



UNIVERSIDAD DE CUENCA

Facultad de Ciencias Químicas

Carrera de Ingeniería Industrial

Modelo de pronóstico de ventas de vehículos livianos usando redes
neuronales artificiales

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

Autora:

Jenny Fabiola Morocho Chitacapa

CI: 0105719017

Correo electrónico: jenny_fabs@hotmail.com

Director:

Ing. Juvenal Alejandro Ortiz Ulloa

CI: 0104254149

Cuenca, Ecuador

27-febrero-2020

1. Resumen:

La precisión en la predicción de las ventas es vital en cualquier tipo de industria ya que puede mejorar la calidad de las estrategias de negocios o de la toma de decisiones, específicamente en la industria automotriz juega un papel cada vez más importante debido a la creciente competencia registrada en el mercado, a los largos tiempos de desarrollo y producción y a su relación con las variables económicas. En este documento se compara el desempeño de los métodos clásicos de previsión contra las redes neuronales artificiales (RNA) al pronosticar las ventas de vehículos livianos de la empresa Neohyundai, se consideran variables internas y externas propias del sector. Primero, se llevó a cabo un paso de pre-procesamiento para asegurar la calidad de los datos de entrada a la RNA, en esta etapa se incluye la normalización y la selección de las variables más influyentes a través de la regresión de Lasso, a continuación se establece la arquitectura de la red y los parámetros de aprendizaje. Los resultados muestran que las RNA superan a los métodos tradicionales de predicción, esto significa que la demanda de vehículos que son bienes de consumo duradero puede ser pronosticada mediante el uso de diferentes variables. Además, al determinar la importancia relativa de las variables de entrada se encontró que las variables económicas contribuyen de forma significativa en la previsión.

Palabras claves: Pronóstico de ventas de vehículos. Industria automotriz. Promedio móvil. Suavización exponencial. Variación cíclica. Regresión. RNA.

2. Abstract:

Accuracy in sales prediction is vital in any type of industry as it can improve the quality of business strategies or decision making. Specifically, in the automotive industry it plays an increasingly important role due to the growing competition registered in the market, to the long development and production times and to its relationship with the economic variables. This study compares the performance of the classical forecasting methods against artificial neural networks (ANN) when forecasting light vehicle sales of the Neohyundai company, internal and external variables characteristic of the sector are considered. First, a preprocessing step was carried out to ensure the quality of the input data to the ANN, in this stage the normalization and selection of the most influential variables through Lasso regression is included, then Network architecture and learning parameters are established. The results show that ANN exceed traditional prediction methods, this means that the demand for vehicles that are durable consumer goods can be predicted by using different variables. Furthermore, when determining the relative importance of the input variables, it was found that the economic variables contribute significantly to the forecast.

Keywords: Vehicle sales forecast. Automotive industry. Moving average. Exponential smoothing. Cyclic variation. Regression. ANN.



Índice del Trabajo


1.	Resumen:.....	2
2.	Abstract:	3
3.	Introducción	7
3.1	Justificación	7
3.2	Objetivos	11
3.2.1	Objetivo general.....	11
3.2.2	Objetivos específicos.....	11
3.3	Marco conceptual	11
3.3.1	Modelos de pronósticos tradicionales	12
3.3.2	Redes Neuronales Artificiales (RNA)	12
3.3.3	Criterio para la evaluación de los métodos de previsión	13
3.3.4	Importancia relativa de las variables de entrada.....	13
4.	Materiales y métodos	14
4.1	Procedimiento del modelo.....	14
4.1.1	Alcance del pronóstico	14
4.1.2	Variables del modelo.....	15
4.1.3	Recolección de datos.....	17
4.1.4	Análisis del color de los vehículos	17
4.1.5	Pre procesamiento de datos de entrada.....	17
4.1.6	Pronóstico de ventas	18
5.	Resultados y discusiones	20
5.1	Variables seleccionadas.....	20
5.2	Comparación de resultados generales obtenidos por cada uno de los métodos de pronósticos.....	22
5.3	Análisis de los resultados para cada familia.....	24
5.4	Importancia relativa de las variables de entrada	30
5.5	Participación por color de vehículo en las ventas.....	30
6.	Conclusiones.....	31
7.	Agradecimiento	32
8.	Bibliografía	32
9.	Anexos	35

Cláusula de licencia y autorización para publicación en el Repositorio Institucional

Jenny Fabiola Morocho Chitacapa en calidad de autora y titular de los derechos morales y patrimoniales del trabajo de titulación “Modelo de pronóstico de ventas de vehículos livianos usando redes neuronales artificiales”, de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 27 de febrero de 2020




Jenny Fabiola Morocho Chitacapa

C.I: 0105719017

Cláusula de Propiedad Intelectual

Jenny Fabiola Morocho Chitacapa, autora del trabajo de titulación "Modelo de pronóstico de ventas de vehículos livianos usando redes neuronales artificiales", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autora.

Cuenca, 27 de febrero de 2020



Jenny Fabiola Morocho Chitacapa

C.I: 0105719017

3. Introducción

3.1 Justificación

Actualmente, la optimización de los recursos y la creciente demanda de una mayor diversidad de productos exige a las organizaciones: efectuar planes y programas de producción con los que se aproveche al máximo la materia prima, la mano de obra y la maquinaria, así como entregar los pedidos en las fechas estipuladas para reducir costos y brindar un buen servicio al cliente; pero para lograr planes eficientes es necesario un pronóstico de ventas preciso, sin embargo, los patrones de la demanda de bienes y servicios suelen variar considerablemente a través del tiempo, provocando incertidumbre en las organizaciones y complicando la elaboración de pronósticos [1]. Así pues, la selección y ejecución de un modelo apropiado de pronósticos constantemente ha sido un tema trascendental para las compañías, pues un error significativo en el pronóstico de ventas podría dejar a una organización sin los recursos necesarios para la producción o podría generarle un exceso de inventario, básicamente el reto es poseer la cantidad apropiada de inventario de tal manera que se puedan alcanzar los objetivos eficientemente [2]. De acuerdo a esto, las organizaciones cuentan con distintas clases de inventarios para poder procesar todos los requerimientos que se manifiesten, sin embargo, estos representan una gran inversión monetaria por los costos de mantenimiento, el tipo más común es el stock de seguridad, que es una cantidad extra de inventario, que tiene como objetivo la protección ante la fluctuación de la demanda, el tiempo de espera y las variaciones en el aprovisionamiento [3].

Las ventas son importantes para cualquier negocio, es así que la planificación estratégica fundamentada en un pronóstico de ventas confiable es un componente esencial para una gestión empresarial de calidad dentro de una organización orientada al mercado. Esto es especialmente cierto para la industria del automóvil, ya que es uno de los sectores más importantes en muchos países. En particular, los procesos de desarrollo, producción e importación toman un tiempo relativamente largo, además la presencia de competidores fuertes, las importantes inversiones y la constante renovación de modelos de vehículos hacen de la previsión un elemento clave [4] [5].

