

**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE CUENCA**

**CARRERA DE INGENIERÍA MECÁNICA
AUTOMOTRIZ**

TRABAJO DE TITULACIÓN
PREVIO A LA OBTENCIÓN
DEL TÍTULO DE: INGENIERO
MECÁNICO AUTOMOTRIZ

PROYECTO TECNICO

"ESTUDIO DE LA AUTONOMÍA DEL VEHÍCULO ELÉCTRICO KIA
SOUL APLICANDO MÁQUINAS DE SOPORTE VECTORIAL EN LA
CIUDAD DE CUENCA"

AUTORES

DELGADO TELLO FABIÁN ANDRÉS

OCHOA CARPIO WILLIAM FERNANDO

TUTOR

ING. ADRIÁN XAVIER SIGÜENZA REINOSO

Cuenca – Ecuador
2018



CESIÓN DE DERECHOS DE AUTOR

Nosotros, William Fernando Ochoa Carpio con C.I. 010496591-8 y Fabián Andrés Delgado Tello con C.I. 010426366-0, manifestamos nuestra voluntad y cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales, en virtud de que somos autores del trabajo de titulación: **"ESTUDIO DE LA AUTONOMÍA DEL VEHÍCULO ELÉCTRICO KIA SOUL APLICANDO MÁQUINAS DE SOPORTE VECTORIAL EN LA CIUDAD DE CUENCA"**, mismo que ha sido desarrollado para optar por el título de: Ingeniero Mecánico Automotriz, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en nuestra condición de autores nos reservamos los derechos morales de la obra citada. En concordancia, suscribimos este documento en el momento que hacemos la entrega del trabajo final en formato impreso y digital a la Biblioteca de la Universidad Politécnica Salesiana.



William F. Ochoa C.
CI: 010496591-8



Fabián A. Delgado T.
CI: 010426366-0



CERTIFICACIÓN

Yo declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: **"ESTUDIO DE LA AUTONOMÍA DEL VEHÍCULO ELÉCTRICO KIA SOUL APLICANDO MÁQUINAS DE SOPORTE VECTORIAL EN LA CIUDAD DE CUENCA"**, realizado por los autores William Fernando Ochoa Carpio y Fabián Andrés Delgado Tello, obteniendo el Proyecto Técnico que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana.

Cuenca, octubre del 2018



Ing. Adrián Sigüenza
CI: 010382736-6



DECLARATORIA DE RESPONSABILIDAD

Nosotros, William Fernando Ochoa Carpio con C.I. 010496591-8 y Fabián Andrés Delgado Tello con C.I. 010426366-0, autores del trabajo de titulación: **"ESTUDIO DE LA AUTONOMÍA DEL VEHÍCULO ELÉCTRICO KIA SOUL APLICANDO MÁQUINAS DE SOPORTE VECTORIAL EN LA CIUDAD DE CUENCA"**, certificamos que el total contenido del Proyecto Técnico es de nuestra exclusiva responsabilidad y autoría.

Cuenca, octubre del 2018



William F. Ochoa C.
CI: 010496591-8



Fabián A. Delgado T.
CI: 010426366-0



AGRADECIMIENTO

Agradezco a Dios por darme la vida y las fuerzas para poder culminar mis estudios.

Especialmente a mis padres Gustavo Delgado y Esperanza Tello, que me han apoyado incondicionalmente en cada etapa de mi vida.

A mis hermanos Gustavo, Jorge Luis y Gabriela, por todo el apoyo y motivación que me han brindado en cada etapa de mi vida.

A mis profesores, compañeros y amigos por todo el apoyo que supieron brindarme para la culminación de este proyecto.

Al Ing. Adrián Sigüenza, por la contribución recibida para la elaboración de este proyecto.

Fabián Andrés Delgado Tello



AGRADECIMIENTO

Gracias a Dios por brindarme las fuerzas necesarias para culminar mis estudios universitarios.

A mis padres William Ochoa y R. Elena Carpio por el apoyo incondicional en mi vida y por ser mi mayor referencia de superación y de coraje.

A mis hermanos Christian y Camila por ser parte de la motivación que tengo en mi vida.

A mis profesores y compañeros por compartir todos los conocimientos de cada uno, y ser parte de mi aprendizaje.

Al Ing. Adrián Sigüenza, por la contribución recibida para la elaboración de este proyecto.

William Fernando Ochoa Carpio



DEDICATORIA

Dedico este trabajo a mis padres Gustavo Delgado y Esperanza Tello, quienes supieron guiarme y apoyarme en cada etapa de mi vida.

A mis hermanos Gustavo, Jorge Luis y Gabriela, por todo el apoyo y constancia que me han brindado cada día.

A mi esposa Ansheleth por todo el apoyo y fortaleza que me ha brindado.

Especialmente dedico este trabajo a mi hija Renata Delgado, quien es mi inspiración, fortaleza y mi motivación que me ayuda a salir adelante día a día.

Fabián Andrés Delgado Tello



DEDICATORIA

Este proyecto de titulación dedico principalmente a mis padres William Ochoa y R. Elena Carpio por ser el pilar fundamental en mi vida y confiar en mis condiciones.

Dedico también a mis hermanos Christian y Camila por siempre ser mi apoyo.

A mi Abuelita Esthela y a mis tíos que siempre me apoyaron.

William Fernando Ochoa Carpio.



RESUMEN

El presente proyecto técnico estudia la autonomía del vehículo eléctrico Kia Soul dentro de la ciudad de Cuenca con rutas ya establecidas anteriormente en (Bueno Juela & Quizhpe Sinchire, 2017) , esto con el fin de comprobar la eficacia del método máquinas de soporte vectorial.

La información de las rutas ya están establecidas en una base de datos elaborada por un proyecto anterior, dicha base de datos tiene un total de 50 variables, de las cuales se realizó un análisis de correlación con respecto a la variable que define autonomía del tablero con el fin de seleccionar las que más influencia tienen con respecto a la autonomía, dichas variables son: Available charge power, battery dc voltaje, max cell voltaje, min cell voltaje e Inverter capacitor voltaje.

Por medio del software Rstudio (software estadístico) se procedió a aplicar máquinas de soporte vectorial para regresión, a los datos de las 5 variables seleccionadas, dentro de la misma se aplica diferentes kernels a las diferentes regresiones que utiliza el software, de estos resultados se procedió analizar cada uno de ellos y a seleccionar el mejor modelo que más se llegue ajustar al valor teórico de autonomía.

Una vez que se seleccionó el mejor modelo se procedió a realizar la validación del resultado, por medio de un análisis de comportamiento de variables influyentes vs autonomía, de la misma manera se realizó el análisis de residuos para cada una de las variables influyentes vs autonomía, de tal manera se logra determinar la valides del resultado.



SUMMARY

This technical project studies the autonomy of the Kia Soul electric vehicle inside Cuenca city through previously established routes in (Bueno Juela & Quizhpe Sinchire, 2017), with the objective of verify the effectiveness of support vector machine method.

The information of the routes are already established in a database made in a previous project, that database has a total of 50 variables, of which a correlation analysis was made with respect to the variable that defines dashboard autonomy with the purpose of choose the most influential in regard to autonomy, these variables are: Available charge power, battery dc voltage, max cell voltage, min cell voltage e Inverter capacitor voltage.

Through the Rstudio software (statistical software) it has proceeded to apply support vector machine for regression to the data of the 5 selected variables, within it applies different kernels to the different regressions the software uses, of these results has analyzed each one of them and selected the best model who is the most adjusted value to the theoretical autonomy.

Once the best model was selected it has proceeded to make the validation of the result, through an analysis of the behavior of the Influential Variables against autonomy, in the same way it has made the residual analysis to each one of the influential variables against autonomy, in such a way determinate the validity of the result.

INDICE GENERAL

CESIÓN DE DERECHOS DE AUTOR.....	I
CERTIFICACIÓN	II
DECLARATORIA DE RESPONSABILIDAD	III
AGRADECIMIENTO	IV
AGRADECIMIENTO	V
DEDICATORIA.....	VI
DEDICATORIA.....	VII
RESUMEN.....	VIII
SUMMARY	IX
INDICE DE FIGURAS	XIII
INDICE DE TABLAS	XV
Capítulo 1: Estado del Arte.....	1
1.1 Vehículo eléctrico.	1
1.1.1 Motor eléctrico.	1
1.1.2 Baterías.	2
1.1.3 Inversor.	2
1.1.4 Convertidor de bajo voltaje.	2
1.1.5 Engranaje reductor.	2
1.2 Autonomía.....	2
1.2.1 Autonomía del vehículo eléctrico.	3
1.3 Máquinas de soporte vectorial.....	3
1.3.1 Clasificación con máquinas de soporte vectorial.....	4
1.3.2 SVMs linealmente separables.	4
1.3.3 SVMs no linealmente separables.....	4
1.3.4 SVM para problemas Multiclase.	6
1.3.5 Ventajas y desventajas de las SVMs.	8
1.4 Priorización de variables.....	9
1.4.1 Correlación de variables.	9
1.4.2 Matriz de confusión.	9
1.5 Software R Studio.	9
1.6 Rutas de muestreo.....	9
1.6.1 Ruta 1.....	9
1.6.2 Ruta 2.....	10
1.6.3 Ruta 3.....	10
1.6.4 Ruta 4.....	11
1.6.5 Ruta 5.....	11
1.6.6 Ruta 6.....	12
1.6.7 Ruta 7.....	12
Capítulo 2: Procesamiento de Datos.....	14

2.1 Software EmoLab V2.0.....	14
2.2 Variables obtenidas por el software EmoLab 2.0.1.....	15
2.3 Clasificación de variables.	16
2.3.1 Variables de estudio.	17
2.3.2 Variables controlables.	17
2.3.3 Variables no controlables o de ruido.....	17
2.3.4 Variables de respuesta.....	17
2.4 Procesamiento de variables.	17
2.5. Discriminación de variables.	18
2.5.1 Criterio para la discriminación de variables.....	18
2.5.2. Correlación de Pearson.....	18
2.5.3 Correlación de variables grupo 1.	19
2.5.4 Correlación de variables grupo 2.	20
2.5.5 Correlación de variables grupo 3.	21
2.5.6 Correlación de variables grupo 4.	22
2.5.7 Correlación de variables grupo 5.	23
2.5.8 Correlación de variables grupo 6.	24
2.5.9 Correlación de variables grupo 7.	25
2.5.10 Correlación de variables grupo 8.	26
2.5.11 Correlación de variables grupo 9.	27
2.5.12 Correlación de variables grupo 10.	28
2.5.13 Variables influyentes.	29
<i>Capítulo 3: Obtención de modelo matemático que define autonomía mediante máquina de soporte vectorial.</i>	31
3.1 Support Vector Regresión (SVR)	31
3.2 Funcionamiento de la SVR	31
3.3 Kernels y tipos.....	31
3.4 Validación cruzada	32
3.5 Generación del modelo.	33
3.6 Optimización del modelo.....	34
3.7 Selección del modelo efectivo.....	35
3.8 Ecuación del modelo de autonomía.	36
• <i>Capítulo 4: Validación de resultados mediante análisis estadístico.</i>	38
4.1 Análisis de variables influyentes vs Autonomía del tablero.	38
4.2 Análisis del error de la ecuación lineal vs autonomía del tablero.....	41
4.3 Análisis Estadístico.	43
4.3.1 Varianza	43
4.3.2 Aleatoriedad	44
4.3.3 Normalidad	44
4.3.4 Análisis de residuos.....	45
<i>Conclusiones.....</i>	61
<i>Recomendaciones.....</i>	62

<i>Bibliografía</i>	63
<i>Anexos</i>	65

INDICE DE FIGURAS

Figura 1: Clasificación de datos biclase mediante hiperplano	3
Figura 2: Caso linealmente separable, junto con los vectores de soporte	4
Figura 3: Ejemplo de aplicación de una función Kernel	5
Figura 4: SVMs biclase con margen blando	6
Figura 5: Clasificación SVM multiclase	7
Figura 6: Clasificación uno contra el resto.	8
Figura 7: Clasificación uno contra uno.	8
Figura 8: Ruta 1. Universidad Politécnica salesiana – Control sur.	10
Figura 9: Ruta 2. Control sur - Universidad Estatal de Cuenca.	10
Figura 10: Ruta 3. Centro Histórico de la ciudad de Cuenca.	11
Figura 11: Ruta 4 Centro histórico – Av. Gonzales Suarez.	11
Figura 12: Ruta 5. Camino del Valle - Mirador de Turi.	12
Figura 13: Ruta 6. Mirador de Turi – Baños	12
Figura 14: Ruta 7. Baños - Universidad Politécnica Salesiana.	13
Figura 15: Panel Principal Software EmoLab V2.0.	15
Figura 16: Fuerzas de correlación de Pearson.	18
Figura 17: Correlación de variables grupo 1	20
Figura 18: Correlación de variables grupo 2.	21
Figura 19: Correlación de variables grupo 3.	22
Figura 20: Correlación de variables grupo 4.	23
Figura 21: Correlación de variables grupo 5.	24
Figura 22: Correlación de variables grupo 6.	25
Figura 23: Correlación de variables grupo 7.	26
Figura 24: Correlación de variables grupo 8.	27
Figura 25: Correlación de variables grupo 9.	28
Figura 26: Correlación de variables grupo 10.	29
Figura 27: Comportamiento de función Kernel	32
Figura 28: procedimiento de la validación cruzada.	33
Figura 29: Datos de eps-regression con kernel radial.	35
Figura 30: Autonomía del tablero vs Avalaible Charge Power.	38
Figura 31: Autonomia del tablero vs Battery DC Voltage.	39
Figura 32: Autonomia del tablero vs Min Cell Votage [V].	40
Figura 33 Autonomía del Tablero vs Min Cell Voltage [V].	40
Figura 34: Autonomía del tablero vs Inverter Capacitor Voltage [V].	41
Figura 35: Error de Autonomía calculada vs Autonomía del tablero.	42
Figura 36: Comportamiento del error vs Autonmia calculada y autonmia del tablero.	43
Figura 37: Resultado de varianza obtenido por el software Minitab.	43
Figura 38: Serie de tiempo de autonomía calculada.	44
Figura 39: Prueba de normalidad en Minitab.	45
Figura 40: Grafica de Probabilidad para available charge power.	46
Figura 41: Histograma para available charge power.	46
Figura 42: Valor ajustado para available charge power.	47
Figura 43: Orden de observación de available charge power.	48
Figura 44: Grafica de probabilidad para battery dc voltage.	49
Figura 45: Histograma para battery dc voltage.	49
Figura 46: Valor ajustado para battery dc voltage.	50
Figura 47: Orden de observacion para battery dc voltage.	51
Figura 48: Grafica de probabilidad para max cell voltage.	52
Figura 49: Histograma para max cell voltage.	52
Figura 50: Valor ajustado para max cell voltage.	53

