2 real vs estimado mediante la velocidad.

Por otro lado, el Dióxido de Carbono (CO2) demuestra una correcta igualdad entorno a los rangos generales de las muestras para los valores reales como para los estimados, pues ambos se rigen a [0 - 7] g/s (a diferencia del resto de gases en los que la resultante estimada siempre se extiende entorno al rango por encima de los reales medidos). De manera notable se rescata que a velocidad bajas [0 - 30] Km/h se ajustan en valores similares la relación de gases.

Figura 55

Gráfico por puntos del CO2 real vs estimado




Nota: El gráfico por puntos representa una comparación del CO2 real vs estimado

En el rango de velocidades [20 - 70] Km/h se denota una clara diferencia entre los índices reales con los estimados; la muestra de puntos es distinta a tal grado de distorsionar la forma de las curvas generada por la unión entre ellos; siendo así un método visual sencillo para distinguir la dispersión entre valores. A velocidades relativamente altas [90 - 100] Km/h de igual manera se ajusta el modelo de manera correcta. Concluyendo así que el presente modelo de estimación en relación al CO2 es aconsejable aplicar en zonas urbanas y autopistas, dejando de lado los recorridos rurales por el alto índice de dispersión mostrado en las dos gráficas anteriormente analizadas.

Figura 56

Comparación del HC real vs estimado mediante VSS




Nota: Se muestra una comparación del HC real vs estimado mediante la velocidad.

El gráfico de comparación entre las variables reales y estimadas para los Hidrocarburos (HC) revela una dispersión significativa en el intervalo [45 - 75] Km/h. En este rango, las muestras representadas por la estimación resultante se extienden en un espectro que varía desde [0 - 3] $\times 10^{-3} g/s$ mientras que la resultante real se limita a [0 - 1] $\times 10^{-3} g/s$. Esta diferencia en la dispersión entre las estimaciones y los valores reales destaca la variabilidad en la precisión del modelo, particularmente en el rango de velocidades mencionado. Es importante destacar que, para el resto de las velocidades, el modelo demuestra un ajuste notable. El

Figura 57

Gráfico por puntos del HC real vs estimado




Nota: El gráfico por puntos representa una comparación del HC real vs estimado

El gráfico de dispersión por puntos de la concentración de real vs estimado de hidrocarburos (HC) exhibe desviaciones notables de la red neuronal en la predicción de este gas contaminante a velocidades medias y altas, específicamente en el rango de [50,100] Km/h. No obstante, se evidencia una concordancia significativa entre las predicciones del modelo y los valores reales en velocidades inferiores a 50 Km/h. Esto sugiere que la red neuronal es efectiva para estimar las concentraciones de HC en condiciones de baja velocidad, mientras que enfrenta desafíos al abordar velocidades más altas. Esta observación resalta la importancia de considerar la validez del modelo en diferentes rangos de velocidad para su aplicación precisa en la predicción de contaminantes atmosféricos.

Figura 58

Comparación del NOx real vs estimado mediante VSS




Nota: Se muestra una comparación del NOx real vs estimado mediante la velocidad.

La quinta y última red neuronal artificial dedicada al estudio de los óxidos nitrosos (NOx) exhibe una dispersión considerable similar a los Hidrocarburos (HC). Se debe al lineamiento de la dependencia de múltiples factores – parámetros. Los rangos de muestras para los Óxidos Nitrosos Reales es de $[0 - 1.2] \times 10^{-3} g/s$; mientras que los gases estimados con la presente y cuarta red neuronal artificial arroja un rango aproximado de muestras $[0 - 2] \times 10^{-3} g/s$. La dispersión que existe por aparte de la resultante estimada se da en la mayoría de intervalos de velocidad de toda la ruta RDE; a excepción de las velocidades relativamente bajas como lo son: $[0 - 30]$ Km/h. Demostrando que fácilmente este modelo se ajustaría a zonas urbanas en donde se limita las velocidades por debajo de 35 Km/h por leyes de tránsito vial, paradas, intersecciones, tráfico o semaforización.