Los automóviles forman parte de los bienes de consumo duradero y según Shahabuddin las ventas de este tipo de bienes se correlacionan fuertemente con los principales indicadores económicos [6]. Predecir las ventas de estos bienes puede ser complejo para las empresas debido a los constantes cambios económicos del entorno. Un análisis en Gran Bretaña indica que los ingresos de las personas por sí solos no determinan la demanda de automóviles, el motivo podría ser que, para comprar este

tipo de bienes, las personas usan ahorros o financiamiento. A través de la reparación y mantenimiento se puede alargar la vida útil del mismo, también es muy probable que los consumidores tengan más de un coche. Estas incertidumbres hacen que la demanda de bienes duraderos sea difícil y desafiante de pronosticar [6].

En Ecuador, la intervención del gobierno dentro de la industria automotriz ha sido muy activa, pues ha decretado medidas fiscales para regularizar ciertos aspectos, en consecuencia las ventas del sector automotor se ven directamente afectadas. Una de las medidas impuestas fue la restricción a la importación de vehículos que se extendió desde el año 2012 al 2016, debido a cuestiones ambientales y al déficit que presentaba la balanza comercial por la caída del precio de petróleo en ese entonces [7]. Se estableció un cupo anual máximo de importación para las empresas del sector, tanto en número de unidades como en la cantidad de USD “Free On Board” (FOB) importados. Hay que mencionar que en el país se venden vehículos previamente importados por “Completely Built Up” (CBU) o “Completely Knock Down” (CKD), inicialmente la restricción aplicaba únicamente para CBU luego se extendió para CKD [7] [8]. Para los años 2012-2014 se asignó un cupo con una reducción del 30% del total de ventas alcanzadas en el año 2010, para el año 2015 se redujeron los cupos hasta un 57% y para el año 2016 el cupo fue un 9% menor al año anterior [8] [9]. Es decir, hubo una reducción progresiva de cupos que produjo la contracción de la industria automotriz, pues no se contaba con la oferta suficiente para satisfacer las necesidades del mercado, lo que implica que no se podían ofrecer ciertos modelos de vehículos, a partir del año 2017 esta medida fue eliminada [10].

Otra de las medidas fiscales es el pago de impuestos y aranceles tanto para la importación de CBU como para CKD, por estos se deben cancelar tributos como: “Arancel Cobrado a las Mercancías” (Advalorem), “Impuesto al Valor Agregado” (IVA), “Impuesto a los Consumos Especiales” (ICE), “Fondo de Desarrollo para la infancia” (FODINFA), “Impuesto a la Salida de Divisas” (ISD), Impuesto a la Renta, Salvaguardias, en efecto todos estos se incluyen en el costo de los vehículos [11]. Asimismo, en la matriculación vehicular, se incluyen varios rubros que deben ser cancelado por los propietarios de vehículos de forma anual, estos son: el Impuesto a la Propiedad de Vehículos Motorizados, el Impuesto al Rodaje que aplica para los municipios con los que se ha suscrito un convenio de recaudación, la Tasa de la Junta de Beneficencia de Guayaquil para vehículos matriculados en ese cantón, la tasa “Sistema Público para Pago de Accidentes de Tránsito” (SPPAT) y tasas y multas por matriculación, hay que mencionar que cuando un vehículo es nuevo el valor de la matrícula se generará de manera proporcional a lo que resta del año desde la compra [12]. Otro de los cambios relevantes en el país, es que los combustibles que se utilizan en el sector tienen un nuevo

esquema de precios [13]. Por consiguiente, todos estos estatutos representan un enorme desafío para la industria automotriz.

Por otra parte, hay varias características que los compradores pueden considerar en el momento de adquirir un vehículo nuevo, como por ejemplo: el modelo, el color, los accesorios, el precio, transmisión automática o manual, el motor entre otros. Conforme a una encuesta efectuada por “PPG Industries” una de las más grandes compañías en recubrimientos a nivel global, el 60% de los encuestados afirman que el color del vehículo es un punto fundamental en la decisión de compra, pues aunque parezca algo trivial, existen clientes que valoran este parámetro como muy importante ya que refleja personalidad y estilo propio [14]. Así pues no poseer un color de la gama de los preferidos por los consumidores implicaría la pérdida de la venta de ese vehículo. Frente a esto los concesionarios deben ofrecer a sus clientes una amplia gama de modelos y colores a diferentes precios de tal manera que los consumidores puedan encontrar su vehículo ideal, lo que les lleva a contar con un alto nivel de inventario incurriendo en grandes costos para el mantenimiento del mismo [15]. Otro de los puntos a considerar es que el sector automotriz ofrece vehículos con el año modelo adelantado un período al año en curso, es así que aproximadamente hasta el primer semestre del año se dedican a vender unidades con el año modelo en curso, por ejemplo hasta el mes de junio del año 2019 se venden las unidades con el año modelo 2019 para así deshacerse de todo el inventario con el que cuentan pues a partir de ese mes hay cambio de año modelo ya que se empiezan a ofrecer los vehículos 2020. De modo que los concesionarios se ven obligados a usar estrategias comerciales como descuentos, promociones especiales, entre otras para así vender el inventario existente del año en curso. Cabe destacar que los periodos considerados para ofrecer el nuevo año modelo y vender el año modelo anterior pueden variar dependiendo de la cantidad de vehículos que se encuentren en inventario así como de la fecha de cambio de año modelo definida por la marca.

Por lo tanto, un pronóstico de ventas erróneo puede influir negativamente en una organización particularmente en la industria automotriz que es uno de los sectores con gran aporte económico en muchos países [6], específicamente en Ecuador contribuyó con 1633 millones de dólares por el pago de tributos a la SENAE Y al SRI en el año 2018, convirtiéndose así en uno de los sectores que más aporta con respecto a impuestos, además genera un total de 68155 empleos de acuerdo a lo registrado por el IEES [11]. Cabe destacar que en el país en el año 2018 se vendieron 137615 vehículos, incluidos livianos y pesados, los vehículos livianos vendidos fueron: automóviles, camionetas y “Sport Utility Vehicle” (SUV), con 123457 unidades equivalentes al 89,71% del mercado, Figura 1. El sector registró un crecimiento del 31% en comparación al 2017, que fue derivado de mejoras en la

economía nacional, expansión del crédito y la exclusión de restricciones que limitaban la venta de vehículos nuevos en el país. De hecho, este crecimiento se manifestó con la introducción de 15 nuevas marcas y 89 nuevos modelos con precios económicos, es así que la comercialización de automotores por rango de precios se concentró en el segmento de hasta USD 20000 [11].




Figura 1. Ventas anuales de vehículos nuevos en Ecuador (unidades) [11]

En las últimas décadas, para resolver casos de pronósticos de ventas comúnmente se han aplicado técnicas de previsión tradicionales, como la suavización exponencial, media móvil, Box Jenkins (ARIMA), regresión lineal y multivariada pero no siempre se desempeñan correctamente sobre todo cuando el mercado fluctúa con alta frecuencia y al azar. Otros, trataron de desarrollar modelos incluyendo diferentes variables para afinar los resultados [6] [16] [17]. Tal es el caso de Shahabuddin en el estudio “Previsión de las ventas de automóviles”, que utiliza un modelo de regresión para determinar relaciones causales, se seleccionan variables demográficas y económicas en su mayoría asumiendo que afectan a la compra de automóviles y otros bienes de consumo [6]. Las ecuaciones obtenidas pueden predecir las ventas con un 91%, 73% y 98% de exactitud para vehículos extranjeros, nacionales y camiones respectivamente. El autor menciona que los resultados y las relaciones entre variables podrían mejorar sustancialmente si se añaden variables internas a partir de un análisis de cada modelo de vehículo y de coches en diferentes rangos de precios.