<i>Figura 51: Orden de observacion para max cell voltage.</i>	54
<i>Figura 52: Grafica de probabilidad para min cell voltage.</i>	55
<i>Figura 53: Histograma para min cell voltage.</i>	55
<i>Figura 54: Valor ajustado para min cell voltage.</i>	56
<i>Figura 55: Orden de observacion para min cell voltage.</i>	57
<i>Figura 56: Grafica de probabilidad para inverter capacitor voltage.</i>	58
<i>Figura 57: Histograma para inverter capacitor voltage.</i>	58
<i>Figura 58. Valor ajustado para inverter capacitor voltage.</i>	59
<i>Figura 59: Orden de observacion para inverter capacitor voltage.</i>	60

INDICE DE TABLAS

<i>Tabla 1: Ventajas y desventajas de la SVMs.</i>	9
<i>Tabla 2: Variables obtenidas por el software EmoLab</i>	16
<i>Tabla 3: Grupos de variables para proceso de correlación.</i>	19
<i>Tabla 4: Resultados de correlación de variables grupo 1.</i>	20
<i>Tabla 5: Resultados de correlación de variables grupo 2.</i>	21
<i>Tabla 6: Resultados de correlación de variables grupo 3.</i>	22
<i>Tabla 7: Resultados de correlación de variables grupo 4.</i>	23
<i>Tabla 8: Resultados de correlación de variables grupo 5.</i>	24
<i>Tabla 9: Resultados de correlación de variables grupo 6.</i>	25
<i>Tabla 10: Resultados de correlación de variables grupo 7.</i>	26
<i>Tabla 11: Resultados de correlación de variables grupo 8.</i>	27
<i>Tabla 12: Resultados de correlación de variables grupo 9.</i>	28
<i>Tabla 13: Resultado de correlación de variables grupo 10.</i>	29
<i>Tabla 14: Variables más influyentes.</i>	30
<i>Tabla 15: elementos para selección del mejor Kernel de eps-regression.</i>	34
<i>Tabla 16: Elementos para selección del mejor Kernel de nu-regression.</i>	34
<i>Tabla 17: Valores aleatorias de las variables más influyentes.</i>	41



Capítulo 1

ESTADO DEL ARTE

1.1 Vehículo eléctrico.

En la actualidad se vive un cambio significativo en el campo Automotriz, los vehículos eléctricos están cada día ganando posicionamiento en el mercado a nivel mundial, hoy en día el mundo depende netamente de la electricidad en todos los ámbitos, en el campo automotriz por muchos años se ha dependido de los combustibles fósiles derivados del petróleo, teniendo en cuenta que es un recurso limitado y a más de esto el aumento de la contaminación por emisiones de CO₂ es cada vez mayor, con estos antecedentes el vehículo eléctrico es la mejor opción futurista a pesar que tiene ventajas y desventajas, con el pasar del tiempo se espera que llegue a remplazar al vehículo de combustión interna (Sanz, 2015).

Los vehículos eléctricos tienen la capacidad de moverse gracias a la energía eléctrica que obtiene de las baterías, en la gran mayoría estas usan acumuladores electroquímicos formada por dos sustancias conductoras cubiertas por un líquido que permite el paso de cargas positivas y negativas entre sí, de esta manera mantiene la corriente eléctrica para el funcionamiento de un vehículo eléctrico (Ruíz, 2015).

1.1.1 Motor eléctrico.

Es el principal elemento de un vehículo eléctrico, cumple la función de transformar la energía eléctrica en energía mecánica a través de una serie de procesos electromagnéticos, este a su vez tiene la capacidad de poder realizar el mismo proceso en sentido inverso, transforma la energía mecánica en energía eléctrica lo que a su vez lo convierte en un generador (Ruíz, 2015).

Motor de Inducción

Este tipo de motor utiliza corriente alterna que es alimentada por medio de inducción electromagnética, de esta manera alimenta al rotor que se encuentra rodeado por una jaula y se genera un campo magnético giratorio en el estator permitiendo el movimiento del rotor (Ruíz, 2015).

Motores Síncronos de Imanes Permanentes

El funcionamiento de estos motores como su nombre lo indica es por medio de imanes permanentes, la diferencia radica en que el rotor no posee una jaula de ardilla como lo es en el motor de inducción, este motor consta de un devanado que es alimentado de manera directa a través de escobillas y anillos deslizantes (Sixtega A, 2011).



Motor de Flujo axial

Este tipo de motor tiene la capacidad de permitir grandes flujos magnéticos, el rotor es formado de discos de imanes permanentes, se consigue una mayor potencia considerando que estos motores se pueden inducir directamente en la rueda y por la tecnología que usa se puede decir que son los motores del futuro (Ruíz, 2015).

Motor de Reluctancia Conmutada

Este motor consta de un eje de hierro apoyado sobre unos rodamientos, este al igual que otros es alimentados por medio de un campo magnético, la diferencia se da mediante una conmutación del campo magnético lo que conseguirá que se genere movimiento en el núcleo de hierro, la resistencia magnética dada del rotor al campo magnético es la que define el concepto de reluctancia (Ruíz, 2015).

Motor de corriente continua sin escobillas

El rotor de este motor no acciona sus escobillas para realizar una variación en la polaridad del mismo, tiene muchas aplicaciones en baja escala como en lectores de DVD, a pesar de que la fabricación es más económica que otros y requiere menos mantenimiento el control es complejo es por esto que se ha eliminado el uso a gran escala (Ruíz, 2015).

1.1.2 Baterías.

Las baterías en los vehículos eléctricos son los dispositivos encargados de almacenar la energía, estos elementos cuentan con celdas electroquímicas que se encargan de transformar la energía química en energía eléctrica (Morente Fernández, 2015).

1.1.3 Inversor.

Este dispositivo tiene la capacidad de poder invertir la corriente continua en corriente alterna para en su momento permitir el suministro de corriente para el funcionamiento del motor eléctrico y a su vez admite hacer el proceso contrario, reinvertir la corriente alterna en corriente continua para poder permitir la carga del motor del vehículo eléctrico, estos procesos del inversor se puede usar para otros componentes del vehículo eléctrico (Bueno Juela & Quizhpe Sinchire, 2017; Vargas Fabre, 2012).

1.1.4 Convertidor de bajo voltaje.

Se encarga de convertir la tensión de la batería de alto voltaje a un bajo voltaje, para poder entregar 12 V a todos los elementos del vehículo eléctrico que funcionan con este voltaje (Bueno Juela & Quizhpe Sinchire, 2017).

1.1.5 Engranaje reductor.

Teniendo en cuenta que los motores eléctricos trabajan desde revoluciones muy bajas hasta revoluciones muy elevadas se necesita un dispositivo que realice la función de la caja de cambios, este dispositivo es lo que se conoce como engranaje reductor, cumple la misma función de la caja de cambios transmitiendo el par torque y potencia adecuada a las ruedas motrices del vehículo (Urgilés Contreras, 2014).

1.2 Autonomía.

Un vehículo eléctrico es impulsado en vez de un motor de combustión interna, por un motor en este caso eléctrico, que normalmente se han utilizado por más de un siglo, este motor eléctrico requiere de baterías previamente recargadas para poder brindar energía al vehículo para un trayecto cualquiera, el inconveniente de este sistema utilizado por los vehículos



eléctricos recae sobre el tiempo que dura la carga que se realizó en las baterías y de esto depende la autonomía de un vehículo eléctrico.

1.2.1 Autonomía del vehículo eléctrico.

Se puede denominar Autonomía a la Distancia que un vehículo eléctrico puede recorrer desde la carga completa de las baterías hasta que estas se agotan por completo, se mide en KMH y depende del tipo de baterías que se utilizan, así como del tiempo que han sido cargadas en una toma de corriente.

1.2.1.1 Autonomía total.

La autonomía total de un vehículo eléctrico es, por lo tanto, el número de kilómetros que se puede recorrer con las baterías completamente cargadas.

1.2.1.2 Autonomía consumida.

La autonomía consumida de un vehículo eléctrico viene a ser, los kilómetros que ya se han recorrido de la autonomía total.

1.2.1.3 Autonomía restante.

La autonomía restante de un vehículo eléctrico es la diferencia que hay entre la autonomía total menos la autonomía consumida, en otras palabras, es lo que resta de autonomía por recorrer en un vehículo.

1.3 Máquinas de soporte vectorial.

Las SVMs también conocidas como (Support Vector Machine), forman parte de la inteligencia artificial, pensada para ser un clasificador, la empresa AT&T desarrollo a la máquina de soporte vectorial por Vapnik, pensado en disminuir el riesgo estructural, en la actualidad a más de usarlo para problemas de clasificación, se lo usa para problemas de regresión (Riobó Otero, 2012).

La máquina de soporte vectorial, es capaz de entrenar un conjunto de datos, etiquetando cada una de las clases, construye un modelo que tiene la capacidad de suponer a que clase corresponden los próximos valores que se introduzcan, por medio de ciertos datos que se usaron para el entrenamiento separa las clases presentes con una distancia mayor, al introducir datos nuevos dependiendo de la proximidad de uno de los conjuntos ya separados con anterioridad se colocan sobre el mismo eje y, y realiza la clasificación correspondiente (Riobó Otero, 2012).

En la Figura 1, es apreciable el comportamiento de la máquina de soporte vectorial al clasificar un conjunto de datos de dos clases.




Figura 1: Clasificación de datos biclase mediante hiperplano



Fuente: (Riobó Otero, 2012)

1.3.1 Clasificación con máquinas de soporte vectorial.

La SVM, tiene la capacidad de trabajar con más clases conociéndola como clasificación multiclase, durante la clasificación existe dos fases, la primera de aprendizaje automático y la segunda que es de reconocimiento (González, Barrientos, Toapanta, & Del Cerro, 2017).

1.3.1.1 Fase de aprendizaje automático.

Una vez que selecciona el conjunto de datos de entrenamiento, se extraen los atributos y características del espacio de entrada y se entrena el clasificador, como resultado se tiene un conjunto de parámetros a los que se los llama pesos, que define a la función discriminante y al clasificador que representan la frontera de clases (González et al., 2017).

1.3.1.2 Fase de reconocimiento.

El modelo del grupo de datos entrenado, concede a los nuevos datos que se ingresan una de las clases según la similitud de sus características, según los datos nuevos se obtiene una predicción de su comportamiento (González et al., 2017).

1.3.2 SVMs linealmente separables.

Se puede realizar una separación de variables de dos clases, el caso más simple para máquina de soporte vectorial, las clases a separar pueden ser $\{+1; -1\}$ busca un hiperplano que se adapte mejor a la separación de las clases ya mencionadas, estas deben ser completamente separables dejando un margen considerable entre los vectores de soporte, en la Figura 2, se aprecia un caso linealmente separable (Bermeo & Cueva, 2015).




Figura 2: Caso linealmente separable, junto con los vectores de soporte

Fuente: (Bermeo & Cueva, 2015)

En la Figura 2, se observa que existen diferentes formas de trazar un hiperplano como se aprecia en las líneas inter punteadas, pero siempre se opta por el que tenga mayor margen o distancia entre los vectores de soporte de cada clase, estos vectores son los que se encuentran más próximos al hiperplano (Bermeo & Cueva, 2015).

1.3.3 SVMs no linealmente separables.

En los casos no lineales existen dos formas que son importantes de tomar en cuenta, a continuación, se presentan:

- **Algoritmos SVM con margen máximo en el espacio de características**

Esta forma importante de tomar en cuenta cuando existen datos que no se pueden separar linealmente con un margen máximo en una dimensión inicial de entrada R , por lo cual



este método cambia a otra dimensión R^n en la cual, si se pueda clasificar linealmente los datos, pero esto se puede realizar mediante el uso de una función Kernel, que es un producto interno en el espacio de características, que tiene a su vez, su análogo en el espacio de entrada R según (Bermeo, 2015).

$$K(x, x') = \langle \phi(x), \phi(x') \rangle$$

Donde:

K = función que es simétrica (+) definitiva que se rige en las reglas del teorema de Mercer.