Figura 59

Gráfico por puntos del NOx real vs estimado



Nota: El gráfico por puntos representa una comparación del NOx real vs estimado

La representación gráfica de las muestras de gases mediante puntos y curvas resulta esencial para validar el análisis previo mediante un gráfico de dispersión. En el intervalo de muestras entre 1 y 2.5 ($\times 10^{-3} g/s$) de óxidos nitrosos, se observa una dispersión significativa, lo que conlleva a un margen de error elevado en esa sección. Esta variabilidad radical subraya la importancia de la representación gráfica en la interpretación de los resultados. Los factores de emisión estimados y reales de cada uno de los gases en cada sector de recorrido son mostrados a continuación:

Determinación de factores de emisión de cada vehículo en rutas RDE.

Para la determinación de los factores de emisión se hace uso del procedimiento descrito en (UE, 2016) Los factores de emisión se derivan de las concentraciones volumétricas de contaminantes presentes en los gases expulsados a través del tubo de escape del vehículo.

Se realiza una estimación del flujo másico del escape con la siguiente ecuación:

$$\dot{m}_{es} = \dot{m}_{air} + \dot{m}_{comb}$$

Donde \dot{m}_{air} es el flujo másico del aire (MAF) parámetro obtenido del dispositivo OBDlink Mx, \dot{m}_{comb} es el flujo másico de combustible.

Si las emisiones se evalúan en base seca, las concentraciones deben ser convertidas a base húmeda mediante la siguiente expresión:

$$C_{wet,j} = k_{w,j} C_{dry,j}$$

Donde $C_{wet,j}$ representa la concentración en base húmeda del gas contaminante, $k_{w,j}$ es el factor de corrección de la base seca a base húmeda y $C_{dry,j}$ es la concentración en base seca de un gas (ppm o porcentaje).

Para calcular el factor de corrección se hace uso de la siguiente ecuación:

$$k_w = \frac{1.008}{1 + 0.005\alpha(C_{CO_2} + C_{CO})}$$

Donde α es la relación molar del Hidrógeno, C_{CO_2} representa la concentración en base seca del CO2 [%] y C_{CO} representa la concentración en base seca del CO.

Luego se procede a determinar las emisiones másicas instantáneas por medio de la siguiente expresión:

$$m_{gas} = \mu_{gas} * c_{gas} * \dot{m}_{es} * 10^{-3}$$

c_{gas} representa la concentración del gas del escape (ppm), μ_{gas} es la relación que existe entre la densidad del gas y la densidad global del escape. Basándose en esta estimación, es posible calcular los niveles de emisión instantánea de los vehículos.

Habiendo calculado la masa de cada gas contaminante en (gramos) se procede a determinar los factores de emisión mediante:

$$F_{gas} = \frac{m_{gas}}{s}$$

La presentación de los factores de emisión (g/km) durante una ruta en ciclo de conducción real (RDE) se organizan a continuación en tablas separadas para cada tipo de vehículo (Sedán, Crossover y SUV) lo que permite un análisis comparativo detallado de los factores de emisión entre estos vehículos.

Tabla 20

Factores de emisión total - Vehículo tipo Sedán

Gases contaminantes	F (g/km)
CO	[0.0735]
CO2	[43.1812]
HC	[0.0039]
Nox	[0.0059]

Nota: En la tabla se presentan los factores de emisión que emite el vehículo tipo Sedán durante su ruta RDE. Fuente: Autores

Tabla 21*Factores de emisión total - Vehículo tipo Crossover*

Gases contaminantes	F (g/km)
CO	[0.9143]
CO2	[90.2931]
HC	[0.0051]
Nox	[0.0151]

Nota: En la tabla se presentan los factores de emisión que emite el vehículo tipo Crossover durante su ruta RDE. Fuente: Autores

Tabla 22*Factores de emisión total - Vehículo tipo SUV*

Gases contaminantes	F (g/km)
CO	[0.1868]
CO2	[92.8487]
HC	[0.0033]
Nox	[0.0073]

Nota: En la tabla se presentan los factores de emisión que emite el vehículo tipo SUV durante su ruta RDE. Fuente: Autores

Además, se considera oportuno obtener resultados de factores de emisión por cada sector que involucra un recorrido en una ruta RDE (Urbano, rural y autopista). Realizando los cálculos respectivos obtenemos los siguientes resultados de factores de emisión por sector en los tres tipos de vehículos.