La búsqueda de nuevos modelos de pronóstico de negocios ha llevado a los expertos de algunas especialidades a la denominada Inteligencia Artificial Computacional, pues parece que las modernas herramientas como las Redes neuronales artificiales (RNA) sobrepasan los resultados proporcionados por métodos empleados en el pasado [16]. En este contexto, hay varias investigaciones de previsión

que se llevaron a cabo en diferentes campos de acuerdo a lo presentado en varios estudios, en donde las RNA dan resultados precisos [2], [18], [19], [20].

La previsión de ventas de vehículos ha tomado un especial interés, por ejemplo en un estudio realizado en Turquía se analiza el efecto de las políticas económicas aplicadas en ese país a la venta de automóviles a través de regresión múltiple y redes neuronales artificiales, en donde se obtiene que el tipo de cambio, la tasa de interés de préstamos para vehículos y el Impuesto Especial al Consumo son los factores que realmente afectan a la comercialización de automóviles, obteniendo un Error Porcentual Absoluto Medio (MAPE) de 54,45% para la técnica de regresión y 18,84% para RNA, de lo que se concluye que la red neuronal realiza un pronóstico más ajustado que la regresión [21].

Por otra parte, en un estudio desarrollado en Estado Unidos se realiza un pronóstico de ventas de automóviles mediante RNA y procesos de jerarquía analítica, se evalúan factores como el precio, rendimiento del vehículo, seguridad, apariencia, comodidad y los efectos de los meses en el volumen de ventas. En donde, las RNA obtienen un Error cuadrático medio (MSE) de 0.44×10^{-8} , en comparación a la regresión lineal y exponencial que obtienen 1.64×10^{-8} y 37×10^{-8} respectivamente, se encuentra que las RNA reducen al mínimo el error de predicción en comparación a los métodos comúnmente usados [22].

3.2 Objetivos

3.2.1 Objetivo general

- Desarrollar un modelo de pronóstico de ventas de vehículos livianos con el uso de redes neuronales artificiales considerando variables internas y externas que afecten al sector automotriz.

3.2.2 Objetivos específicos

- Determinar las variables internas y externas que influyen directamente en las ventas de vehículos livianos.
- Desarrollar el modelo de pronóstico de ventas de vehículos livianos usando redes neuronales artificiales.
- Pronosticar las ventas de vehículos livianos con el modelo desarrollado y con los métodos tradicionales, y comparar los resultados obtenidos con los datos de ventas reales.

3.3 Marco conceptual

3.3.1 Modelos de pronósticos tradicionales

Un pronóstico “es una predicción de acontecimientos futuros que se utiliza con propósitos de planificación” [3]. Los métodos de previsión pueden fundamentarse en modelos matemáticos que emplean los datos históricos disponibles o en métodos cualitativos que hacen uso de la experiencia administrativa o los juicios de los clientes, o en una combinación de las dos. Entre los métodos cuantitativos están:

- Análisis de series de tiempo: promedio móvil simple, promedio móvil ponderado, suavizamiento exponencial, variación cíclica o método estacional multiplicativo.
- Métodos causales: regresión lineal simple, regresión lineal múltiple.

3.3.2 Redes Neuronales Artificiales (RNA)

Nojek *et al.* [2], señalan que las redes neuronales artificiales son “sistemas dinámicos auto adaptativos. Son adaptables debido a la capacidad de auto ajustarse de los elementos procesales que componen el sistema. Son dinámicos, pues son capaces de estar constantemente cambiando para adaptarse a las nuevas condiciones”.

De acuerdo a su naturaleza y a sus principios, las RNA poseen propiedades similares a las del cerebro humano [2]. La estructura de una red neuronal artificial se muestra en la Figura 2, en donde las neuronas de cada una de las capas se enlazan en una sola dirección con las de la siguiente capa, es decir se conectan todas con todas, lo que les permite aprender y adquirir experiencia [18].




Figura 2. Red multicapa del tipo feed forward [23]

Están diseñadas para modelar problemas de clasificación, regresión y predicción no lineal con alta complejidad para los cuales los modelos matemáticos estándar resultan inadecuados [23]. El modelo de red neuronal utilizada en este estudio es el “Perceptrón multicapa” (MLP) que posee en su

arquitectura tres capas: entrada (valores conocidos), capa oculta y la capa de salida (valores conocidos). Es una red supervisada, es decir necesita una salida deseada para aprender, los datos históricos se utilizan como entradas para luego predecir la salida cuando la salida deseada es desconocida [24]. El entrenamiento del MLP, generalmente se hace utilizando el algoritmo de propagación de errores hacia atrás conocido como backpropagation, con el que es posible determinar el gradiente del error con relación a los diferentes parámetros de la red, lo que indica cómo han de modificarse estos parámetros para ajustar los pesos de tal manera que se consiga el mínimo error [25].

Entre las aplicaciones de éxito de las redes neuronales artificiales están: procesamiento de imágenes y voz, reconocimiento de patrones, planeamiento, predicción, control y optimización [2]. Se han usado para solucionar problemas económicos y financieros, así como en la predicción de series temporales, se destaca su capacidad para encontrar y aprovechar la no linealidad existente en la información que se les presenta, regularmente logran un buen rendimiento al modelar problemas de alta complejidad, en donde el reconocimiento de comportamientos es esencial [26].

3.3.3 Criterio para la evaluación de los métodos de previsión

La evaluación de los diferentes modelos de pronóstico se realiza en función del Error Porcentual Absoluto Medio (MAPE), calculado mediante la ecuación (1):

$$MAPE = \frac{\frac{\sum_{t=1}^n |D_t - F_t|}{|D_t|}}{n} \quad (1)$$

Donde n es el número de periodos considerados, D_t es la demanda real en el periodo t y F_t es el Pronóstico en el periodo t [3].

3.3.4 Importancia relativa de las variables de entrada

Garson [27] plantea una técnica para determinar la importancia relativa de cada una de las variables de entrada a partir de la división de los pesos finales de conexión de la red neuronal artificial, de acuerdo a la ecuación (2):

$$RI_x = \frac{\sum_{y=1}^n \frac{|W_{xy}W_{yz}|}{\sum_{y=1}^m |W_{xy}W_{yz}|}}{\sum_{y=1}^m |W_{xy}W_{yz}|} \quad (2)$$

En donde, RI_x es la importancia relativa de la neurona x , y $\sum_{y=1}^m W_{xy}W_{yz}$ es la suma del producto de los pesos finales de las conexiones de las neuronas de entrada-ocultas con las conexiones de las neuronas ocultas-salida, para luego asignar un porcentaje del total a cada una de las entradas de

acuerdo a su contribución en la predicción de la variable dependiente [28] [29]. Por lo tanto, se espera que el pronóstico de ventas de vehículos livianos a través del análisis de variables y con el uso de redes neuronales artificiales permita obtener resultados más acertados en comparación a los resultados obtenidos por los métodos tradicionales de pronósticos, lo que reduciría considerablemente el error que se genera al usar las técnicas convencionales, pues al revisar el estado del arte se encuentran casos de éxito de modelos de inteligencia artificial para predecir las ventas de automóviles, como son los estudios realizados por [17], [21], [22], [24]. Además, servirá como base de la planificación, para permitir un nivel de inventario óptimo, para tomar decisiones de compra adecuadas y para diseñar políticas de mercadeo.