En la Figura 3, se puede observar cómo trabaja este caso aplicando una función Kernel, se ve que las variables están mezcladas en el espacio de entrada R , pero al aplicar una función Kernel se le puede pasar a una dimensión superior R^n y ahora si separar linealmente los datos de una forma más cómoda (Bermeo & Cueva, 2015).




Figura 3: Ejemplo de aplicación de una función Kernel

Fuente: (Bueno Juela & Quizhpe Sinchire, 2017)

Entre los Kernels más conocidos que se utilizan están los siguientes:

- La función Lineal
- Función Polinomial
- Función radial
- Otro
- **SVMs con margen blando**

Esta forma se utiliza cuando los datos de entrada están con fallo, con demasiado ruido o con un ocultamiento cruzado entre las clases de algunas variables de entrenamiento, lo cual perjudica al hiperplano de clasificación, por esto se busca cambiar el punto de vista y se encuentra un hiperplano de clasificación que pueda admitir todas estas dificultades en los datos como se ve en la Figura 4.

Por lo tanto, se obtiene distendiendo las restricciones dadas en el caso que es lineal, colocando variables de holgura que no sean negativas $\xi_i \geq 0$ (Bermeo & Cueva, 2015).




Figura 4: SVMs biclase con margen blando

Fuente: (Bermeo & Cueva, 2015)

Por lo tanto, matemáticamente queda definido de la siguiente forma:

$$\begin{aligned} \text{MINIMIZAR} \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \\ \text{Sujeto a:} \quad & y_i (w \cdot X_i + b) \geq 1 - \xi_i \\ & \xi_i \geq 0, i = 1, \dots, l \end{aligned}$$

Se ve que en la función de optimización para el caso de máquinas de soporte vectorial con margen blando, aparece un valor de regularización, el mismo que es dependiente de los datos o variables de holgura, y al mismo tiempo es dependiente de la magnitud y margen de estos datos. También este valor adiciona una C que es también conocida como una constante, la que decreta la distancia del margen blando. El valor de la constante C tendría que tener un valor aproximado con anterioridad y depende del evaluador y es muy importante, dado que según este valor y el Kernel que se utilice influirán en el desempeño de las Maquinas de soporte vectorial.

Así como en la ocurrencia lineal separable, siguiendo la misma forma de resolución, para este problema se intenta encontrar los multiplicadores de Lagrange, se los fabrica y se solventa el ejercicio dual, sabiendo que un Lagrange en física, se refiere a una función escalar.

$$\begin{aligned} \text{MINIMIZAR} \quad & \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N y_i y_j \alpha_i \alpha_j K(x_i, x_j) \\ \text{Sujeto a:} \quad & \sum_{i=1}^N y_i \alpha_i = 0 \\ & 0 \leq \alpha_i \leq C \quad 1 \leq i \leq N \end{aligned}$$

1.3.4 SVM para problemas Multiclase.

En los problemas cotidianos siempre se encuentran problemas que no solo tienen dos clases, como la principal metodología de las SVMs, ya que existen problemas con más de dos clases, es decir con k clases que se conoce como problemas multiclases, por esto se requiere tener una resolución mediante aproximaciones directas que tienen en cuenta todas las clases (Bermeo & Cueva, 2015).

$$\min \frac{1}{2} \sum_{n=1}^n \|W_m\|^2 + C \sum_{i=1}^l \sum_{m \neq y_i}^n \xi_i^m$$

$$\text{Sujeto a: } W_{y_i} * x_i + b_{y_i} \geq W_m * x_i + b_m + 2 - \xi_i^m, \xi_i^m \geq 0$$

De tal manera, para la aproximación de estos problemas multiclase, se han realizado combinando las aproximaciones biclase, en la Figura 5, se distingue una combinación de aproximaciones de dos clases en un problema multiclase (Bermeo & Cueva, 2015).




Figura 5: Clasificación SVM multiclase

Fuente: (Bermeo & Cueva, 2015)

Entre las diferentes formas de combinar la aproximación biclase, para resolver problemas multiclase están las siguientes:

- **Uno contra el resto**

En esta forma lo que se realiza es una construcción de k clasificadores que describen más hiperplanos los que dividen la clase i de k-1 que quedan, con el fin de entender mejor se menciona el siguiente caso, suponiendo que tenemos un caso de 4 clases, se construyen clasificadores así; 1 vs 2-3-4, 2 vs 1-3-4, 3 vs 1-2-4 y por último 4 vs 1-2-3. De esta manera al tener datos actuales los mismos se someten a los k clasificadores, siendo la de máximo margen el resultado (Bermeo & Cueva, 2015).

$$\hat{C}_i = \arg \max (W_i x + b_i) \quad i = 1, \dots, k$$




Figura 6: Clasificación uno contra el resto.

Fuente: (Bermeo & Cueva, 2015)

- **Uno contra uno**

Por su parte este modo en cambio construye $k(k-1)/2$ clasificadores, en este caso sería uno para cada par de clases confrontando así uno a uno cada clase, tomando en cuenta el mismo ejemplo anterior, si tuviéramos una problemática de 4 clases se construiría los consecuentes clasificadores; 1 vs 2, 1 vs 3, 1 vs 4, 2 vs 3, 2 vs 4 y 3 vs 4. Luego se introduce a cada base de datos del grupo para test a todos estos clasificadores, y se adiciona un voto a cada una de las clases ganadoras de cada caso y la que más votos acumule será la clase dada en el problema (Bermeo & Cueva, 2015).




Figura 7: Clasificación uno contra uno.

Fuente: (Bermeo & Cueva, 2015)

1.3.5 Ventajas y desventajas de las SVMs.

Las máquinas de soporte vectorial fueron realizadas en primera instancia para clasificaciones de dos clases, pero con algunas configuraciones realizadas, se ha podido extender a problemas multiclase es decir de varias clases, es por esto que a continuación en la Tabla 1, mencionamos las ventajas y desventajas de las SVMs frente a otros clasificadores.

VENTAJAS	DESVENTAJAS
----------	-------------



En cuanto al entrenamiento de las diferentes variables o datos que se tienen, es parcialmente fácil	Se necesita de una buena función Kernel para que nos dé menos error y los resultados sean confiables y validados
Mediante las funciones kernel se pueden pasar dimensiones más amplias con facilidad	
Minimiza el riesgo estructural (RMS) lo cual nos proporciona datos más coherentes y precisos	

*Tabla 1: Ventajas y desventajas de la SVMs.**Fuente: (Sánchez Anzola, 2016)*

1.4 Priorización de variables.

Cuando se realiza un estudio con una cantidad considerable de variables, es necesario seleccionar las variables más influyentes realizando una priorización de variables, para de esta forma poder disminuir el error en los resultados. Para esta priorización se puede usar los siguientes métodos.

1.4.1 Correlación de variables.

La correlación de Variables se usa para hacer una relación entre variables en los casos de regresión, estas variables deben ser cuantitativas y su resultado nos expresa si se ajusta la relación entre las dos variables que se analiza, de esta manera se puede llegar a determinar si las variables que se analizan son o no influyentes en el estudio (Hernandez Cabrera, 2017).

1.4.2 Matriz de confusión.

La matriz de confusión se usa específicamente en el campo de la inteligencia artificial como redes neuronales, máquina de soporte vectorial etc. Sirve para comprobar en casos de clasificación si dicho sistema puede llegar a confundir dos o más clases distintas por medio de una matriz (Ariza, Pinilla, & García, 2000).

1.5 Software R Studio.

El Software R Studio es una herramienta para el análisis estadístico, es muy dinámico y tiene la posibilidad de visualizar una amplia gama de graficas a diferencia de otros softwares, está diseñado exclusivamente para análisis estadísticos, permitiendo trabajar tanto con matrices como también con vectores, ofreciendo diferentes herramientas para un análisis de datos. Además, el entorno del software R permite descargar librerías para correr en el programa que ya vienen diseñadas para cierto método de análisis, como por ejemplo para las SVMs que se utiliza en este estudio.

1.6 Rutas de muestreo.

En este estudio se utiliza las rutas presentadas en el proyecto de titulación (Bueno Juella & Quizhpe Sinchire, 2017).

1.6.1 Ruta 1.

Esta Ruta está establecida desde la Universidad Politécnica Salesiana – Control sur, es apreciable en la Figura 8, consta de una longitud aproximada de 8.6 km se la considera como una vía rápida y de mayor circulación con un límite de velocidad de 60 [km/h], el primer tramo de 4.6 km consta de 3 carriles, mientras que el segundo tramo de 4 km consta de 2 carriles, esto debido a la construcción del Tranvía de los 4 ríos lo que produjo un incremento en el tráfico vehicular (Bueno Juella & Quizhpe Sinchire, 2017).




Figura 8: Ruta 1. Universidad Politécnica salesiana – Control sur.

Fuente : (Bueno Juela & Quizhpe Sinchire, 2017)

1.6.2 Ruta 2.

Esta ruta está establecida desde el Control Sur – Universidad Estatal de Cuenca, tiene una longitud de 4.4 km aproximadamente se la considera una vía rápida, de mayor circulación y congestión constante con un límite de velocidad de 60 [km/h] (Bueno Juela & Quizhpe Sinchire, 2017).




Figura 9: Ruta 2. Control sur - Universidad Estatal de Cuenca.

Fuente: (Bueno Juela & Quizhpe Sinchire, 2017)

1.6.3 Ruta 3.

Esta ruta está establecida en el centro de la ciudad de Cuenca, se ha considerado esta ruta en vista de que es una de mayor circulación, por su tipo de calzada que permite solo dos carriles de circulación para los vehículos y por ende una congestión vehicular mayor, tiene una longitud de 5.0 km , intensidad vehicular de 400 [veh/h] y velocidad máxima de 30 [Km/h] (Bueno Juela & Quizhpe Sinchire, 2017) .




Figura 10: Ruta 3. Centro Histórico de la ciudad de Cuenca.

Fuente: (Bueno Juela & Quizhpe Sinchire, 2017)

1.6.4 Ruta 4.

Esta ruta está establecida desde Centro Histórico – Av. Gonzales Suarez, se ha considerado esta ruta de mayor recorrido con 6.3 km de longitud, una intensidad de 400 [veh/h], además dicha ruta consta de 2 tramos: el primero con una velocidad establecida de 30[km/h] y congestión vehicular constante, el segundo tramo de vía rápida con una velocidad de 60 [km/h] (Bueno Juela & Quizhpe Sinchire, 2017).




Figura 11: Ruta 4 Centro histórico – Av. Gonzales Suarez.

Fuente: (Bueno Juela & Quizhpe Sinchire, 2017)

1.6.5 Ruta 5.

Esta ruta está establecida entre Camino del Valle – Mirador de Turi, se ha considerado esta ruta por ser una vía de mayor recorrido, rápida, tipo de calzada (asfalto y gravilla) y pendientes (máximos y mínimos), con una longitud de 16.5 km, velocidad máxima de 60 [km/h] y una intensidad aproximada de 800 [veh/h] (Bueno Juela & Quizhpe Sinchire, 2017).




Figura 12: Ruta 5. Camino del Valle - Mirador de Turi.

Fuente: (Bueno Juela & Quizhpe Sinchire, 2017)

1.6.6 Ruta 6.

Esta ruta está establecida entre Mirador de Turi – Baños, se ha considerado esta ruta por ser una vía rápida, de mayor recorrido y por las pendientes, con una longitud de 9.7 km, una velocidad determinada de 60 [km/h] e intensidad aproximada de 800 [veh/h] (Bueno Juela & Quizhpe Sinchire, 2017).




Figura 13: Ruta 6. Mirador de Turi – Baños

Fuente: (Bueno Juela & Quizhpe Sinchire, 2017)

1.6.7 Ruta 7.

Esta ruta está establecida desde Baños – Universidad Politécnica Salesiana, se ha considerado las siguientes variables: Vía rápida, mayor recorrido, pendientes y congestión vehicular. Con una longitud de 16.8 km, velocidad de 50 [km/h] e intensidad aproximada de 800 [veh/h] (Bueno Juela & Quizhpe Sinchire, 2017).




Figura 14: Ruta 7. Baños - Universidad Politécnica Salesiana.

Fuente: (Bueno Juela & Quizhpe Sinchire, 2017)



Capítulo 2

PROCESAMIENTO DE DATOS

En el presente capítulo se reconoce las diferentes variables de la base de datos generada por (Bueno Juela & Quizhpe Sinchire, 2017), con el fin de poder llegar a determinar cuáles son las variables más influyentes en la definición de autonomía, de igual manera poder anular las variables de estado que no genera ninguna relación de dependencia con las otras variables, todo este proceso se realiza a través de una correlación, de esta manera se define las variables significativas para la obtención del modelo de autonomía.

2.1 Software EmoLab V2.0.

El software EmoLab V2.0 es un software de adquisición de datos que se conecta por medio de un periférico bluetooth al vehículo, que gracias a la configuración de labview extrae información del vehículo en forma hexadecimal y los convierte en variables con un comportamiento continuo definidos, con una frecuencia de muestreo de 1 segundo. Su ambiente de trabajo es de tipo basic (Figura 15), en el cual se permite configuraciones de adquisición de variables que se desea estudiar como protocolos de comunicación.




Figura 15: Panel Principal Software EmoLab V2.0.

Fuente: Autores.

2.2 Variables obtenidas por el software EmoLab 2.0.1.

Las variables como: posición del pedal de aceleración, porcentaje de autonomía, temperatura del motor, entre otras. Se adquieren en tiempo real durante el tiempo que dura cada uno de los recorridos. El software entrega un total de 50 variables las cuales se puede apreciar en la Tabla 2, las mismas que son utilizadas para realizar el estudio de las variables más influyentes (Bueno Juela & Quizhpe Sinchire, 2017).