Tabla 23*Factores de emisión por secciones RDE - Vehículo tipo Sedán*

F	Urbano (g/Km)	Rural (g/Km)	Autopista (g/Km)
CO	0.0691	0.0967	0.0571
CO2	28.21	62.46	39.93
HC	0.00087	0.0087	0.0024
NOx	0.0030	0.0065	0.0080

Nota: En la tabla se presentan los factores de emisión del vehículo tipo Sedán durante su ruta RDE seccionando por zonas. Fuente: Autores

Tabla 24*Factores de emisión por secciones RDE - Vehículo tipo Crossover*

F	Urbano (g/Km)	Rural (g/Km)	Autopista (g/Km)
CO	0.1279	0.8992	1.7618
CO2	42.24	46.61	183.51
HC	0.0048	0.0026	0.0078
NOx	0.0130	0.0082	0.0238

Nota: En la tabla se presentan los factores de emisión del vehículo tipo Crossover durante su ruta RDE seccionando por zonas. Fuente: Autores

Tabla 25*Factores de emisión por secciones RDE - Vehículo tipo SUV*

F	Urbano (g/Km)	Rural (g/Km)	Autopista (g/Km)
CO	0.2456	0.1808	0.1322
CO2	36.95	55.77	184.19
HC	0.0057	0.0037	0.00035
NOx	0.0050	0.0036	0.0132

Nota: En la tabla se presentan los factores de emisión del vehículo tipo SUV durante su ruta RDE seccionando por zonas. Fuente: Autores

Factores de emisión estimados**Tabla 26***Factores de emisión estimados*

F	Urbano (g/Km)	Rural (g/Km)	Autopista (g/Km)
CO	0.0606	0.0760	0.0691
CO2	29.95	57.02	44.02
HC	0.0021	0.0058	0.0059
NOx	0.0021	0.0047	0.0038

Nota: En la tabla se presentan los factores de emisión de los resultados estimados que se obtuvieron mediante el uso de las redes neuronales artificiales.

Dado que la ruta utilizada para estimar los factores de emisión está asociada a un vehículo de tipo Sedán, se vuelve esencial y práctico llevar a cabo un análisis comparativo en torno a la Ruta de Emisión en Conducción Real (RDE) específica del vehículo Sedán, como se detalla en la Tabla 13 durante los entrenamientos de las Redes Neuronales Artificiales (RNA).

La comparación de los coeficientes reales con los estimados revela una notable similitud numérica, evidenciando la precisión del modelo generado por las distintas RNA empleadas en el proceso. Este vínculo de datos se logra mediante la alineación de las rutas RDE, asegurando la adquisición de datos bajo parámetros establecidos por la norma EURO 6. De esta manera, se garantiza que cada uno de los recorridos realizados por los vehículos sometidos a prueba comparta características similares, consolidando así la consistencia en la evaluación del desempeño de los modelos de emisión. Este enfoque meticuloso fortalece la confiabilidad de los resultados obtenidos y proporciona una base sólida para la interpretación y comparación de los factores de emisión entre los diferentes tipos de vehículos.

Conclusiones

A lo largo de todo el desarrollo del proyecto técnico, se obtuvieron las siguientes conclusiones en relación a los lineamientos descritos previamente:

- El análisis profundo del estado actual del aprendizaje automático ha sido crucial para mejorar la eficiencia en la implementación de programas informáticos en el proyecto. Se destaca la utilidad de las redes neuronales artificiales (RNA) en procesos de estimación. Además, se ha realizado una investigación exhaustiva sobre las emisiones de fuentes móviles y los factores de emisión de la industria automotriz en el medio ambiente. Esto ha generado una base de datos confiable y estadísticas relevantes sobre el impacto de los gases contaminantes emitidos por vehículos en el aire.
- Durante la recolección de datos, se realizó un análisis detallado de la normativa EURO 6, centrándose en los criterios y variables relevantes para las rutas de conducción normalizadas. La operación adecuada de los dispositivos automotrices portátiles es crucial para obtener resultados de alta calidad con un margen de error mínimo. Se encontraron deficiencias durante los recorridos para adquirir señales PID's, lo que prolongó el tiempo de desarrollo del proyecto en el campo. Es fundamental abordar estas deficiencias para garantizar la efectividad y precisión de los datos recopilados, optimizando así el análisis y la validación de conformidad con los estándares EURO 6.
- Se recopilaron los parámetros de funcionamiento y los factores de emisión necesarios para entrenar las redes neuronales utilizando los dispositivos OBD-Link MX y KANE. Para ubicar las variables geográficas de los vehículos, se integró el dispositivo FREEMATICS ONE+. Las señales PID se validaron y compactaron para igualar el número de muestras y matrices. Se aplicaron procesos de filtrado, igualación y corrección en las variables para

desarrollar un modelo robusto y preciso de estimación. Las matrices de entrada para entrenar en el Consumo de Combustible, CO, CO₂, HC y NO_x se seleccionaron según las correlaciones entre las salidas mencionadas y los parámetros de funcionamiento del vehículo. Se implementaron estrategias estadísticas y de inteligencia artificial para mejorar los coeficientes de determinación en los entrenamientos de las RNA, como la normalización y la eliminación de periodos iniciales en las pruebas, así como la ampliación de las capas ocultas y el número de neuronas en cada red, evitando el sobreajuste. Los resultados de los entrenamientos superaron el umbral de 0.70 requerido por los principios de la inteligencia artificial, alcanzando cifras de 0.94% y 0.90%.

- Comenzando a analizar los resultados de las estimaciones se terminaron de adaptar correctamente las unidades y conversiones en las variables de los cuatro gases contaminantes relacionados al estudio. El uso de redes neuronales para las estimaciones reveló distintos niveles de precisión y eficiencia. La variable de salida relacionada con el consumo de combustible se entrenó adecuadamente, produciendo estimaciones idénticas a los valores reales obtenidos por el analizador KANE. El primer gas contaminante (CO) denotó una similitud considerable en velocidades bajas, volviendo preciso el modelo para aplicaciones de estimación en zonas urbanas. La resultante del Dióxido de Carbono (CO₂) mostró un ajuste preciso en velocidades bajas y altas, diferenciando el sector rural para el modelo. En el estudio de las salidas más controversiales del estudio (HC) y (NO_x) nuevamente se indica que el modelo de ambas salidas es eficaz en un entorno donde las velocidades son moderadas por debajo de los 40 Km/h. Mientras que a velocidades regulares – medias se dispersa considerablemente las muestras por parte de los índices estimados.

- Con los resultados obtenidos se llega a concluir que el uso de variables denominadas dummy es de vital importancia para la mejorar la predicción de las redes neuronales empleadas.

Recomendaciones

Para el desarrollo del presente proyecto técnico, se hizo uso de equipos de medición para la obtención de datos necesarios para realizar el estudio y análisis de los mismos con el objetivo de obtener resultados fiables de factores de emisión de vehículos híbridos, se recomienda configurar a una frecuencia de muestro común de los equipos de medición y así facilitar la adquisición y procesamiento de los datos.

Con los resultados de este proyecto se recomienda tomar en cuenta y dar la importancia que se merecen a los vehículos híbridos como tecnología de transición dentro de países en vías de desarrollo con el objetivo de disminuir significativamente las emisiones contaminantes y mejorar la calidad del aire. Se podrían implementar incentivos para la renovación del parque automotor del país, fomentando la adopción de vehículos híbridos más modernos y menos contaminantes.

Se recomienda seguir monitoreando las emisiones de vehículos híbridos y actualizar políticas y regulaciones en consecuencia. La investigación y el análisis continuos son fundamentales para garantizar que las medidas tomadas sean efectivas y estén alineadas con los objetivos de calidad del aire y sostenibilidad ambiental.