4. Materiales y métodos

El tipo de investigación que se realizó es propositiva, pues la finalidad del ensayo fue generar un modelo de pronóstico de ventas de vehículos livianos con el uso de redes neuronales artificiales considerando variables que afectan al sector automotriz. Para obtener un pronóstico de ventas de vehículos livianos más ajustado en esta investigación se consideran variables internas, es decir propias de la empresa, y variables externas que son los factores que no pueden ser controlados por la organización. Después de seleccionar las variables de entrada, se desarrolla el modelo de pronóstico con redes neuronales artificiales y también se predicen las ventas usando los métodos tradicionales, para posteriormente calcular el “Error Porcentual Absoluto Medio” (MAPE), lo que indicará el desempeño proporcionado por cada uno de los modelos. Luego, se determina la importancia relativa de las variables de entrada utilizadas en el modelo, asimismo se especifica la participación porcentual por color de vehículo en las ventas cada familia.

La propuesta se efectuó para la empresa “Negocios Automotrices Neohyundai S.A.”, que se dedica a la importación y comercialización de vehículos livianos y comerciales de la marca Hyundai, específicamente se desarrollará el pronóstico de ventas para vehículos livianos pues esta línea de ventas es la que produce mayor cantidad de ingresos para la organización. La población considerada son las ventas mensuales de los dos segmentos de la línea de vehículos livianos, que son: automóviles y SUV.

4.1 Procedimiento del modelo

4.1.1 Alcance del pronóstico

Particularmente, al ser esta una empresa comercializadora de vehículos previamente importados en su mayoría por CBU el pronóstico de ventas debe hacerse con anticipación pues un error en la previsión no le daría el tiempo suficiente para reaccionar, debido a los tiempos de tránsito que dependen del país de origen, así como de los tiempos para accesorización y distribución de los vehículos, para luego en función de eso, ejecutar la planificación de ventas, considerando que el lead time del proceso es aproximadamente 3 meses. De acuerdo a lo anterior, se propone que el pronóstico se realizará a corto plazo.

La estética, forma y otras características como el año modelo varían cada año en los modelos de vehículos, lo que lleva a esta organización a segmentar los productos en función de categorías y familias, tabla 1.

Tabla 1. Categorías y familias de vehículos livianos Neohyundai

Categoría	Familia
Automóviles	Grand i10 Hatchback
	Grand i10 Sedán
	Accent
	Ioniq
	Sonata
SUV	Creta
	Tucson
	Santa Fe

Fuente: Elaboración propia

Dentro de cada una de las familias se ubican diferentes modelos de vehículos, dependiendo de si la transmisión es automática o manual, si es la versión estándar o full, del cilindraje, de la tracción, del número de puertas, del número de pasajeros, entre otras, por lo que se realizará el pronóstico de ventas en función de las familias de vehículos.

4.1.2 Variables del modelo

De acuerdo a estudios anteriores, a la información proporcionada por la empresa y a los boletines del sector automotriz las variables que afectan a la venta de vehículos en el país y se analizaron son las siguientes, tabla 2:

Tabla 2. Variables Internas y Externas

VARIABLES INTERNAS		
Notación	Variable	Fuente
X1	Año	Empresa
X2	Mes	Empresa
X3	Precio promedio por familia (USD)	Empresa
X4	Número de Concesionarios	Empresa
X5	Inversión en publicidad (USD)	Empresa
Y	Demanda (Unidades)	Empresa

VARIABLES EXTERNAS		
Notación	Variable	Fuente
X6	PIB Real (o a precios constantes) (USD)	Banco Central del Ecuador
X7	PIB Nominal (o a precios corrientes) (USD)	Banco Central del Ecuador
X8	Tasa de Inflación (%)	INEC
X9	Índice de confianza del consumidor 5 ciudades ICC (Puntos)	INEC
X10	Riesgo país (Puntos)	Banco Central del Ecuador
X11	Importaciones totales (Millones USD)	Banco Central del Ecuador
X12	Exportaciones totales (Millones USD)	Banco Central del Ecuador
X13	Balanza Comercial Total (Millones USD)	Banco Central del Ecuador
X14	Gasto de Consumo final Hogares Real (Miles USD 2007=100)	Banco Central del Ecuador
X15	Gasto de Consumo final Hogares Nominal (Miles USD)	Banco Central del Ecuador

X16	Remesas (USD)	Banco Central del Ecuador
X17	Petróleo (WTI precio promedio) (USD)	Banco Central del Ecuador
X18	Tipo de cambio (USD/EURO)	Banco Central del Ecuador
X19	Tipo de cambio (USD/INR)	es.investing.com
X20	Tipo de cambio (USD/KRW)	es.investing.com
X21	Tasa de interés activa referencial (%)	Banco Central del Ecuador
X22	Tasa de desempleo (%)	INEC
X23	Crédito de consumo ordinario (USD)	Superintendencia de Bancos
X24	Impuesto al valor agregado (IVA) (%)	SRI
X25	Número de edificaciones a construir	INEC
X26	Número de vehículos motorizados matriculados	INEC
X27	Ventas de vehículos de tipos competitivos (Unidades)	AEADE

Fuente: Elaboración propia

4.1.3 Recolección de datos

Se utilizaron los datos históricos de cada variable desde enero de 2017 hasta junio de 2019. La fuente de la cantidad de vehículos facturados mensualmente por familias, así como de las variables internas es la organización y los datos relacionados a las variables externas se obtuvieron de instituciones gubernamentales, de acuerdo a la tabla 2.

4.1.4 Análisis del color de los vehículos

A partir de un análisis de las ventas de vehículos por colores, se decide que no es necesario considerar este parámetro en la RNA, ya que la participación porcentual por color no presenta mayor variación mensual, además las ventas se condensan principalmente en tres colores, por lo tanto este factor se puede tomar directamente luego de obtener el pronóstico con la metodología propuesta, para de esta manera tener una referencia de la participación por color en las ventas.

4.1.5 Pre procesamiento de datos de entrada

4.1.5.1 Coeficiente de correlación

Mide el grado de correlación entre variables, es así que si dos variables están altamente correlacionadas entre sí se debe eliminar una de ellas, se consideró un coeficiente de correlación (r) superior a 0.95.

4.1.5.2 Normalización

La normalización busca asegurar la calidad de los datos de entrada en los algoritmos de aprendizaje con la finalidad de aumentar la capacidad de predicción, es apropiada para casos en donde las entradas no están en la misma escala. La técnica que se utilizó es la normalización Min-Máx., que es básicamente transformar los datos a un rango de valores comprendido entre 0 y 1 [30].