VARIABLE	DETALLE
Time [HH:MM:SS]	Tiempo de recorrido [HH:MM:SS]
Accel Pedal [%]	Pedal del vehículo eléctrico [%]
Speed [Kmh]	Velocidad de recorrido [Kmh]
SOC [%]	Autonomía del vehículo eléctrico en [%]
Available Charge Power [KW]	Potencia de carga disponible [KW]
Available Discharge Power [KW]	Potencia de descarga disponible [KW]
Battery Current [A]	Corriente de la batería [A]
Battery DC Voltage [V]	Voltaje de la Batería DC [V]
Battery Max Temperature [°C]	Temperatura máxima de la batería [°C]
Battery Min Temperature [°C]	Temperatura mínima de la batería [°C]
Battery Module 1 Temperature [°C]	Módulo de la batería temperatura 1 [°C]
Battery Module 2 Temperature [°C]	Módulo de la batería temperatura 2 [°C]
Battery Module 3 Temperature [°C]	Módulo de la batería temperatura 3 [°C]
Battery Module 4 Temperature [°C]	Módulo de la batería temperatura 4 [°C]
Battery Module 5 Temperature [°C]	Módulo de la batería temperatura 5 [°C]
Battery Inlet Temperature [°C]	Temperatura admisión de la batería [°C]



Max Cell Voltage [V]	Máximo voltaje de celda [V]
Max Cell Voltage [No.]	Máximo voltaje de celda [N°]
Min Cell Voltage [V]	Mínimo voltaje de celda [V]
Min Cell Voltage [No.]	Mínimo voltaje de celda [N°]
Auxiliary Battery Voltage [V]	Voltaje de Batería auxiliar [V]
Cumulative Charge Current [Ah]	Corriente de carga acumulativa [Ah]
Cumulative Discharge Current [Ah]	Corriente de descarga acumulativa [Ah]
Cumulative Charge Energy [kWH]	Energía de carga acumulativa [kWH]
Cumulative Discharge Energy [kWH]	Energía de descarga acumulativa [kWH]
Cumulative Operating Time [Sec]	Tiempo de operación acumulativa [seg]
Inverter Capacitor Voltage [V]	Voltaje del capacitor del inventar [V]
Drive Motor Speed [rpm]	Velocidad de entrada del motor[rpm]
Isolation Resistance [Kohms]	Resistencia del aislamiento [kohms]
Auxiliary Battery Voltage [V]	Voltaje de Batería auxiliar [V]
Motor Actual Speed [rpm]	Velocidad actual del motor [rpm]
Motor Phase Current [A]	Corriente de la fase del motor [A]
Motor Torque Command [Nm]	Comando del torque del motor [Nm]
Estimated Motor Torque [Nm]	Torque del motor estimado [Nm]
Motor Temperature [-C]	Temperatura del motor [°C]
MCU Temperature [-C]	Temperatura MCU [°C]
Head Sink Temperature [-C]	Temperatura de disipador de calor [°C]
Battery Module 6 Temperature [-C]	Módulo de la batería temperatura 6 [°C]
Battery Module 7 Temperature [-C]	Módulo de la batería temperatura 7 [°C]
Battery Module 8 Temperature [-C]	Módulo de la batería temperatura 8 [°C]
SOC Display [%]	Autonomía del monitor display [%]
Gear State P	Estado de engranaje P
Gear State R	Estado de engranaje R
Gear State N	Estado de engranaje N
Gear State D	Estado de engranaje D
Gear State B	Estado de engranaje B
ECO OFF Switch	Interruptor ECO off
Charge Cancel Switch	Interruptor de cancelación de carga
Odometer [Km]	Cuenta Kilómetro
AUTONOMIA TABLERO	Autonomía del tablero en [Kmh]
AUTONOMIA EN Kmh	Autonomía del vehículo en [Kmh]

Tabla 2: Variables obtenidas por el software EmoLab

Fuente: (Orellana, n.d.)

2.3 Clasificación de variables.

Existen diferentes tipos de variables que se adquieren a lo largo de las rutas establecidas, algunas no intervienen en la autonomía directamente, por lo cual se pueden obviar del análisis, a su vez existe variables que influyen directamente con autonomía por tal motivo son tomados



en cuenta para el análisis, a continuación, se describe los diferentes tipos de variables que se presentan en una experimentación, mismas que puede ser definidas como:

2.3.1 Variables de estudio.

Son las variables de entrada que tienen influencia con la respuesta de la definición de autonomía, dichas variables en sus valores pueden ser controlables o no controlables, están definidas por un total de 50 variables, en relación a la información obtenida por el software, sin embargo en una priorización de variables solo se estudia a 5 de ellas (Paucar Urdialez & Sigüenza Reinoso, 2016).

2.3.2 Variables controlables.

Los factores controlables son variables que se puede controlar en el proceso de toma de datos, como el tipo de conducción, velocidad, posición del pedal, entre otras, que para garantizar la repetitividad en estudios similares debe ser consideradas significativamente (Paucar Urdialez & Sigüenza Reinoso, 2016).

2.3.3 Variables no controlables o de ruido

Los factores no controlables son variables que no se modifican a voluntad en las experimentaciones en el proceso de toma de datos, como temperatura del motor, temperaturas de los módulos, entre otras, pero dichas variables deben ser consideradas para medir el grado de influencia que ellas pueden tener en la experimentación, dada la probabilidad de presencia de valores atípicos.

2.3.4 Variables de respuesta.

Las variables de respuesta son las que dan en si el resultado en el proceso, son las variables que tienen una correlación directa con la definición de autonomía, como las variables que definen voltaje.

2.4 Procesamiento de variables.

Para el procesamiento de variables, se requiere que todas estén en las mismas unidades, en este caso se necesita que las variables estén en decimales por lo cual, se realiza una conversión de ciertas variables como son: el tiempo que el software EmoLab V2.0 genera en formato de horas y la autonomía que se tiene en formato de porcentaje, esto se realiza para proceder con la correlación de todas las variables que genera el software.

Para convertir el tiempo desde un formato de hora a decimal se ocupa la siguiente conversión:

La celda en la que se tiene el formato horas (HH:MM:SS) se multiplica por 24, dando así un número decimal del tiempo que se convierte.

Para convertir la autonomía desde un formato de porcentaje (%) a un número decimal y en Kmh se ocupa la siguiente conversión:

Se realiza una regla de tres utilizando la autonomía máxima que tiene el vehículo en Kmh, la misma que es de 167Kmh, sabiendo que esta autonomía equivale al 100% en porcentaje se realiza entonces la regla de tres, así si se quiere transformar 91% de autonomía a kmh en número decimal, queda de la siguiente forma.

$$\begin{array}{ccc} 167\text{Kmh} & \longrightarrow & 100\% \\ X & \longrightarrow & 91\% \end{array}$$



$$\frac{91\% \times 167Kmh}{100\%} = 151.97 Kmh$$

De esta forma se tiene que el 91% de autonomía equivale a 151,97 Kmh de autonomía.

2.5. Discriminación de variables.

Para el proceso de discriminación de variables se usa el software Rstudio, el cual permite realizar la correlación de variables y verificar la relación que existe de cada una de las variables obtenidas por el software EmoLabV2.0 con respecto a la autonomía del automóvil que nos indica el tablero, este proceso se realiza dividiendo en grupos de 5 variables a la vez.

2.5.1 Criterio para la discriminación de variables.

En el presente estudio existe un total de 50 variables, sin embargo, no todas ellas logran tener un alto impacto en la respuesta, por tal motivo se considera aplicar una metodología (correlación de Pearson), para determinar las variables que generan importancia en el resultado de autonomía.

2.5.2. Correlación de Pearson.

La correlación de Pearson es un indicador estadístico que nos ayuda a calcular el porcentaje dependencia que hay entre variables, está detallado por el valor de los coeficientes -R- y se cuantifica en un rango que cambia entre -1 y +1. Cuando el valor es de +1, se toma como una correlación buena y directa; mientras que, si el valor es -1, se interpreta como una correlación perfecta e inversa. Si el valor es R=0, quiere decir en cambio que no hay correlación entre las variables, lo cual expresa que las variables son independientes entre sí (Pedroza & Dicoskyi, 2006).




Figura 16: Fuerzas de correlación de Pearson.

Fuente: Autores.

Según la Figura 16, se considera un grado de coeficiente de correlación de 0.75 como buena o importante, un valor inferior de correlación indica que no tiene significancia en el resultado, un coeficiente alto nos indica que en el resultado se minimizara el error, por tal motivo es indispensable trabajar con las variables que tengan un coeficiente alto mayor a 0.75.

Para realizar la correlación entre todas las variables independientes, respecto a la AUTONOMIA TABLERO, se divide en 10 grupos de 5 variables para conseguir una mejor visión de los valores de los coeficientes y de su comportamiento en un resultado gráfico, los grupos se conforman de la siguiente manera como se muestra en la Tabla 3.



Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
Accel Pedal [%]	Battery Current [A]	Battery Module 2 Temperature [-C]	Max Cell Voltage [V]	Cumulative Charge Current [Ah]
Speed [km]	Battery DC Voltage [V]	Battery Module 3 Temperature [-C]	Max Cell Voltage [No.]	Cumulative Discharge Current [Ah]
Autonomía en kmh	Battery Max Temperature [-C]	Battery Module 4 Temperature [-C]	Min Cell Voltage [V]	Cumulative Charge Energy [kWh]
Available Charge Power [KW]	Battery Min Temperature [-C]	Battery Module 5 Temperature [-C]	Min Cell Voltage [No.]	Cumulative Discharge Energy [kWh]
Available Discharge Power [KW]	Battery Module 1 Temperature [-C]	Battery Inlet Temperature [-C]	Auxiliary Battery Voltage [V]	Cumulative Operating Time [Sec]
Grupo 6	Grupo 7	Grupo 8	Grupo 9	Grupo 10
Inverter Capacitor Voltage [V]	Motor Actual Speed [rpm]	MCU Temperature [-C]	TIEMPO RECORRIDO	Gear State B
Drive Motor Speed [rpm]	Motor Phase Current [A]	Head Sink Temperature [-C]	Gear State P	ECO OFF Switch
Drive Motor Speed [rpm]__1	Motor Torque Command [Nm]	Battery Module 6 Temperature [-C]	Gear State R	Charge Cancel Switch
Isolation Resistance [Kohms]	Estimated Motor Torque [Nm]	Battery Module 7 Temperature [-C]	Gear State N	Odometer [Km]
Auxiliary Battery Voltage [V]__1	Motor Temperature [-C]	Battery Module 8 Temperature [-C]	Gear State D	

Tabla 3: Grupos de variables para proceso de correlación.

Fuente: Autores

2.5.3 Correlación de variables grupo 1.

El análisis estadístico en Rstudio entrega los resultados en forma gráfica y numérica, en la Figura 17, se pueden apreciar los resultados de la correlación y las gráficas que entrega Rstudio de la correlación entre el grupo de variables.




Figura 17: Correlación de variables grupo 1

Fuente: Autores

Se puede apreciar el comportamiento de cada una de las variables (Figura 17) por medio de graficas que se encuentran en la diagonal de la misma, se puede observar la correlación que existe de cada una de ellas con respecto a la autonomía del tablero en la fila superior de la misma. Se puede apreciar que la autonomía en Km tiene una correlación buena de 1 lo que comprueba la veracidad del proceso de correlación considerando que todas las variables se las correlacionan con la autonomía del tablero, en este grupo la variable que se la considera con un grado de correlación bueno es “Available Charge Power [KW]” que tiene una correlación de -0.9. Los resultados de correlación entre variables del grupo 1 se los aprecia en la Tabla 4.

Grupo 1	Correlación
Accel Pedal [%]	0.03
Speed [km]	0.02
Autonomía en kmh	1
Available Charge Power [KW]	-0.9
Available Discharge Power [KW]	NA

Tabla 4: Resultados de correlación de variables grupo 1.

Fuente: Autores.

2.5.4 Correlación de variables grupo 2.

La Figura 18, indica el comportamiento de las variables del grupo 2 con respecto a la autonomía del tablero, se puede apreciar que la variable “Battery DC voltaje [V]” es la que tiene un valor de correlación buena de 0.86, por lo cual es la única de este grupo que se considera para el proceso.




Figura 18: Correlación de variables grupo 2.

Fuente: Autores.

Tabla 5 puede apreciar en la siguiente tabla, los resultados de la correlación de las variables del grupo 2.

Grupo 2	Correlación
Battery Current [A]	0.04
Battery DC Voltage [V]	0.86
Battery Max Temperature [-C]	-0.63
Battery Min Temperature [-C]	-0.72
Battery Module 1 Temperature [-C]	-0.63

Tabla 5: Resultados de correlación de variables grupo 2.

Fuente: Autores.

2.5.5 Correlación de variables grupo 3.

La Figura 19, indica el comportamiento de las variables del grupo 3 con respecto a la autonomía del tablero, se puede apreciar que en este grupo de variables no hay alguna que cumpla con el margen necesario de correlación para considerarlas para el proceso, por este motivo no se consideró ninguna variable de este grupo.




Figura 19: Correlación de variables grupo 3.

Fuente: Autores.

A continuación, en la Tabla 6, se puede apreciar los resultados de la correlación de variables del grupo 3 (Tabla 6).