Bibliografía

- Bagheri, S., Huang, Y., Walker, P. D., Zhou, J. L., & Surawski, N. C. (2021). Strategies for improving the emission performance of hybrid electric vehicles. En *Science of the Total Environment* (Vol. 771). Elsevier B.V. <https://doi.org/10.1016/j.scitotenv.2020.144901>
- Buenaño, L., Torres, H., & Fernández, E. (2023). Location of the Interurban Fast Charging Infrastructure for Electric Vehicles Using the Methodology for Calculating the Maximum Distance between Fast Charges (MDFC) and Simulation: A Case Study in Ecuador. *World Electric Vehicle Journal*, 14(5). <https://doi.org/10.3390/wevj14050129>
- Çağatay Bayindir, K., Gözüküçük, M. A., & Teke, A. (2011). A comprehensive overview of hybrid electric vehicle: Powertrain configurations, powertrain control techniques and electronic control units. *Energy Conversion and Management*, 52(2), 1305–1313. <https://doi.org/10.1016/j.enconman.2010.09.028>
- euro 6. (s/f).
- Farahzadi, L., & Kioumars, M. (2023). Application of machine learning initiatives and intelligent perspectives for CO2 emissions reduction in construction. En *Journal of Cleaner Production* (Vol. 384). Elsevier Ltd. <https://doi.org/10.1016/j.jclepro.2022.135504>
- Gregorio, D., & Sancan, C. (2017). Vehículos híbridos, una solución interina para bajar los niveles de contaminación del medio ambiente causados por las emisiones provenientes de los motores de combustión interna. *INNOVA Research Journal*, 2(12), 1–10.
- Huang, Y., Surawski, N. C., Organ, B., Zhou, J. L., Tang, O. H. H., & Chan, E. F. C. (2019). Fuel consumption and emissions performance under real driving: Comparison between hybrid and conventional vehicles. *Science of the Total Environment*, 659, 275–282. <https://doi.org/10.1016/j.scitotenv.2018.12.349>
- Introduction_to_hybrid_electric_vehicles_State_of_art.* (s/f).
- Kane. (2023). *Kane Live*.
- Kebriaei, M., Niasar, A. H., & Asaei, B. (2016). Hybrid electric vehicles: An overview. *2015 International Conference on Connected Vehicles and Expo, ICCVE 2015 - Proceedings*, 299–305. <https://doi.org/10.1109/ICCV.2015.84>
- Maino, C., Misul, D., Di Mauro, A., & Spessa, E. (2021). A deep neural network based model for the prediction of hybrid electric vehicles carbon dioxide emissions. *Energy and AI*, 5. <https://doi.org/10.1016/j.egyai.2021.100073>
- METODOLOGÍAS PARA LA ESTIMACIÓN DE EMISIONES DE TRANSPORTE URBANO DE CARGA Y GUÍAS PARA LA RECOPIACIÓN Y ORGANIZACIÓN DE DATOS.* (2013). <http://www.cleanairinstitute.org/cops/>
- Molina Campoverde, J. J. (2020). Driving Mode Estimation Model Based in Machine Learning Through PID's Signals Analysis Obtained From OBD II. *Communications in Computer and Information Science*, 1194 CCIS, 80–91. https://doi.org/10.1007/978-3-030-42520-3_7