4.1.5.3 Retraso de variables

Utilizar datos macroeconómicos como variables para realizar el pronóstico de ventas es un asunto complicado debido a que no se dispone de estos en el momento en el que se necesite predecir las ventas pues se actualizan mensualmente, trimestralmente o anualmente, entonces las variables que se ingresaron a la red neuronal artificial tienen un retraso de 6 meses.

4.1.5.4 Selección de variables usando la Regresión de Lasso

La selección de variables consiste en elegir un número reducido de variables explicativas para describir una variable de respuesta. Se consigue: eliminar variables que son redundantes o que no contribuyen con información relevante, disminuir el tamaño del problema para incrementar la rapidez de los algoritmos y reducir el sobre aprendizaje. Este proceso puede hacerse de varias maneras, pero en general hay 3 métodos: de filtro, envoltura o incrustado [30].

En su estudio Fonti y Belister mencionan que:

Uno de los métodos incrustados es la regresión de Lasso “Least Absolute Shrinkage and Selection Operator”, formulado por Robert Tibshirani en 1996, es una técnica de regresión lineal regularizada, que aplica un proceso de reducción (regularización) donde penaliza los coeficientes de las variables de regresión reduciendo algunas de ellas a cero. Durante el proceso de selección de características, las variables que todavía tienen un coeficiente distinto de cero después del proceso de reducción se seleccionan para formar parte del modelo. El objetivo de este proceso es minimizar el error de predicción [30].

4.1.6 Pronóstico de ventas

Los métodos utilizados para predecir las ventas así como los parámetros necesarios para cada técnica de previsión se describen en la tabla 3. Cabe señalar que los métodos de análisis de series de tiempo y métodos causales para poder predecir hacen uso de la demanda, únicamente el método de regresión paso a paso trabaja en función de las variables internas y externas, este se realizó en el software SPSS que automáticamente devuelve la ecuación de regresión, y el algoritmo para la red neuronal artificial se desarrolló en Python (Python® Versión 3.7) utilizando la biblioteca Keras, en donde los parámetros como el número de épocas, número de neuronas en la capa oculta y el tamaño de lote varían en cada familia de vehículos.

Tabla 3. Parámetros de cada uno de los métodos

Método	Parámetros
Promedio móvil simple (PMS)	$F_t = \frac{D_{t-1} + D_{t-2} + \dots + D_{t-n}}{n}$ Donde D_t = demanda real en el periodo t n = número de periodos incluidos en el promedio = 2 o 3 F_t = pronóstico para el periodo t
Promedio móvil ponderado (PMP)	$F_t = W_1 D_{t-1} + W_2 D_{t-2} + W_3 D_{t-3} + \dots + W_n D_{t-n}$ Donde D_t = demanda real en el periodo t W_i = factor de ponderación = 0,3 y 0,7 o 0,2 – 0,3 y 0,5 F_t = pronóstico para el periodo t
Suavización exponencial	$F_t = F_{t-1} + \alpha(D_{t-1} - F_{t-1})$ Donde F_{t-1} = pronóstico del periodo anterior t-1 D_{t-1} = demanda real en el periodo anterior t-1 α = coeficiente de suavización entre 0,0 y 1,0 = 0,2 o 0,4 F_t = pronóstico para el periodo t
Variación cíclica	$F_t = I * D$ Donde I = índice estacional promedio D = demanda promedio F_t = pronóstico para el periodo t

Regresión lineal simple	$Y = a + bX$ Donde Y = variable dependiente X = variable independiente a = intersección de la recta con el eje Y b = pendiente de la recta
Regresión paso a paso	$Y = a + b_1X_1 + \dots b_kX_k$ Donde Y = variable dependiente X_i = variables independientes b_i = coeficiente de las variables independientes X_i a = constante
Red neuronal artificial (RNA)	1 capa oculta Número de neuronas en la capa oculta Épocas Tamaño de lote Tasa de aprendizaje = 0,001 Optimizador = Adam

Fuente: Elaboración propia

5. Resultados y discusiones

5.1 Variables seleccionadas

Inicialmente se contaba con un total de 27 variables, sin embargo al revisar si había información disponible no se encontró datos recientes, entonces se eliminaron 2 variables (X25 y X26). Al efectuar el análisis de correlación se encontró que un par de variables estaban altamente correlacionadas entre sí X15 y X7, entonces se procedió a eliminar una de ellas X15.

Luego de desarrollar el análisis de correlación hay un total de 24 variables, sin embargo la cantidad de variables se aproxima al número de muestras, lo que incrementa la complejidad del modelo y el riesgo de sobreajuste al desarrollar la RNA.

Así pues, se utiliza el procedimiento de la regresión de Lasso para determinar las variables más influyentes y utilizarlas como variables de entrada. El algoritmo se desarrolló en Python para cada una de las familias de vehículos, esta metodología realiza el análisis en función de la variable dependiente e independientes, por lo tanto las variables seleccionadas varían en cada uno de los casos, como se muestra en la tabla 4, además se encontró que la variable gasto de consumo final hogares real (X14) fue eliminada en todos los casos y en la familia Santa Fe todas las variables internas se descartaron.

Tabla 4. Variables seleccionadas para cada una de las familias

Notación	Automóviles					SUV		
	Grand i10 Hatchback	Grand i10 Sedán	Accent	Ioniq	Sonata	Creta	Tucson	Santa Fe
X3					X		X	
X4	X	X	X	X	X	X		
X5	X	X	X		X	X	X	
X6						X	X	X
X7	X	X	X					X
X8	X	X	X		X	X	X	X
X9	X	X	X			X	X	X
X10			X	X			X	X
X11	X	X		X	X	X		
X12	X			X	X	X		X
X13		X	X					X
X14								
X16	X	X		X	X			
X17				X	X	X	X	
X18				X			X	X
X19	X		X		X	X	X	X
X20	X	X	X	X		X	X	X
X21	X		X	X	X	X		X
X22				X	X		X	X
X23		X					X	
X24		X	X	X	X	X		
X27		X	X	X	X	X	X	
Total	11	12	12	12	13	13	13	12

Fuente: Elaboración propia

5.2 Comparación de resultados generales obtenidos por cada uno de los métodos de pronósticos

Es común en técnicas estadísticas y de aprendizaje automático, dividir los datos en conjuntos de entrenamiento y prueba para conseguir una evaluación imparcial, de acuerdo a eso se consideró una partición del total de datos en 80% para entrenamiento y 20% para prueba, es decir los datos del primer semestre del 2019 fueron utilizados como conjunto de prueba.

Con relación a la configuración de la red neuronal artificial, se utiliza una sola capa oculta ya que se considera suficiente para resolver este caso, ahora el número de neuronas de la capa oculta no es un parámetro que se puede calcular con alguna fórmula matemática, por lo tanto se determinó experimentalmente para cada una de las familias. Además, el tamaño de lote, así como el número de épocas está configurado para obtener el menor error en cada una de las familias como se muestra en la tabla 5. Hay que mencionar que esta configuración podría ser utilizada en periodos posteriores, sin embargo estaría sujeta a cambios, pues al modificar el conjunto de datos los resultados podrían mejorar o empeorar.