Grupo 3	Correlación
Battery Module 2 Temperature [-C]"	-0.64
"Battery Module 3 Temperature [-C]"	-0.7
"Battery Module 4 Temperature [-C]"	-0.7
"Battery Module 5 Temperature [-C]"	-0.73
Battery Inlet Temperature [-C]	-0.66

Tabla 6: Resultados de correlación de variables grupo 3.

Fuente: Autores.

2.5.6 Correlación de variables grupo 4.

La Figura 20, indica el comportamiento de las variables del grupo 4 con respecto a la autonomía del tablero, se puede apreciar que las variables "Max cell voltaje [V]" y "Min cell voltaje [V]" son las que tienen un valor de correlación buenas de 0.86 y 0.84 respectivamente, por tal motivo dichas variables son consideradas para el proceso.




Figura 20: Correlación de variables grupo 4.

Fuente: Autores.

A continuación, se puede apreciar los resultados de la correlación de variables del grupo 4. (Tabla 7).

Grupo 4	Correlación
"Max Cell Voltage [V]"	0.86
"Max Cell Voltage [No.]"	-0.02
"Min Cell Voltage [V]"	0.84
"Min Cell Voltage [No.]"	-0.23
"Auxiliary Battery Voltage [V]"	0.3

Tabla 7: Resultados de correlación de variables grupo 4.

Fuente: Autores.

2.5.7 Correlación de variables grupo 5.

La Figura 21, indica el comportamiento de las variables del grupo 5 con respecto a la autonomía del tablero, se puede apreciar que en este grupo de variables no hay alguna que cumpla con el margen necesario de correlación para considerarlas para el proceso, por este motivo no se consideró ninguna variable de este grupo.




Figura 21: Correlación de variables grupo 5.

Fuente: Autores.

En la Tabla 8, es apreciable los resultados de la correlación de variables del grupo 5.

Grupo 5		Correlación
"Cumulative Charge Current [Ah]"		-0.42
"Cumulative Discharge Current [Ah]"		-0.57
"Cumulative Charge Energy [kWh]"		-0.42
"Cumulative Discharge Energy [kWh]"		-0.57
"Cumulative Operating Time [Sec]"		-0.39

Tabla 8: Resultados de correlación de variables grupo 5.

Fuente: Autores.

2.5.8 Correlación de variables grupo 6.

La Figura 22, nos indica el comportamiento de las variables del grupo 6 con respecto a la autonomía del tablero, se puede apreciar que la variable "Inverter capacitor voltaje [V]" es la que tiene un valor de correlación buena de 0.84, por lo cual es la única de este grupo que se considera para el proceso.




Figura 22: Correlación de variables grupo 6.

Fuente: Autores.

En la Tabla 9, son evidentes los resultados de la correlación de variables del grupo 6.

Grupo 6	Correlación
"Inverter Capacitor Voltage [V]"	0.84
"Drive Motor Speed [rpm]"	0.02
"Drive Motor Speed [rpm]__1"	0.02
"Isolation Resistance [Kohms]"	NA
"Auxiliary Battery Voltage [V]__1"	0.31

Tabla 9: Resultados de correlación de variables grupo 6.

Fuente: Autores.

2.5.9 Correlación de variables grupo 7.

La Figura 23, indica el comportamiento de las variables del grupo 7 con respecto a la autonomía del tablero, se puede apreciar que en este grupo de variables no hay alguna que cumpla con el margen necesario de correlación para considerarlas para el proceso, por este motivo no se consideró ninguna variable de este grupo.




Figura 23: Correlación de variables grupo 7.

Fuente: Autores.

Se puede apreciar los resultados de la correlación de variables del grupo 7 (Tabla 10).

Grupo 7	Correlación
"Motor Actual Speed [rpm]"	0.02
"Motor Phase Current [A]"	-0.03
"Motor Torque Command [Nm]"	0.03
"Estimated Motor Torque [Nm]"	0.03
"Motor Temperature [-C]"	-0.73

Tabla 10: Resultados de correlación de variables grupo 7.

Fuente: Autores

2.5.10 Correlación de variables grupo 8.

La Figura 24, indica el comportamiento de las variables del grupo 8 con respecto a la autonomía del tablero, se puede apreciar que en este grupo de variables no hay alguna que cumpla con el margen necesario de correlación para considerarlas para el proceso, por este motivo no se consideró ninguna variable de este grupo.




Figura 24: Correlación de variables grupo 8.

Fuente: Autores.

La Tabla 11, indica los resultados de la correlación de variables del grupo 8.

Grupo 8	Correlación
"MCU Temperature [-C]"	-0.12
"Head Sink Temperature [-C]"	-0.64
"Battery Module 6 Temperature [-C]"	-0.7
"Battery Module 7 Temperature [-C]"	-0.68
"Battery Module 8 Temperature [-C]"	-0.61

Tabla 11: Resultados de correlación de variables grupo 8.

Fuente: Autores

2.5.11 Correlación de variables grupo 9.

La Figura 25, indica el comportamiento de las variables del grupo 9 con respecto a la autonomía del tablero, se puede apreciar que en este grupo de variables no hay alguna que cumpla con el margen necesario de correlación para considerarlas para el proceso, por este motivo no se consideró ninguna variable de este grupo.




Figura 25: Correlación de variables grupo 9.

Fuente: Autores.

La Tabla 12, expresa los resultados de la correlación de variables del grupo 9.

Grupo 9	Correlación
"TIEMPO RECORRIDO"	-0.5
"Gear State P"	NA
"Gear State R"	NA
"Gear State N"	0.02
"Gear State D"	-0.01

Tabla 12: Resultados de correlación de variables grupo 9.

Fuente: Autores.

2.5.12 Correlación de variables grupo 10.

La Figura 26, indica el comportamiento de las variables del grupo 10 con respecto a la autonomía del tablero, se puede apreciar que en este grupo de variables no hay alguna que cumpla con el margen necesario de correlación para considerarlas para el proceso, por este motivo no se consideró ninguna variable de este grupo.




Figura 26: Correlación de variables grupo 10.

Fuente: Autores.

En la Tabla 13, se puede visualizar los resultados de la correlación de variables del grupo 10.

Grupo 10	Correlación
"Gear State B"	NA
"ECO OFF Switch"	NA
"Charge Cancel Switch"	NA
"Odometer [Km]"	-0.61

Tabla 13: Resultado de correlación de variables grupo 10.

Fuente: Autores

2.5.13 Variables influyentes.

Una vez realizada la correlación de todas las variables con respecto a la autonomía del tablero se tiene la

Tabla 14, en la cual es apreciable las variables que tienen mayor porcentaje de correlación con respecto a la autonomía del tablero y con las que se procede a realizar la regresión del estudio de autonomía.

Variables mas influyentes	Correlación
Available Charge Power [KW]	-0.9
Battery DC Voltage [V]	0.86
"Max Cell Voltage [V]"	0.86
"Min Cell Voltage [V]"	0.84
"Inverter Capacitor Voltage [V]"	0.84



Tabla 14: Variables más influyentes.

Fuente: Autores




Figura 27: Resultado de correlación de las variables influyentes.

Fuente Autores.



Capítulo 3

OBTENCION DE MODELO MATEMATICO

En el presente capítulo se obtiene el modelo matemático que permite definir la autonomía del vehículo eléctrico kia Soul en las rutas establecidas en el proyecto de titulación de (Bueno Juela & Quizhpe Sinchire, 2017) dentro de la ciudad de Cuenca, aplicando máquinas de soporte vectorial para regresión. Este proceso se realiza en el software estadístico “Rstudio”.

3.1 Support Vector Regresión (SVR)

Las máquinas de soporte vectorial para regresión se usan para resolver problemas multidimensionales, usando la misma estrategia de la clasificación, se puede abordar una regresión, la idea general es usar un hiperplano regresor que se pueda ajustar de mejor manera al conjunto de datos de entrenamiento, de esta manera no se dispone de clases para separar, a su vez todos los conjuntos de vectores de soporte se tiene de un solo lado del hiperplano, también es posible trabajar con modelos no lineales y por medio de una función Kernel se puede convertir en un modelo lineal de esta manera se facilitaría el proceso regresor (Martín Guareño, 2016).

3.2 Funcionamiento de la SVR

Las máquinas de soporte vectorial para regresión nos permiten tratar problemas multidimensionales y así poder definirlos por medio de una ecuación lineal, el funcionamiento de la máquina de soporte vectorial para regresión es extenso y se abastece de una matemática muy compleja que el software “Rstudio” lleva ya programado en sus funciones, en resumen la (SVR) realiza lo siguiente: la máquina de soporte vectorial para regresión trata de encontrar los parámetros $w = (w_1, \dots, w_n)$ para que la función se ajuste al modelo lineal óptimo $f(x) = (w_1, x_1 + \dots + w_d, x_d) + b$, por medio de un conjunto de datos de entrenamiento $s = \{(x_1, y_1), \dots, (x_n, y_n)\}$, donde $x_i \in \mathbb{R}^d$ e $y_i \in \mathbb{R}$, de esta manera los valores de y_i se pueden llegar ajustar mediante una función lineal implícita en el proceso de las (MVR) (Carmona Suárez, 2014).

3.3 Kernels y tipos

Los kernels son funciones que trabajan con un modelo no lineal llegando a optimizar dicho modelo y convertirlo a un modelo lineal, existen diferentes tipos de kernels cada uno puede proporcionar diferentes resultados (Pérez Soria, 2017).

Los tipos de Kernels son los siguientes:



- Polinomial
- Función de base Radial
- Sigmoideos
- Lineal

Uno de los aspectos más importantes de trabajar con kernels dentro de máquina de soporte vectorial para regresión es que se tiene la posibilidad de trabajar con muchas dimensiones.




Figura 28: Comportamiento de función Kernel

Fuente:(Pérez Soria, 2017)

3.4 Validación cruzada

Cuando se refiere a la validación cruzada en un análisis estadístico de una base de datos, nos referimos a la técnica que se utiliza, con el fin de evaluar los resultados del análisis que se realiza y también para garantizar que los datos, son independientes de la división entre datos de entrenamiento y datos de prueba. Existen dos métodos que brindan buenos resultados al momento de validar los parámetros de un modelado, estos son: validación cruzada y validación Bootstrap, de estos dos métodos se puede considerar según trabajos realizados, que el de Bootstrap brinda mejores resultados por tener un mejor respuesta de varianza (Pérez Soria, 2017), sin embargo este método requiere mayor coste computacional, por lo que en este caso utiliza la validación cruzada.

Dentro del método de validación cruzada, existen tres tipos que son:

- K-fold cross validation
- Random cross validation
- Leave one out cross validation

Tomando en cuenta los costes computacionales más adecuados para nuestro caso, se ha optado por realizar el tipo K-fold cross validation, el mismo que consiste en separar la base de datos pura, en dos conjuntos: uno para entrenar y otro para validar. Siendo 9090 datos en total, de los cuales se toman el 50% de datos para entrenar, es decir 4545, y para la validación cruzada ocupamos 1010 datos del conjunto de entrenamiento, de esta manera $9090/1000 = 9$, siendo $k=9$ el número de iteraciones, esto quiere decir que los 1010 datos para la validación cruzada van rotando de 1010 en 1010 en cada iteración hasta cumplir con todo el total de 9090 muestras, como se muestra en la Figura 29 (Pérez Soria, 2017).




Figura 29: procedimiento de la validación cruzada.

Fuente: (Pérez Soria, 2017)

3.5 Generación del modelo.

A continuación se introduce la base de datos en el software “Rstudio”, dicha base de datos está compuesta por 6 variables, de las cuales una es dependiente (AUTONOMIA) y las 5 son independientes (AvailableChargePower, Battery Voltage, Max Cell Voltage, Min Cell Voltage, InverterCapacitorVoltage), con un total de 9090 datos para cada variable, en el proceso de modelado existe 3 conjuntos de datos que son fundamentales, el primero es el conjunto de datos de entrenamiento, este representa los datos que se toma para entrenar a la máquina de soporte vectorial para regresión, en nuestro estudio es el 50% de datos es decir 4545, el segundo es el conjunto de datos de validación que sirve para poder seleccionar los mejores modelos que se ajuste más a nuestros intereses que en nuestro estudio fue 50% de datos.

Para obtener el mejor modelo que más se ajuste a la autonomía del vehículo eléctrico, se realiza una selección entre los diferentes tipos de regresión que existen en las máquinas de soporte vectorial y los diferentes kernels que se pueden aplicar, esto mediante la selección del método que tenga menos error, para ello se da a conocer los tipos de regresión que nos brinda las SVM, existen dos tipos de regresiones que nos permite trabajar las máquinas de soporte vectorial para regresión, estas tienen diferente manera de trabajar con los vectores, de las cuales se menciona a continuación.

- Eps-regresion o (Epsilon-SVR), se caracteriza por generar mejor confiabilidad en su resultado, por la falta de control sobre cuantos vectores se convierte en vectores de soporte, de esta manera puede trabajar con pocos vectores o con una cantidad muy grande de vectores, de esta manera se obtiene un mejor resultado, aunque el proceso sea más demorado, de la misma manera genera un error menor al de otros procesos.
- Nu-regresion trabaja igual que eps-regresion con la única diferencia que este controla la cantidad de vectores que se convierten en vectores de soporte, es decir, menor cantidad de vectores de soporte que eps-regresion, su manejo es muy útil para procesos rápidos y respuestas simples.

Cada tipo de regresión usa diferentes kernels (Lineal, Polinomial, radial y sigmoide) el software Rstudio nos entrega los resultados de cada uno de estos kernels en las dos regresiones, es aquí donde se escoge el mejor modelo que más se acerque a nuestros requerimientos.