- Molina Campoverde, P. A., Rivera Campoverde, N. D., Novillo Quirola, G. P., & Bermeo Naula, A. K. (2021). Characterization of Braking and Clutching Events of a Vehicle Through OBD II Signals. *Advances in Intelligent Systems and Computing*, 1273 AISC, 134–143. https://doi.org/10.1007/978-3-030-59194-6_12
- Nanaki, E. A., & Koroneos, C. J. (2013). Comparative economic and environmental analysis of conventional, hybrid and electric vehicles - The case study of Greece. *Journal of Cleaner Production*, 53, 261–266. <https://doi.org/10.1016/j.jclepro.2013.04.010>
- Néstor Diego, R. C., Molina Campoverde, P. A., Quirola Novillo, G. P., & Naula Bermeo, A. K. (2021). Development of an Algorithm Capable of Classifying the Starting, Gear Change and Engine Brake Variables of a Vehicle by Analyzing OBD II Signals. *Advances in Intelligent Systems and Computing*, 1273 AISC, 121–133. https://doi.org/10.1007/978-3-030-59194-6_11
- OBDlink. (2023). *OBDlink Mx*.
- ONU. (2023). *Objetivos de Desarrollo Sostenible*.
- Pielecha, J., Skobiej, K., & Kurtyka, K. (2020). Exhaust emissions and energy consumption analysis of conventional, hybrid, and electric vehicles in real driving cycles. *Energies*, 13(23). <https://doi.org/10.3390/en13236423>
- Plan-de-Creación-de-Oportunidades-2021-2025-Aprobado_compressed*. (s/f).
- Prati, M. V., Costagliola, M. A., Giuzio, R., Corsetti, C., & Beatrice, C. (2021). Emissions and energy consumption of a plug-in hybrid passenger car in Real Driving Emission (RDE) test. *Transportation Engineering*, 4. <https://doi.org/10.1016/j.treng.2021.100069>
- Rivera, N. D., Molina, P. A., Bermeo, A. K., Bermeo, O. E., & Figueroa, J. L. (2022). Driving Style Analysis by Studying PID's Signals for Determination of Its Influence on Pollutant Emissions. *Smart Innovation, Systems and Technologies*, 252, 321–331. https://doi.org/10.1007/978-981-16-4126-8_30
- Rivera-Campoverde, N. D., Muñoz-Sanz, J. L., & Arenas-Ramírez, B. D. V. (2021). Estimation of pollutant emissions in real driving conditions based on data from OBD and machine learning. *Sensors*, 21(19). <https://doi.org/10.3390/s21196344>
- Rivera-Campoverde, N., Muñoz-Sanz, J., & Arenas-Ramírez, B. (s/f). *Modelo de bajo costo para la estimación de emisiones contaminantes basado en GPS y aprendizaje automático*.
- Šarkan, B., Gnap, J., & Kiktová, M. (2019). THE IMPORTANCE OF HYBRID VEHICLES IN URBAN TRAFFIC IN TERMS OF ENVIRONMENTAL IMPACT. En *The Archives of Automotive Engineering-Archiwum Motoryzacji* (Vol. 85, Número 3).
- UE. (2016). *Reglamento (UE) 2016/427*.
- Velepucha-Sánchez, J. M., & Sabando-Piguabe, L. F. (2021). Emisiones de gases contaminantes en vehículos livianos a gasolina. *Revista Científica INGENIAR: Ingeniería, Tecnología e Investigación*, 4(8), 78–95. <https://doi.org/10.46296/ig.v4i8.0024>
- Volkswagen de Mexico. (2022). *Vehiculos híbridos*.

Wang, Y., Hao, C., Ge, Y., Hao, L., Tan, J., Wang, X., Zhang, P., Wang, Y., Tian, W., Lin, Z., & Li, J. (2020). Fuel consumption and emission performance from light-duty conventional/hybrid-electric vehicles over different cycles and real driving tests. *Fuel*, 278. <https://doi.org/10.1016/j.fuel.2020.118340>

Zhai, H., Christopher Frey, H., & Roupail, N. M. (2011). Development of a modal emissions model for a hybrid electric vehicle. *Transportation Research Part D: Transport and Environment*, 16(6), 444–450. <https://doi.org/10.1016/j.trd.2011.05.001>

Anexos

Figura 60

Proceso de adquisición de datos



Nota: En la imagen se observa el proceso de adquisición de datos y monitoreo de los mismos desde el habitáculo del vehículo. Fuente: Autores

Figura 61

Instrumentación del vehículo



Nota: En la imagen se observa la sonda del analizador de gases que se conecta en el tubo de escape para tomar los datos de los gases contaminantes. Fuente: Autores