Tabla 5. Parámetros especificados en la Red neuronal artificial

Parámetros	Automóviles					SUV		
	Grand i10 Hatchback	Grand i10 Sedán	Accent	Ioniq	Sonata	Creta	Tucson	Santa Fe
Número de neuronas	15	15	14	12	15	18	10	15
Tamaño de lote	2	3	1	2	8	3	3	3
Número de épocas	150	125	59	342	125	200	70	51

Fuente: Elaboración propia

El Error Porcentual Absoluto Medio (MAPE) alcanzado por cada uno de los métodos de pronósticos de ventas se resume en la tabla 6 y en la figura 3, de acuerdo a eso, el mejor MAPE obtenido por la RNA es para la familia Creta con 14,39%. En general, el mejor promedio MAPE es de 23,25% que corresponde a la RNA, valor considerablemente inferior a los resultados obtenidos por los seis métodos tradicionales de predicción. Sin embargo, hay que considerar que en el primer semestre del 2019 mismo que es utilizado como conjunto de prueba se evidencia una reducción de las ventas en comparación a los periodos anteriores.

Tabla 6. Comparación de los resultados MAPE de los métodos de predicción

Método		Automóviles					SUV			Promedio MAPE
		Grand i10 Hatchback	Grand i10 Sedán	Accent	Ioniq	Sonata	Creta	Tucson	Santa Fe	
1	Promedio móvil simple	35,58	43,86	11,57	40,19	60,88	19,99	51,54	22,01	35,70
2	Promedio móvil ponderado	34,86	37,43	11,64	41,48	54,17	17,70	49,43	21,89	33,58
3	Suavización exponencial	27,04	43,18	16,57	42,08	73,12	19,90	50,95	21,88	36,84
4	Variación cíclica	25,61	38,96	28,99	49,42	64,81	30,20	40,46	36,60	39,38
5	Regresión lineal	25,24	42,23	23,36	37,05	88,89	43,75	47,80	22,29	41,33
6	Regresión paso a paso	25,56	65,19	21,03	98,51	63,16	8,99	55,57	33,66	46,46
7	Red neuronal artificial	19,88	20,90	16,73	38,95	34,46	14,39	20,94	19,74	23,25

Fuente: Elaboración propia




Figura 3. MAPE por método y familia.
Fuente: Elaboración propia.

5.3 Análisis de los resultados para cada familia

Las Familias de vehículos en las que se obtiene el menor MAPE al utilizar los métodos tradicionales son: Accent y Creta de acuerdo a lo visto en la tabla 6, para ilustrar mejor los resultados alcanzados y entender el comportamiento de las ventas se muestran las Figuras 4 y 5 respectivamente. En donde, se puede observar que el rango de la demanda en los periodos considerados va de 104 a 153 unidades para la familia Accent, por su parte las ventas de la familia Creta van de 148 a 213 unidades.

Con relación al Accent (Figura 4), en los dos últimos meses se observa una tendencia decreciente que también es evidenciada por la regresión lineal, además el PMS y PMP logran un mejor ajuste que la RNA, como se sabe estos métodos dan mayor importancia a los datos más recientes razón por la cual se adaptan fácilmente.




Figura 4. Comparación de los pronósticos con las ventas para la familia Accent.
Fuente: Elaboración propia.

Para el caso de Creta (Figura 5), conforme a los últimos periodos también se trataría de una tendencia decreciente sin embargo la regresión lineal no refleja lo mismo, fácilmente se puede evidenciar que la regresión paso a paso se ajusta mejor en comparación a la RNA. La regresión paso a paso al igual que la RNA hace uso de variables independientes para predecir la variable objetivo, la diferencia del MAPE entre estos dos métodos puede verse justificada porque en la regresión paso a paso no se considera el retraso de las variables.




Figura 5. Comparación de los pronósticos con las ventas para la familia Creta.
Fuente: Elaboración propia.

En las familias Grand i10 Hatchback, Grand i10 Sedán, Ioniq, Sonata, Tucson y Santa Fe, las redes neuronales artificiales obtienen mejores resultados en comparación a los métodos tradicionales de acuerdo a lo mostrado en la tabla 6.

Las ventas para las familias Grand i10 Hatchback, Grand i10 Sedán, Ioniq, Sonata, Tucson, Santa Fe, se muestran en la Figura 6, 7, 8, 9, 10 y 11 respectivamente, podemos ver que las ventas alcanza valores mínimos y máximos de manera drástica, es decir se presenta mayor variabilidad que en los casos anteriores a juzgar por el rango de la demanda, además claramente se observa una tendencia creciente o decreciente dependiendo el caso, la RNA logra acoplarse mejor al comportamiento de la demanda y consigue un MAPE menor que los otros métodos, hay que mencionar que en las familias Ioniq y Santa Fe la diferencia de MAPE entre métodos no es muy significativa. En algunos casos los picos de ventas son causados porque en ciertos meses se manejan promociones así como por un tema de disponibilidad de vehículos.




Figura 6. Comparación de los pronósticos con las ventas para la familia Grand i10 hatchback.
Fuente: Elaboración propia.




Figura 7. Comparación de los pronósticos con las ventas para la familia Grand i10 sedán.
Fuente: Elaboración propia.




Figura 8. Comparación de los pronósticos con las ventas para la familia Ioniq.
Fuente: Elaboración propia.




Figura 9. Comparación de los pronósticos con las ventas para la familia Sonata.
Fuente: Elaboración propia.




Figura 10. Comparación de los pronósticos con las ventas para la familia Tucson.
Fuente: Elaboración propia.




Figura 11. Comparación de los pronósticos con las ventas para la familia Santa Fe.
Fuente: Elaboración propia.

5.4 Importancia relativa de las variables de entrada

En el Anexo 1, se ilustran las Figuras de todas las familias de vehículos con el porcentaje de importancia relativa alcanzado por cada una de las variables de entrada en la RNA. Conforme a eso, la importancia relativa de las variables de entrada oscila entre el 3 y el 11%, dos puntos importantes a considerar son que en las familias Grand i10 Hatchback, Grand i10 Sedán, Accent y Tucson la variable índice de confianza del consumidor (X9) logra ubicarse entre las primeras. Con relación a las variables internas, la variable inversión en publicidad (X5) sobresale en comparación a las variables X3 y X4 que también son internas. En general, se asigna un mayor porcentaje a las variables externas que en su mayoría son variables económicas.