El tercer conjunto de datos de test, sirve para poder medir el error del modelo que se seleccionó como óptimo, este conjunto de datos es tomado de manera implícita por la máquina de soporte vectorial para regresión.

3.6 Optimización del modelo.

Para seleccionar el modelo más ajustado primero hay que seleccionar el Kernel que mejor se ajuste y para ello hay que tener presente algunos aspectos que entrega el software, uno de ellos es el valor de MSE (error cuadrático medio), se obtiene dividiendo la suma de los cuadrados del error y representa el la variación que existe en torno a la línea de regresión que se encuentra ya ajustada, de esta manera nos indica si los términos del modelo son significativos o no, si el valor es pequeño significa que se ajusta más a la línea de regresión (Lehmann & Casella, 1998). Otro valor que entrega el software Rstudio es R^2 (coeficiente de determinación) representa el valor de aceptación con respecto a la variable independiente, en nuestro estudio representa el valor de aceptación con respecto a la Autonomía del tablero.

eps-regression		LINEAL	POLINOMIAL	RADIAL	SIGMOIDE
	suport vectors	3096	4038	2408	4539
	MSE	17,78538	55,40221	8,301489	3795704
	R^2	85,88%	66,92%	93,47%	11,49%
	$R^2(\text{test})$	85,74%	54,99%	93,08%	11,32%

Tabla 15: elementos para selección del mejor Kernel de eps-regression.

Fuente: Autores

Se puede apreciar en la Tabla 15, los resultados entregados por el software Rstudio de los tipos de kernels en tipo de regresión “eps-regresion”, como se mencionó anteriormente se considera el MSE y el valor de R^2 , de esta manera se selecciona el Kernel que más se ajuste a la línea de regresión, y el que menos porcentaje error genere, analizando la Tabla 15, el Kernel que mejor se adapta a nuestras condiciones es el radial puesto que el valor de MSE es el más pequeño a comparación de los otros kernels (8,301489) y el valor de aceptación con respecto a la variable independiente R^2 es mayor (93,47%), de esta manera se ha seleccionado para este tipo de regresión el Kernel Radial como el mejor para nuestro estudio.

nu-regression		LINEAL	POOLINOMIAL	RADIAL	SIGMOIDE
	suport vectors	2280	2280	2304	2274
	MSE	17,41614	52,72513	8,297896	2131803
	R^2	86,1%	57,36%	93,43%	4,14%
	$R^2(\text{test})$	86,04%	56,52%	93,03%	4,07%

Tabla 16: Elementos para selección del mejor Kernel de nu-regression.

Fuente: Autores

En la Tabla 16, se distingue los resultados entregados por el software Rstudio de los tipos de kernels para el tipo de regresión “nu-regression”, con las mismas consideraciones que se analizó la Tabla 15, se decidió que el mejor Kernel para este tipo de regresión en la Tabla 16, es



el Kernel radia con un valor de MSE de 8,297896 y un R^2 de 93,43%. De esta manera para ambos tipos de regresiones se decidió que los mejores kernels son los radiales.

3.7 Selección del modelo efectivo.

Luego de seleccionar el mejor kernel de cada tipo de regresión que nos permite las SVMs (eps-regression, nu-regression), que en este caso es el kernel Radial para ambos casos, se procede a sacar mediante el software computacional, los coeficientes para la ecuación del modelo tanto del tipo nu-regression como para el eps-regression.

Se debe tener en cuenta que cada x de la ecuación corresponde a una variable en sí, de la siguiente forma:

Y	—————>	AUTONOMIA
X1	—————>	Available Charge Power
X2	—————>	Battery Voltage
X3	—————>	Max Cell voltaje
X4	—————>	Min Cell voltaje
X5	—————>	Inverter Capacitor Voltage

```
Call:
lm(formula = AUTONOMIA ~ AvailableChargePower + `Battery voltage` +
`Max cell voltage` + `Min Cell voltage` + InverterCapacitorVoltage,
data = testdata, subset = predepsradial)

Residuals:
    Min       1Q   Median       3Q      Max
-0.31251 -0.03753  0.00242  0.03326  0.47204

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)    234.592995   0.478776  489.985 < 2e-16 ***
AvailableChargePower -0.916220   0.004279 -214.135 < 2e-16 ***
`Battery voltage` -0.053532   0.007113  -7.526 6.26e-14 ***
`Max cell voltage`  3.757026   0.338075  11.113 < 2e-16 ***
`Min cell voltage` -2.691360   0.282944  -9.512 < 2e-16 ***
InverterCapacitorVoltage  0.008726   0.003516   2.482  0.0131 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.09708 on 4539 degrees of freedom
Multiple R-squared:  0.9377,    Adjusted R-squared:  0.9376
F-statistic: 1.366e+04 on 5 and 4539 DF, p-value: < 2.2e-16
```

Figura 30: Datos de eps-regression con kernel radial.

Fuente: Autores

La Figura 30, expresa los datos generados por el software Rstudio, donde se tiene en la columna de Estimación, los coeficientes para cada variable independiente así como el valor de la constante que interviene en la forma principal de la ecuación, así mismo el software nos permite visualizar el RSE en la parte inferior, en este caso es de 0.09708, en la figura también se observa el valor de R^2 que es de 0.9377 que pasando a porcentaje es 93,77% de ajuste lineal del modelo.



Por lo tanto, la ecuación modelo del tipo eps-regression con kernel radial nos queda de la siguiente forma:

$$y = 234,592995 - 0,916220 X1 - 0,053532 X2 + 3,757026 X3 - 2,691360 X4 + 0,008726 X5$$

```
Call:
lm(formula = AUTONOMIA ~ AvailableChargePower + `Battery voltage` +
  `Max Cell voltage` + `Min Cell voltage` + InverterCapacitorVoltage,
  data = testdata, subset = prednuradial)

Residuals:
    Min       1Q   Median       3Q      Max
-0.26241 -0.04126  0.00709  0.02201  0.50083

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)    233.019062    0.514187   453.179 < 2e-16 ***
AvailableChargePower -0.933099    0.004530  -205.978 < 2e-16 ***
`Battery voltage` -0.106856    0.006831   -15.643 < 2e-16 ***
`Max Cell voltage`  3.370113    0.362361    9.300 < 2e-16 ***
`Min Cell voltage`  1.550861    0.297040    5.221 1.86e-07 ***
InverterCapacitorVoltage 0.029270    0.003350    8.737 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.1023 on 4539 degrees of freedom
Multiple R-squared:  0.9308,    Adjusted R-squared:  0.9307
F-statistic: 1.221e+04 on 5 and 4539 DF,  p-value: < 2.2e-16
```

Figura 31: Datos de nu-regression con Kernel radial.

Fuente: Autores

De igual forma en la Figura 31, se observa los datos para el modelado de tipo nu-regression, donde se observa en la columna de “estimate” los valores que toman cada coeficiente de la ecuación, se aprecia el valor del RSE que es de 0,1023 y el R^2 en este caso es de 0,9308 que en porcentaje es 93,08% de ajuste lineal al modelo.

Por lo tanto, la ecuación modelo del tipo eps-regression con kernel radial nos queda de la siguiente forma:

$$y = 233,019062 - 0,933099 X1 - 0,106856 X2 + 3,370113 X3 + 1,550861 X4 + 0,029270 X5$$

3.8 Ecuación del modelo de autonomía.

Luego de obtener los dos modelos con eps-regression y nu-regression respectivamente, observando los valores de $R^2 = 93,77\%$ para eps-regression y de $R^2 = 93,08\%$ para nu-regression, se verifica que el primer método es el de mejor ajuste de acuerdo a su R^2 que es mayor, por lo que se selecciona como la mejor regresión y la ecuación definitiva que se opta por escoger es la siguiente:

$$y = 234,592995 - 0,916220 X1 - 0,053532 X2 + 3,757026 X3 - 2,691360 X4 + 0,008726 X5$$



Quedando de esta manera definida la ecuación de nuestro modelo para autonomía del vehículo eléctrico Kia Soul.




Capítulo 4

VALIDACION DE RESULTADOS

Se establece un modelo matemático lineal para la definición de autonomía mediante máquinas de soporte vectorial para regresión, la validación de este resultado se realiza un análisis de variables influyentes vs respuesta de autonomía, y el análisis de las gracias de residuos para cada una de las variables vs la respuesta de autonomía.

4.1 Análisis de variables influyentes vs Autonomía del tablero.

En el presente estudio las variables seleccionadas con un valor de correlación mayor (0.75) con respecto a la autonomía del tablero son en función de voltaje, dando mucha lógica a dicha correlación dado que una disminución de autonomía se verá reflejado en el consumo de voltaje y por ende la disminución de voltaje en sus baterías, se puede apreciar dicho comportamiento en las siguientes figuras de cada una de las variables más influyentes vs la autonomía del tablero.





Fuente: Autores

La Figura 32, expresa el comportamiento de la variable dependiente “Available charge power”, claramente se observa que tiene una tendencia o correlación negativa, es decir es inversamente proporcional a la autonomía del tablero, lo que justifica que en el análisis de correlación de variables obtuvimos un valor de -0.9 que se puede observar en la tabla 3, es decir a mayor autonomía disponible menor porcentaje de carga disponible, es un valor netamente influyente en el cual se ve reflejado el comportamiento de autonomía.




Figura 33: Autonomia del tablero vs Battery DC Voltage.

Fuente: Autores

La Figura 33, se puede apreciar el comportamiento de la variable “Battery Dc voltaje” en este caso tiene un comportamiento proporcional al de la Autonomía del tablero, con un porcentaje de correlación de 0.86 indica el comportamiento de autonomía.




Figura 34: Autonomia del tablero vs Min Cell Voltage [V].

Fuente: Autores

En la Figura 34, se puede observar el comportamiento de la variable “min cell voltage”, indicando claramente la tendencia de la misma con respecto a la autonomía del tablero, con una correlación de 0.86 refleja el comportamiento de la autonomía.




Figura 35 Autonomía del Tablero vs Min Cell Voltage [V].

Fuente: Autores

En la Figura 35, se puede apreciar el comportamiento de la variable “Min cell voltage”, que indica claramente el comportamiento de dicha variable con respecto a la autonomía del



tablero, se puede apreciar que ambas graficas tienen la misma tendencia en su comportamiento lo que significa que ambas tienen relación en sí.




Figura 36: Autonomía del tablero vs Inverter Capacitor Voltage [V].

Fuente: Autores.

La Figura 36, indica el comportamiento de la variable “Inverter capacitor Voltage” vs la Autonomía del tablero, se puede apreciar que ambas graficas tienen la misma tendencia de esta manera se puede corroborar la correlación que existen entre si.

4.2 Análisis del error de la ecuación lineal vs autonomía del tablero.

Con la ecuación lineal del modelo de autonomía, se obtiene un valor de la base de datos para poder realizar el cálculo del error que da nuestro modelo, en la Tabla 17, se puede apreciar los valores tomados para el presente análisis.

AUTONOMIA TABLERO	153.64
Available Charge Power [KW]	74.15
Battery DC Voltage [V]	387.8
Max Cell Voltage [V]	4.04
Min Cell Voltage [V]	4.02
Inverter Capacitor Voltage [V]	388

Tabla 17: Valores aleatorias de las variables más influyentes.

Fuente Autores

$$y = 234,592995 - 0,916220 X1 - 0,053532 X2 + 3,757026 X3 - 2,691360 X4 + 0,008726 X5$$

$$y = 234,592995 - 0,916220 (74.15) - 0,053532 (387.8) + 3,757026 (4.04) - 2,691360 (4.02) + 0,008726 (388)$$



$$y = 153.6403782$$

Sabiendo que el valor de la autonomía del tablero es de 153.64, se realiza la diferencia de la autonomía del tablero vs el modelo de autonomía de nuestra ecuación.

$$\text{Diferencia} = 153.6403782 - 153.64$$

$$\text{Diferencia} = 0.0003782$$

Para hallar el porcentaje de error con respecto a la autonomía del tablero, se realiza una regla de 3 donde el valor de la autonomía del tablero representa el 100% de autonomía para esos valores y el porcentaje de la diferencia entre el modelo lineal calculado vs la autonomía representaría el error de nuestro modelo.

153.64	→	100%
0.0003782	→	0.00024619 %
$e = 0.00024619$		

Estadísticamente el error máximo aceptable para un modelo es del 5%, en este estudio está demostrado que el error es muy bajo lo que representa que este modelo muy cercano al valor teórico.




Figura 37: Error de Autonomía calculada vs Autonomía del tablero.

Fuente: Autores.

La Figura 37, indica el comportamiento de autonomía del tablero vs la autonomía calculada con toda la base de datos ya aplicado la máquina de soporte vectorial para regresión.

En la Figura 38, se puede apreciar el comportamiento de la autonomía del tablero con una coloración azul, la autonomía calculada con una coloración gris y el error a lo largo de estas dos, se encuentra con una coloración marrón, se puede apreciar que el error está muy cerca de la línea del cero, es decir que el error en general tiene una tendencia muy pequeña como ya se demostró analíticamente.




Figura 38: Comportamiento del error vs autonomía calculada y autonomía del tablero.

Fuente: Autores

4.3 Análisis Estadístico.

El análisis estadístico nos sirve para poder validar el resultado obtenido por medio de la estadística numérica, de tal manera llegara a detalles que se verán reflejados en los resultados estadísticos, el proceso estadístico será realizado con respecto a la diferencia que existe entre la autonomía del tablero vs la autonomía obtenida en este estudio.