5.5 Participación por color de vehículo en las ventas

El color de un vehículo es una característica importante a considerar por las razones indicadas anteriormente, en el Anexo 2, se muestra la distribución de colores en las ventas para cada uno de los casos. De acuerdo a eso, las preferencias de los compradores son para los colores blanco, plata y plomo, esto en las familias Grand i10 Hatchback, Grand i10 Sedán, Ioniq, Creta, Tucson y Santa Fe, con una participación de mercado del 68 al 80%, obviamente el Accent no presenta esta misma distribución debido a que en esta familia se incluye el color amarillo pues este vehículo puede ser utilizado para Taxi, además el Sonata muestra una pequeña variación pues la distribución es blanco, plomo y plata. Cabe mencionar que los colores blanco, plata y plomo también se encuentran dominando las ventas a nivel nacional de acuerdo a lo constatado en [31], asimismo se establece que a nivel de Sudamérica los colores blanco, plata y plomo continúan liderando como los preferidos con una participación total sobre el 74% de acuerdo con [32], [33], [34], lo que permite señalar que son colores que se encuentran posicionados en el mercado y conforme varía el tiempo no presentan mayores modificaciones siendo los colores más populares.

En resumen, la RNA logra mejores resultados en la mayoría de los casos en comparación a los métodos comúnmente utilizados como se ilustra en la tabla 6, lo que significa que se puede predecir las ventas de vehículos por familias utilizando variables internas y externas, de tal manera que se pueda tener una visión más clara del nivel de ventas para cada segmento, además se destacan los colores más populares con los que la marca debería contar. Hay que mencionar que una de las desventajas de las RNA es la ausencia de reglas definitorias que ayuden a desarrollar una red para resolver un problema dado, pues hay varios factores a considerar, como la arquitectura de la red, el algoritmo de aprendizaje, el número de capas, el número de neuronas, la normalización de datos, entre otras [35], por lo que fue necesario efectuar varias pruebas para determinar los parámetros más

apropiados para cada caso, convirtiéndose en una implementación empírica y en un reto para cualquier persona, pese a esto en el presente estudio y en investigaciones desarrolladas anteriormente se muestra la eficiencia de esta metodología. Además, aunque los resultados son satisfactorios, el número de variables internas y externas aún es limitado por la disposición de información tanto en la organización como en las fuentes gubernamentales, de igual manera es posible que no se estén considerando ciertas variables que también tengan relación con las ventas de vehículos y que sean de gran importancia para el sector, por lo tanto, posteriormente se podría investigar más acerca de más variables internas, económicas, políticas, ambientales y sociales para así mejorar el modelo de pronóstico. También, se podría analizar cómo cambia el rendimiento del método propuesto si se proporcionan mayor cantidad de datos, si se utiliza otro tipo de técnica en la selección de variables o si se emplea otro tipo de red.

6. Conclusiones

Es fundamental para la industria automotriz predecir las ventas con anticipación sobre todo por el tiempo que conlleva la importación, accesorización y distribución de los vehículos, es por eso que el presente estudio propone una metodología para predecir las ventas de la marca Hyundai, usando redes neuronales artificiales, que en los últimos tiempos han recibido un gran interés por conseguir un buen rendimiento en aplicaciones de predicción, básicamente las RNA predicen la variable objetivo en función de las variables que se les presenta, además son capaces de extraer información relevante como algún patrón o tendencia, entregando resultados fiables, convirtiéndose de esta manera en una herramienta precisa que ayuda a tomar decisiones y a su vez permite a las organizaciones ir a la par del avance de la tecnología. Inicialmente se realiza un proceso de selección de variables a través de la regresión de Lasso, para determinar las variables de mayor importancia en cada una de las familias de vehículos, evitando así que se produzca un sobreajuste al disponer de una cantidad de datos limitada, misma que se considera una debilidad de las redes neuronales artificiales, sin embargo con la configuración de los parámetros especificados en los puntos anteriores se consiguió mejores resultados que los métodos clásicos comúnmente usados.

De acuerdo a lo presentado anteriormente, se puede evidenciar que en dos familias: Accent y Creta, los métodos tradicionales alcanzan mejores resultados, uno de los puntos a considerar es que en estos casos se presenta menor variabilidad en la demanda, en el resto de familias, la variabilidad de la demanda es mayor y en algunos casos está más marcada que en otros, sin embargo en estas seis

familias la RNA se ajusta mejor en comparación a los métodos tradicionales, pues los métodos clásicos de previsión son muy sensibles a las grandes variaciones de demanda.

Las redes neuronales artificiales son capaces de predecir eficientemente las ventas de vehículos livianos a través del uso de variables internas y externas propias del sector automotriz, las cuales en su mayoría son variables económicas, en consecuencia estas pueden ser consideradas buenos predictores de las ventas de vehículos. Además, es posible determinar la importancia relativa de las variables de entrada a través de la metodología propuesta, en donde se evidenció que las variables externas obtienen porcentajes de importancia mayores que las internas, es decir el sector automotor se ve afectado directamente por los cambios en las medidas económicas del país.

Respecto a las ventas de vehículos por colores, se determinó que en la mayoría de familias las ventas siguen el orden: blanco, plata y plomo, y sumada su participación porcentual representan del 68 al 80% del total de las ventas, por consiguiente se puede señalar que estos colores se encuentran posicionados en el mercado y son los preferidos por los compradores, cabe mencionar que ese orden y participación porcentual también se mantiene a nivel nacional y a nivel de Sudamérica.

Para concluir, pese a que en la metodología propuesta se maneja un retraso en las variables por el tema de disposición de datos actualizados al momento de realizar la previsión, se obtienen resultados más precisos en contraste con los métodos comúnmente utilizados, lo que significa que las RNA son un método válido para predecir las ventas mensuales de vehículos livianos.

7. Agradecimiento

Expreso mis sinceros agradecimientos a la empresa por proporcionar la información necesaria, al docente e investigador Ing. Juvenal Ortiz director de este trabajo así como al investigador Ing. Mario Peña por su aporte y apoyo para que concluyera este proyecto, a mi familia por su constante apoyo y a todas las personas que han sido parte de este proceso.

8. Bibliografía



- [1] E. M. Toro, D. A. Mejía, y H. Salazar, “Pronóstico de ventas usando redes neuronales”, *Sci. Tech.*, vol. 10, núm. 26, pp. 25–30, dic. 2004.

- [2] S. Nojek, P. Britos, B. Rossi, y R. García, “Pronóstico de Ventas: Comparación de Predicción basada en Redes Neuronales versus Método Estadístico”, *Rep. Téc. En Ing. Softw.*, vol. 5, núm. 1, pp. 1–12, 2003.
- [3] L. J. Krajewski, M. K. Malhotra, y L. P. Ritzman, *Administración de operaciones: procesos y cadenas de valor*, 8a ed. México: Pearson Educación, 2008.
- [4] M. Hülsmann, D. Borscheid, C. M. Friedrich, y D. Reith, “General Sales Forecast Models for Automobile Markets and their Analysis”, *Trans. Mach. Learn. Data Min.*, vol. 5, núm. 2, pp. 65–86, 2012.
- [5] D. Fantazzini y Z. Toktamysova, “Forecasting German car sales using Google data and multivariate models”, *Int. J. Prod. Econ.*, vol. 170, pp. 97–135, 2015, doi: 10.1016/j.ijpe.2015.09.010.
- [6] S. Shahabuddin, “Forecasting automobile sales”, *Manag. Res. News*, vol. 32, núm. 7, pp. 670–682, jun. 2009, doi: 10.1108/01409170910965260.
- [7] Asociación de empresas automotrices del Ecuador, “Anuario 2012”, 2012.
- [8] Asociación de empresas automotrices del Ecuador, “Anuario 2014”, 2014.
- [9] Asociación de empresas automotrices del Ecuador, “Anuario 2015”, 2015.
- [10] El telégrafo, “Los cupos para importar autos se eliminan”, 01-oct-2016. [En línea]. Disponible en: <https://www.eltelegrafo.com.ec/noticias/economia/4/los-cupos-para-importar-autos-se-eliminan>. [Consultado: 18-sep-2019].
- [11] Asociación de empresas automotrices del Ecuador, “Anuario 2018”, 2018.
- [12] Servicio de Rentas Internas del Ecuador, “Información general - Servicio de Rentas Internas del Ecuador”, 2019. [En línea]. Disponible en: <https://www.sri.gob.ec/web/guest/informacion-general>. [Consultado: 15-feb-2019].
- [13] M. Pacheco, “La gasolina súper y el diésel tienen nuevos precios en Ecuador”, *El Comercio*, 28-dic-2018. [En línea]. Disponible en: <https://www.elcomercio.com/actualidad/super-diesel-nuevos-precios-gasolina.html>. [Consultado: 03-feb-2019].
- [14] Radio Programas del Perú, “La importancia del color en los autos de lujo”, *RPP Noticias*, 24-nov-2016. [En línea]. Disponible en: <https://rpp.pe/campanas/branded-content/la-importancia-del-color-en-los-autos-de-lujo-noticia-1012262>. [Consultado: 15-feb-2019].
- [15] C. H. Chuang y Y. Zhao, “Demand stimulation in finished-goods inventory management: Empirical evidence from General Motors dealerships”, *Int. J. Prod. Econ.*, vol. 208, pp. 208–220, nov. 2018, doi: 10.1016/j.ijpe.2018.11.013.
- [16] A. Vahabi, S. Seyyedi, y M. Alborzi, “A Sales Forecasting Model in Automotive Industry using Adaptive Neuro-Fuzzy Inference System (Anfis) and Genetic Algorithm (GA)”, *Int. J. Adv. Comput. Sci. Appl.*, vol. 7, núm. 11, pp. 24–30, 2016, doi: 10.14569/IJACSA.2016.071104.
- [17] S. Arslankaya y V. Öz, “Time Series Analysis of Sales Quantity in an Automotive Company and Estimation by Artificial Neural Networks”, *Sak. Univ. J. Sci.*, vol. 22, núm. 5, pp. 1482–1492, oct. 2018, doi: 10.16984/soaufenbilder.456518.
- [18] F. Villada, D. Arroyave, y M. Villada, “Pronóstico del Precio del Petróleo mediante Redes Neuronales Artificiales”, *Inf. Tecnológica*, vol. 25, núm. 3, pp. 145–154, 2014, doi: 10.4067/S0718-07642014000300017.
- [19] S. Vhatkar y J. Dias, “Oral-Care Goods Sales Forecasting Using Artificial Neural Network Model”, *Procedia Comput. Sci.*, vol. 79, pp. 238–243, 2016, doi: 10.1016/j.procs.2016.03.031.
- [20] A. Chawla, A. Singh, A. Lamba, N. Gangwani, y U. Soni, “Demand Forecasting Using Artificial Neural Networks—A Case Study of American Retail Corporation”, en *Applications of Artificial Intelligence Techniques in Engineering*, vol. 697, H. Malik, S. Srivastava, Y. R. Sood, y A. Ahmad, Eds. Singapore: Springer Singapore, 2019, pp. 79–89.


- [21] O. Kitapcı, H. Özekicioğlu, O. Kaynar, y S. Taştan, “The Effect of Economic Policies Applied in Turkey to the Sale of Automobiles: Multiple Regression and Neural Network Analysis”, *Procedia - Soc. Behav. Sci.*, vol. 148, pp. 653–661, ago. 2014, doi: 10.1016/j.sbspro.2014.07.094.
- [22] D. S. Farahani, M. Momeni, y N. S. Amiri, “Car Sales Forecasting Using Artificial Neural Networks and Analytical Hierarchy Process”, *Data Anal.*, pp. 57–62, 2016.
- [23] M. Alas y shaban I. A. Ali, “Prediction of the High-Temperature Performance of a Geopolymer Modified Asphalt Binder using Artificial Neural Networks”, *Int. J. Technol.*, vol. 10, núm. 2, pp. 417–427, abr. 2019, doi: 10.14716/ijtech.v10i2.2421.
- [24] R. Sharma y A. K. Sinha, “Sales Forecast of an Automobile Industry”, *Int. J. Comput. Appl.*, vol. 53, núm. 12, pp. 25–28, sep. 2012, doi: 10.5120/8474-2403.
- [25] F. Berzal, *Redes Neuronales & Deep Learning*, 1a ed. Granada: Universidad de Granada, 2018.
- [26] D. Singhal y K. S. Swarup, “Electricity price forecasting using artificial neural networks”, *Int. J. Electr. Power Energy Syst.*, vol. 33, núm. 3, pp. 550–555, mar. 2011, doi: 10.1016/j.ijepes.2010.12.009.
- [27] G. D. Garson, “Interpreting neural-network connection weights”, *AI Expert*, vol. 6, pp. 47–51, 1991.
- [28] O. M. Ibrahim, “A comparison of methods for assessing the relative importance of input variables in artificial neural networks”, *J. Appl. Sci. Res.*, vol. 9, núm. 11, pp. 5692–5700, 2013.
- [29] J. D. Olden y D. A. Jackson, “Illuminating the ‘black box’: a randomization approach for understanding variable contributions in artificial neural networks”, *Ecol. Model.*, vol. 154, núm. 1–2, pp. 135–150, 2002, doi: 10.1016/S0304-3800(02)00064-9.
- [30] V. Fonti y E. Belitser, “Feature Selection using lasso”, *VU Amst. Res. Pap. Bus. Anal.*, mar. 2017.
- [31] Cámara de la Industria Automotriz Ecuatoriana, “Anuario de la Industria Automotriz Ecuatoriana 2018”, 2018.
- [32] N. Lockhart, “Global Automotive 2017 Color Popularity Report”, *Axalta Coating Systems*, p. 5, 2017.
- [33] N. Lockhart, “Global Automotive 2018 Color Popularity Report”, *Axalta Coating Systems*, p. 5, 2018.
- [34] N. Lockhart, “Global Automotive 2019 Color Popularity Report”, *Axalta Coating Systems*, 2019.
- [35] E. Varela-Arregoces y E. Campbells-Sánchez, “Redes Neuronales Artificiales: Una Revisión del Estado del Arte, Aplicaciones Y Tendencias Futuras”, *Rev. Investig. Desarro. En TIC*, vol. 2, núm. 1, pp. 18–27, jun. 2011.

9. Anexos


Anexo 1. Importancia relativa de las variables de entrada para cada una de las familias de vehículos.




ACCENT




IONIQ




SONATA




CRETA





TUCSON




SANTA FE




Anexo 2. Participación porcentual por color de vehículo para cada una de las familias.




ACCENT




IONIQ




SONATA



CRETA



TUCSON



SANTA FE