4.3.1 Varianza

El análisis de la varianza nos ayuda a saber si en el resultado existe significancia entre conjunto de datos, es el promedio de las desviaciones al cuadrado del conjunto de datos con respecto a la media, de tal manera que un valor de varianza grande nos indica que los datos se encuentran más dispersos entre sí, y un valor de varianza bajo nos indica que los datos se encuentran más apegados a la media(Gras Llopis, 2010).

En el presente estudio usando los valores en porcentaje de error obtenido entre la autonomía del tablero vs la autonomía obtenida en el estudio, se tiene una varianza igual a:

$$v = 48,26$$

Estadísticos descriptivos: autonomia kernel eps radial

Estadísticas

Variable	N	N*	Desv.Est.	Varianza
autonomia kernel eps radial	9090	0	6.95	48.26

Figura 39: Resultado de varianza obtenido por el software Minitab.

Fuente: Autores

4.3.2 Aleatoriedad

El análisis de aleatoriedad se realiza a los datos de las variables que son recopilados en un intervalo de tiempo regulares, dicho análisis nos ayuda a verificar que los sucesos siguen un comportamiento y a verificar si existe algún comportamiento fuera de lo normal, en la Figura 40, se puede analizar el comportamiento de todas las variables representadas en la autonomía calculada por medio de máquina de soporte vectorial para regresión, se puede observar que tiene un punto (3905) en el que la autonomía demuestra un cambio significativo en su comportamiento elevando el valor del mismo, este punto anormal en el comportamiento se da debido a que en la toma de datos en este punto se volvió a cargar el vehículo eléctrico, de esta manera, todos los valores que se tiene de las variables influyentes (voltajes) toman valores que representan al vehículo eléctrico con carga en sus baterías, lo que representa mayor autonomía disponible desde este punto. Existen otros puntos que se puede verificar saltos altos y bajos en su comportamiento, dichos puntos se los considera como reacciones a situaciones adversas propias de cada ruta tales como, congestionamiento en el tráfico, radio encendida, aire acondicionado encendido, aumento de velocidad, variables no controlables, variables de ruido, entre otras.




Figura 40: Serie de tiempo de autonomía calculada.

Fuente: Autores.

4.3.3 Normalidad

En la Figura 41, se puede observar el comportamiento de la autonomía tras ser aplicada la máquina de soporte vectorial para regresión, se puede apreciar claramente en la figura que no existe un patrón que marque una normalidad trazada en su comportamiento, lo que nos indica que estos datos son producto de la experimentación.




Figura 41: Prueba de normalidad en Minitab.

Fuente: Autores

4.3.4 Análisis de residuos

En el proceso de regresión, se genera un modelo matemático de autonomía, la diferencia entre el valor teórico y el valor calculado en el análisis experimental se lo llama residuo o error, el análisis de residuos se encarga de analizar las variables que se utilizó para la obtención de dicho modelo, de esta manera se determina si alguna variable genera algún problema en la respuesta de autonomía. La autonomía del vehículo eléctrico está definida por el comportamiento de voltaje en sus variables, algunas graficas muestran dichas tendencias en sus resultados.

4.3.4.1 Graficas de residuos para Available charge power.

En la Figura 42, se observa que el comportamiento de la gráfica la cual tiende a seguir el comportamiento lineal, lo que indica que el error tiene una distribución normal, se tiene un pequeño aumento del error en la parte final de la gráfica, sin embargo dicho error se encuentra por debajo del 5% dentro del rango de tolerancia aceptable.




Figura 42: Grafica de Probabilidad para available charge power.

Fuente: Autores.

En el histograma de la Figura 43, se observa que los resultados obtenidos están formando parte de una campana de gauss, de esta manera se corrobora los resultados de normalidad mencionados anteriormente.




Figura 43: Histograma para available charge power.



Fuente: Autores

La Figura 44, expresa el comportamiento del valor ajustado o varianza, los puntos de residuos se encuentran dispersos lo que indica que no existe un patrón, sin embargo, se tiene puntos influyentes que encuentran separados de los otros en el eje x, esto significa diferentes eventos en la toma de datos a lo largo de las rutas.




Figura 44: Valor ajustado para available charge power.

Fuente Autores.

En la Figura 45, se observa los valores obtenidos sigue un comportamiento normal de dispersión de puntos, sin embargo es notable que sigue el modelo de autonomía, por lo que se establece que la variable available charge power afecta de manera sistemática a la respuesta de autonomía.




Figura 45: Orden de observación de available charge power.

Fuente: Autores.

4.3.4.2 Graficas de residuos para battery dc voltaje.

En la Figura 46, se aprecia el comportamiento lineal de los residuos, lo que indica que el error tiene una distribución normal, se observa un aumento del error en la parte final, esto debido a las variables de ruido o no controlables, sin embargo, el error se encuentra por debajo del 5% del rango de tolerancia.




Figura 46: Grafica de probabilidad para battery dc voltage.

Fuente: Autores.

En la Figura 47, se aprecia que los resultados obtenidos forman parte de una campana de gauss, de esta manera se corrobora los resultados de normalidad mencionados anteriormente.




Figura 47: Histograma para battery dc voltage.



Fuente: Autores.

En la Figura 48, se aprecia el comportamiento del valor ajustado o varianza, se observa la aleatoriedad de los datos y a su vez un patrón muy pequeño en la gráfica, este efecto se debe a que el valor de la batería del vehículo siempre va a ir disminuyendo con respecto al consumo de autonomía, sin embargo, es el comportamiento adoptado se da por la discretización de la toma de datos, esto indica que no son datos continuos y caen en repeticiones continuas.




Figura 48: Valor ajustado para battery dc voltage.

Fuente: Autores

En la Figura 49, se distingue claramente que los resultados muestran comportamiento aleatorio normal, sin embargo tiene una tendencia que sigue el modelo de autonomía, por lo que se establece que la variable “battery dc voltage” afecta de manera sistemática a la respuesta de autonomía.




Figura 49: Orden de observacion para battery dc voltage.

Fuente: Autores

4.3.4.2 Graficas de residuos para Max cell voltaje.

En la Figura 50, se observa el comportamiento de la gráfica, tiende a seguir el comportamiento lineal, lo que indica que el error tiene una distribución normal de probabilidad, se distingue al final de la gráfica un incremento del error, este efecto se da por variables no controlables o de ruido, sin embargo, dicho incremento del error no afecta el resultado dado que el mismo no excede el 5% de rango de tolerancia aceptable.




Figura 50: Grafica de probabilidad para max cell voltage.

Fuente: Autores

En la Figura 51, se distingue que la gráfica pertenece a una gráfica de distribución normal (campana de gauss), lo que indica que los resultados caen dentro de una población normal, corroborando el análisis de la Figura 50.




Figura 51: Histograma para max cell voltage.



Fuente: Autores

En la Figura 52 de valor ajustado o varianza, es apreciable un patrón en su gráfica, esto se debe a la discretización de la toma de datos, valor de voltaje de cada celda está constantemente en proceso de carga y descarga repitiendo constantemente sus valores, sin embargo, el voltaje de cada una de las celdas son aleatorios pero muy repetitivos, es por este motivo que la gráfica tiende a generar un patrón de saltos en el eje x.




Figura 52: Valor ajustado para max cell voltage.

Fuente: Autores.

En la gráfica de “orden de observación” vs “max cell voltaje” de la Figura 53, se aprecia que los resultados siguen un comportamiento aleatorio normal, sin embargo es apreciable una tendencia de consumo de autonomía mas no un patrón repetitivo, determinando que la variable “max cell voltage” afecta de manera sistemática a la respuesta de autonomía.




Figura 53: Orden de observación para max cell voltage.

Fuente: Autores

4.3.4.3 Graficas de residuos para Min cell voltaje.

En la Figura 54, se distingue el comportamiento de la gráfica al seguir un comportamiento lineal, lo que indica que el error tiene una distribución normal, se tiene un pequeño aumento del error al final de la gráfica, esto debido a variables de ruido o factores no controlables, sin embargo, no afecta a los resultados debido que este error está por debajo del 5% dentro del margen tolerable.




Figura 54: Grafica de probabilidad para min cell voltage.

Fuente: Autores

La Figura 55, indica el comportamiento del histograma para “min cell voltage”, es notable que cae dentro de una campana de gauss, de esta manera se corrobora los resultados de normalidad para la variable.




Figura 55: Histograma para min cell voltage.



Fuente: Autores

La Figura 56, demuestra el comportamiento de valor ajustado o varianza, es apreciable un patrón en su gráfica en forma de saltos correspondientes al eje x, esto se debe a la discretización de la toma de datos correspondiente a los voltajes de las baterías, sin embargo, los valores de voltaje son aleatorios pero a la vez muy repetitivos, por tal motivo la gráfica tiende a generar un patrón a lo largo del eje x.




Figura 56: Valor ajustado para min cell voltage.

Fuente: Autores.

En la Figura 57, que representa “orden de observación”, se aprecia un comportamiento normal aleatorio de valores, sin embargo, existe una tendencia de comportamiento que responde al de autonomía, este efecto se da por el tipo de correlación que existe entre la variable y la respuesta, determinando que la variable “min cell voltage” afecta de manera sistemática la respuesta de autonomía.




Figura 57: Orden de observacion para min cell voltage.

Fuente: Autores.

4.3.4.4 Graficas de residuos para Inverter capacitor voltaje

La Figura 58, demuestra la disposición lineal de la gráfica de probabilidad para “invertir capacitor voltage”, lo que indica que el error tiene una distribución normal, sin embargo, al final de la gráfica es visible un aumento del residuo, el mismo que se da por variables de ruido o no controlables, no obstante, dicho aumento de residuo no afecta el resultado considerando que el error sigue por debajo del margen de tolerancia del 5%.




Figura 58: Grafica de probabilidad para inverter capacitor voltage.

Fuente: Autores.

En la Figura 59, es notable la campana de gauss que se forma con los resultados del residuo, lo que corrobora los resultados de normalidad en la gráfica de probabilidad (Figura 58).




Figura 59: Histograma para inverter capacitor voltage.

Fuente: Autores.



En la Figura 60, se observa el valor ajustado o varianza, los puntos de residuo se encuentran dispersos lo que indica que la varianza es constante, no obstante, es notable un patrón de comportamiento en el eje x, dicho patrón se debe a la discretización de la toma de datos, es decir a los procesos como: descarga - carga de la batería, de esta manera se forman saltos a lo largo del eje x.




Figura 60. Valor ajustado para inverter capacitor voltage.

Fuente: Autores.

En la Figura 61, se aprecia que el valor obtenido sigue un comportamiento normal aleatorio, sin embargo, tiende a adoptar el modelo de autonomía, por lo que se establece que la variable “inverter capacitor voltage” afecta de manera sistemática a la respuesta de autonomía.




Figura 61: Orden de observación para inverter capacitor voltage.

Fuente: Autores.



Conclusiones

- Por medio del estado del arte, se llegó a detallar conceptualmente al vehículo eléctrico, determinando sus partes principales y su funcionamiento, de esta manera se pudo llegar a comprender la necesidad de definir un modelo matemático de autonomía, para que el vehículo eléctrico consiga entrar en el mercado automotriz en la ciudad de Cuenca.
- Para la obtención del modelo matemático se concluye que el uso de máquinas de soporte vectorial, es de suma importancia ya que mejora los resultados en cuanto a precisión, al ser las máquinas de soporte vectorial una herramienta de algoritmos de aprendizaje, mejoran notablemente la respuesta en el modelo de regresión por la forma en la que trabajan.
- La base de datos que genera el software EmoLab V2.0 está constituida de varias variables que interviene en el funcionamiento de un vehículo eléctrico, sin embargo, es importante realizar una selección mediante la correlación de Pearson de las variables más significativas e influyentes en relación con la autonomía, para de esta forma obtener un modelo más ajustado y de mejor precisión.
- Mediante el análisis de residuos se estableció que el resultado obtenido tiene un grado de confianza alto, además se pudo apreciar que las variables seleccionadas como influyentes adoptan el comportamiento de autonomía en cada uno de los análisis realizados para la validación de resultados.
- La aplicación de la herramienta de máquinas de soporte vectorial, tiene gran importancia en este proyecto donde se aplica regresión, ya que al ser una herramienta que trabaja con datos de entrenamiento y validación, genera con más precisión un modelo matemático, debido a que minimiza el error estructural que se da por datos que tienen demasiada desviación con respecto al hiperplano, las máquinas de soporte vectorial no toman en cuenta estos datos por lo que genera una regresión solamente con los datos que más se aproximan al hiperplano.



Recomendaciones

- Para estudios que se puedan realizar a futuro, se recomienda realizar una toma de datos general, es decir con una sola carga del vehículo eléctrico al 100%, realizando la toma de todos hasta que la autonomía se agote por completo, des esta manera se podría tener una mejor continuidad de la descarga
- Para estudios que se puedan realizar a futuro, se recomienda realizar una toma de datos general, es decir con una sola carga del vehículo eléctrico al 100%, realizando la toma de todos hasta que la autonomía se agote por completo, des esta manera se podría tener una mejor continuidad de la descarga.
- En la toma de datos se recomienda minimizar la frecuencia del tiempo, es decir por fracciones de segundo, de esta manera se podría llegar a obtener resultados con mayor precisión.
- Se recomienda realizar el mismo estudio de la autonomía en el vehículo eléctrico Kia Soul, en otras ciudades del país, debido a que el comportamiento del vehículo es diferente en otras regiones.
- Se recomienda realizar el análisis de la autonomía en el vehículo eléctrico, mediante otros métodos de modelado, con el fin de mejorar los resultados obtenidos.



Bibliografía

- Ariza, F. ., Pinilla, C., & García, J. . (2000). Comparación de matrices de confusión celda a celda mediante bootstrapping, 7. Retrieved from http://coello.ujaen.es/ asignaturas/pcartografica/pqcarto/CPQC28/Bootstrapping_Matric es_Confusion.pdf
- Bermeo, M. E., & Cueva, M. A. (2015). *La Universidad Católica de Loja. UNIVERSIDAD TÉCNICA PARTICULAR DE LOJA La Universidad Católica de Loja.*
- Bueno Juela, C. M., & Quizhpe Sinchire, J. C. (2017). Determinación de la autonomía real del vehículo eléctrico en la ciudad de cuenca mediante análisis experimental.
- Carmona Suárez, E. J. (2014). Máquinas de Vectores Soporte (SVM). *Dpto. de Inteligencia Artificial, ETS de Ingeniería Inforática, Universidad Nacional de Educación a Distancia (UNED)*, 1–25.
- Febrero Bande, M., Galeano San Miguel, P., González Díaz, J., & Pateiro López, B. (2012). Prácticas de Estadística en R Ingeniería Técnica en Informática de Sistemas, 102.
- González, R., Barrientos, A., Toapanta, M., & Del Cerro, J. (2017). Aplicación de las Máquinas de Soporte Vectorial (SVM) al diagnóstico clínico de la Enfermedad de Parkinson y el Temblor Esencial. *RIAI - Revista Iberoamericana de Automatica E Informatica Industrial*, 14(4), 394–405. <https://doi.org/10.1016/j.riai.2017.07.005>
- Gras Llopis, M. (2010). Estimación estadística, modelado y análisis de las transmisión y coste de la variabilidad en procesos multi-etapa., 79. Retrieved from <http://www.tdx.cat/bitstream/handle/10803/42926/mgras.pdf?sequence=1>
- Hernandez Cabrera, L. D. (2017). Resumen. Retrieved from <http://ri.uaemex.mx/bitstream/handle/20.500.11799/68860/tesisluisdavid.pdf?sequence=1&isAllowed=y>
- Lehmann, E. L., & Casella, G. (1998). *Theory of Point Estimation , Second Edition Springer Texts in Statistics. Design* (Vol. 41). <https://doi.org/10.2307/1270597>
- Martín Guareño, J. J. (2016). Trabajo Fin De Grado Support Vector Regression : Propiedades Y Aplicaciones.
- Morente Fernández, C. (2015). Análisis y modelado del comportamiento de baterías para vehículos eléctricos.
- Orellana, T. F. (n.d.). Diseño de un sistema inteligente que permita estimar y simular la autonomía de un vehículo eléctrico en rutas urbanas de la ciudad de Cuenca.
- Paucar Urdialez, A. G., & Sigüenza Reinoso, A. X. (2016). Escuela politécnica nacional. *TERMOGRAFIA APLICADA AL DIAGNÓSTICO DE UN MOTOR HYUNDAI DIÉSEL 2.0 CRDI DE COMBUSTION INTERNA ALTERNATIVO COMO TÉCNICA DE MANTENIMIENTO PREDICTIVO DE FALLOS, PROVOCADOS POR EL SISTEMA DE ALIMENTACIÓN AIRE COMBUSTIBLE.*, 244. Retrieved from file:///C:/Users/HOGAR/Downloads/CD-2042.pdf
- Pedroza, H., & Dicovskyi, L. (2006). *Sistema de Analisis Estadistico con SPSS - Google Books. lica.*
- Pérez Soria, C. G. (2017). Departamento de Ingeniería Eléctrica y electrónica. Retrieved from <https://www.ingenieria.bogota.unal.edu.co/dependencias/departamentos/departament o-de-ingenieria-eléctrica-y-electrónica.html>



- Riobó Otero, V. (2012). Reconocimiento De Localizaciones Mediante Máquinas De Soporte Vectorial Autor:, 96.
- Ruíz, M. G. (2015). *Pasado, presente y futuro de vehículos electricos. Universidad Tecnológica De Pereira. Programa De Ingeniería Eléctrica.*
- Sánchez Anzola, N. (2016). Máquinas de soporte vectorial y redes neuronales artificiales en la predicción del movimiento USD/COP spot intradiario. *Odeon*, 9(9), 113.
<https://doi.org/10.18601/17941113.n9.04>
- Sanz, I. A. (2015). Análisis de la evolución y el impacto de los vehículos eléctricos en la economía europea, 84.
- Torres, S. J. D. (2015). *Universidad politecnica salesiana*. Retrieved from
<https://dspace.ups.edu.ec/bitstream/123456789/8050/1/UPS-CT004893.pdf>
- Urgilés Contreras, D. R. (2014). *Diferencial para vehículo eléctrico*. INSTITUTOTECNOLÓGICOY DE ESTUDIOS SUPERIORESDE MONTERREY. Retrieved from
<http://repositorio.educacionsuperior.gob.ec/bitstream/28000/1489/1/T-SENESCYT-00622.pdf>
- Vargas Fabre, J. A. (2012). CONVERSIÓN A AUTO ELÉCTRICO BASADA EN UN ACCIONAMIENTO TRIFÁSICO: DISEÑO, MODELACIÓN E IMPLEMENTACIÓN. *Tesis Conjunta*, 1, 91. Retrieved from
http://tesis.ipn.mx/handle/123456789/20784%5Cnhttp://repositorio.uchile.cl/tesis/uchile/2012/cf-vargas_jf/pdfAmont/cf-vargas_jf.pdf
[%5Cnhttp://www.anac.cl/uploads/web/03-ANAC-MercadoAutomotorMarzo2017.pdf](http://www.anac.cl/uploads/web/03-ANAC-MercadoAutomotorMarzo2017.pdf)



ANEXOS



Anexo A

ANEXXO A: Aplicación de diferentes Kernels

Kernel linear eps- regression: Summary (fitepslinear)

```
Call:
svm(formula = AUTONOMIA ~ ., data = traindata, type = "eps-regression", kernel = "linear",
     cross = 1010)

Parameters:
  SVM-Type:  eps-regression
 SVM-Kernel:  linear
      cost:  1
    gamma:  0.2
   epsilon:  0.1

Number of Support Vectors:  3096

1010-fold cross-validation on training data:
Total Mean Squared Error: 17.78538
Squared Correlation Coefficient: 0.8588039
```

Kernel polinomial eps- regression: Summary (fitepspoly)

```
Call:
svm(formula = AUTONOMIA ~ ., data = traindata, type = "eps-regression", kernel = "polynomial", cross = 1010)

Parameters:
  SVM-Type:  eps-regression
 SVM-Kernel:  polynomial
      cost:  1
    degree:  3
    gamma:  0.2
   coef.0:  0
   epsilon:  0.1

Number of Support Vectors:  4038

1010-fold cross-validation on training data:
Total Mean Squared Error: 55.40221
Squared Correlation Coefficient: 0.5692927
```



Kernel radial eps- regression: Summary (fitepsradial)

```
Call:
svm(formula = AUTONOMIA ~ ., data = traindata, type = "eps-regression", kernel = "radial", cross = 1010)

Parameters:
  SVM-Type:  eps-regression
 SVM-Kernel: radial
      cost:  1
      gamma: 0.2
      epsilon: 0.1

Number of Support Vectors: 2408

1010-fold cross-validation on training data:

Total Mean Squared Error: 8.301489
Squared Correlation Coefficient: 0.9346968
```

Kernel Sigmoid eps- regression: Summary (fitepssigmoid)

```
Call:
svm(formula = AUTONOMIA ~ ., data = traindata, type = "eps-regression", kernel = "sigmoid", cross = 1010)

Parameters:
  SVM-Type:  eps-regression
 SVM-Kernel: sigmoid
      cost:  1
      gamma: 0.2
      coef.0: 0
      epsilon: 0.1

Number of Support Vectors: 4539

1010-fold cross-validation on training data:

Total Mean Squared Error: 3795704
Squared Correlation Coefficient: 0.1149753
```

Kernel lineal un- regression: Summary (fitnulinear)

```
Call:
svm(formula = AUTONOMIA ~ ., data = traindata, type = "nu-regression", kernel = "linear", cross = 1010)

Parameters:
  SVM-Type:  nu-regression
 SVM-Kernel: linear
      cost:  1
      gamma: 0.2
      nu:    0.5

Number of Support Vectors: 2280

1010-fold cross-validation on training data:

Total Mean Squared Error: 17.41614
Squared Correlation Coefficient: 0.8610305
```



Kernel polinomial un- regression: Summary (fitnupoly)

```
Call:
svm(formula = AUTONOMIA ~ ., data = traindata, type = "nu-regression", kernel = "polynomial", cross = 1010)

Parameters:
  SVM-Type:  nu-regression
SVM-Kernel:  polynomial
  cost:      1
  degree:    3
  gamma:     0.2
  coef.0:    0
  nu:        0.5

Number of Support Vectors: 2280

1010-fold cross-validation on training data:

Total Mean Squared Error: 52.72513
Squared Correlation Coefficient: 0.5736431
```

Kernel radial un- regression: Summary (fitnuradial)

```
Call:
svm(formula = AUTONOMIA ~ ., data = traindata, type = "nu-regression", kernel = "radial", cross = 1010)

Parameters:
  SVM-Type:  nu-regression
SVM-Kernel:  radial
  cost:      1
  gamma:     0.2
  nu:        0.5

Number of Support Vectors: 2304

1010-fold cross-validation on training data:

Total Mean Squared Error: 8.297896
Squared Correlation Coefficient: 0.9342979
```

Kernel sigmoide un- regression: Summary (fitnusigmoide)

```
Call:
svm(formula = AUTONOMIA ~ ., data = traindata, type = "nu-regression", kernel = "sigmoid", cross = 1010)

Parameters:
  SVM-Type:  nu-regression
SVM-Kernel:  sigmoid
  cost:      1
  gamma:     0.2
  coef.0:    0
  nu:        0.5

Number of Support Vectors: 2274

1010-fold cross-validation on training data:

Total Mean Squared Error: 2131803
Squared Correlation Coefficient: 0.04140408
```



Anexo B

ANEXO B: Coeficientes de dos Modelos

Modelo eps-regression con kernel radial

```
Call:
lm(formula = AUTONOMIA ~ AvailableChargePower + `Battery voltage` +
  `Max cell voltage` + `Min cell voltage` + InverterCapacitorVoltage,
  data = testdata, subset = predepsradial)

Residuals:
    Min       1Q   Median       3Q      Max
-0.31251 -0.03753  0.00242  0.03326  0.47204

Coefficients:
                Estimate Std. Error t value Pr(>|t|)
(Intercept)      234.592995    0.478776   489.985 < 2e-16 ***
AvailableChargePower -0.916220    0.004279  -214.135 < 2e-16 ***
`Battery voltage`   -0.053532    0.007113   -7.526 6.26e-14 ***
`Max cell voltage`    3.757026    0.338075   11.113 < 2e-16 ***
`Min cell voltage`   -2.691360    0.282944   -9.512 < 2e-16 ***
InverterCapacitorVoltage  0.008726    0.003516    2.482  0.0131 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.09708 on 4539 degrees of freedom
Multiple R-squared:  0.9377,    Adjusted R-squared:  0.9376
F-statistic: 1.366e+04 on 5 and 4539 DF,  p-value: < 2.2e-16
```



Modelo nu-regression con Kernel Radial

```
call:
lm(formula = AUTONOMIA ~ AvailableChargePower + `Max Cell voltage` +
  `Min Cell voltage` + InverterCapacitorVoltage, data = testdata,
  subset = prednuradial)

Residuals:
    Min       1Q   Median       3Q      Max
-0.27691 -0.03840  0.00209  0.03258  0.44398

Coefficients:
                Estimate Std. Error t value Pr(>|t|)
(Intercept)      231.577000    0.519256  445.979 < 2e-16 ***
AvailableChargePower -0.943002    0.004604 -204.801 < 2e-16 ***
`Max Cell voltage` -0.179922    0.289979  -0.620  0.535
`Min Cell voltage` -1.549012    0.227140  -6.820 1.03e-11 ***
InverterCapacitorVoltage -0.002953    0.002712  -1.089  0.276
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


Residual standard error: 0.1051 on 4540 degrees of freedom
Multiple R-squared:  0.9271,    Adjusted R-squared:  0.927
F-statistic: 1.442e+04 on 4 and 4540 DF,  p-value: < 2.2e-16
```




Anexo C

ANEXO C: Correlaciones entre el testData vs Autonomia

Correlación Lineal: $\text{cor}(\text{testdata}\$AUTONOMIA, \text{predepslinear})^2$




Correlación polinomial: $\text{cor}(\text{testdata}\$AUTONOMIA, \text{predepsspoly})^2$






Correlacion radial: $\text{cor}(\text{testdata\$AUTONOMIA}, \text{predepsradial})^2$




Correlacion Sigmoide: $\text{cor}(\text{testdata\$AUTONOMIA}, \text{predepssigmoid})^2$




Anexo D

ANEXO D: Graficas de correlación de los TestData vs Autonomía


Lineal: `plot(testdata$AUTONOMIA, prednulinear)`



Polinomial: `plot(testdata$AUTONOMIA, prednuspoly)`



Radial: `plot(testdata$AUTONOMIA,prednuradial)`



Sigmoide: `plot(testdata$AUTONOMIA,prednusigmoid)`

