


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS
VALPARAÍSO-CHILE



PROYECCIONES DE TRÁFICO EN CARRETERA RUTA DEL MAULE

MEDIANTE MODELOS

ECONOMÉTRICOS CLÁSICOS

FELIPE ANDRÉS CANELO PÉREZ

MEMORIA PARA OPTAR AL TÍTULO DE

INGENIERO CIVIL INDUSTRIAL

PROFESOR GUÍA : SR. JUAN GRAFFIGNA

PROFESOR CORREFERENTE : SR. WERNER KRISTJANPOLLER R.

NOVIEMBRE 2018

AGRADECIMIENTOS

Esta entrega es parte del proceso de vida universitaria que culmina con este trabajo, por lo que quiero agradecer a todas las personas que fueron parte de mi vida en estos años e hicieron de la vida universitaria la tremenda experiencia que fue.

En primer lugar agradecer con todo mi corazón el apoyo incondicional de mi familia, siempre con confianza en mí y mis habilidades, formaron mi fortaleza para poder enfrentar cualquier desafío en el camino, mis ideales, valores y virtudes, gracias madre, padre y hermanito por su apoyo constante y gran paciencia. A mis tíos y tías que han sido un apoyo y siempre es grato conversar con ellos, a mi tía Claudia por recibirme en Santiago. Agradezco a The Petes, que gracias a ellos surgí académicamente, con su información constante sobre cuando son las pruebas y esos estudios a última hora, Miguel, Cristian, Messi, Simi, Coni y a mi primo Javier. Al equipo Joga de Calle, la garra de Bambi, Peirano, Seba Tapia, JP y José, ese campeonato inolvidable. A la ESM con la Carri y la Vane que fueron excelente grupo. A los chiquillos de Iquique y otras carreras, Delatorre, Pelao, Vale Mery, que saldrán pronto, al Seba y la Pía. A la Rama de karate USM excelentes competidores. A mis compañeros Parot, Ramos, Tatán y Caro Arias. Al tremendo Aron Cater que sin él no hubiese sido todo posible, al gran Cristian Rodriguez, el emprendedor Dani y los chicos de Santiago donde pasamos los últimos años en el patio del cañón guitarreando, Tutú, Anais, Doni, Sauliño, Stefano y al Freerider. Los chicos de intercambio, tremendo grupo, Annika, Jerome, Mile, Lola, Julia y Phillip. El Klagenfurt Lost&Found, Gabo, Javi, Andy y Edu. A los niños Klu, Xime, Kari y Cote. A los Vlados, Thelmo y Vladimir. A Camila con sus enojos.


Agradecer al profesor Werner Kristjanpoller por su excelente actitud, guía, aguantarme y apoyarme con mi memoria.

Finalmente agradecer al excelente equipo de Intervial Chile, un abrazo a Ernesto que hizo posible este trabajo con su guía, Constanza que me tendió una mano, a Luis, Federico, Patricio, Rubén, Lorena, Josefina y Alejandra, por su apoyo, su paciencia, toda su energía positiva y hacer posible este trabajo, por sobre todo por darme la posibilidad de desarrollarme profesionalmente y empezar este proceso de vida laboral en un ambiente grato.

Gracias a todos por hacer este proceso tan feliz, disfrutable y a muchos más.



*Dedicado a: mi hermano Daniel,
mi madre Ximena, mi Padre Adrian
a mis abuelas Adriana y Miriam,
y especialmente a mi difunta abuela Delia.
Abuelo Yeyo siempre estarás presente en nuestras vidas.*



RESUMEN EJECUTIVO

“La forma más confiable de predecir el futuro es tratar de entender el presente”

(Jhon Naisbitt, 1930). Analista de tendencias en series de tiempo.

La tarea de proyectar siempre ha sido un desafío interesante y con beneficios sustanciales si es realizado de la forma correcta. La proyección del tráfico es una parte integral del proceso de diseño de carreteras, comenzando desde los estudios de factibilidad de inversión, estructuración de deuda óptima a fin de conseguir menores tasas, hasta el desarrollo de planes de trabajo futuros.

Uno de los resultados del equilibrio entre las necesidades, deseos, ubicación, actividades y factores del transporte entre las personas particulares y transportistas es un cierto volumen de tráfico vehicular. Esto resulta en numerosas variables a que intentan explicar el comportamiento del tráfico vehicular, en el transcurso de esta memoria se toma el enfoque de series de tiempo para tratar dichas variables. Así como (Fildes 2014) define, en la tarea de pronosticar numerosas series de tiempo con procesos repetitivos, es necesario un punto de vista desde la automatización de estos procesos a fin de seleccionar los mejores métodos de proyección.

En el desarrollo de esta memoria un método es escogido y posteriormente aplicado a todas las series de tiempo en su análisis individual, luego siendo comparados y seleccionados los mejores métodos de proyección para dichas series tomando en cuenta sus diferentes características (tendencia, estacionalidad y estabilidad).

Fildes (2001) Demuestra que si la selección puede realizarse perfectamente entonces los beneficios prueban ser sustanciales. Basado en una combinación de ambos principios expuestos, el mismo método de análisis computacional para todas las series de tiempo, basado en los softwares estadísticos R estudio, Microsoft Excel y su extensión Solver. Cuidando individualmente sus características, cómo tendencia, estacionalidad, errores atípicos, estabilidad y estructura de las series de tiempo.

En el caso de esta memoria por los datos dispuestos el criterio será analizar 21 series de tiempo individualmente, una para cada tipo de vehículo, de los cuales se cuenta con 7

clasificaciones, en 3 rutas de peaje ubicadas en la Ruta del Maule. Se busca proyectar flujos anuales y mensuales para los años 2018, 2019 y 2020, y se cuenta con 10 años de datos diarios.

Se determinó que la mejor forma de tomar los datos a fin de proyectar es de forma anual y con ayuda del ajuste estacional generar los pronósticos mensuales requeridos.

Los pronósticos obtenidos fueron medidos y comparados con métricas de desempeño conocidas, como MSE, RMSE, MAE y MAPE para cada modelo en el estudio.



ABSTRACT

“The most reliable way to forecast the future is to try to understand the present.”

(Jhon Naisbitt, 1930)

The task of forecasting has always been an interesting challenge, with substantial benefits if it is done properly. Highway traffic forecasting is an essential part of the process of road designing, from investment feasibility studies to debt structure with the aim of lower interest rates, even in developing future working plans.

One of the results of an equilibrium of needs, desires, location, activities and transportation factors, between individual users and logistic transport of goods, is a certain volume of highway traffic. This analysis ends up with in a very large amount of variables trying to explain the behavior of Highway traffic, in this thesis work the focus the analysis though time series. As (Fildes 2014) defines, in the task of forecasting numerous time series with repetitive processes, an automatization point of view is need with the aim of selecting the best forecasting methods.

In the development of this work a method is chosen and subsequently applied to all time series individual analysis, being compared and selected the best approaches to forecasting, analyzing their characteristics (trend, stationarity, seasonality and stability).

Fildes (2001) proves that if selection can be made perfectly then benefits are substantial. Based on that fact, a combination of principles is defined, and the same computational analysis is applied to all time series, based on the statistic software's R studio, Microsoft excel and it's extension Solver. In this work, based on the data available, the criteria's aim is the analysis of 21 time series individually, for type of vehicle, with 7 classifications in 3 routes of tolls points located in Ruta del Maule Highway. The aim is to produce forecast annually and monthly for the years 2018, 2019 and 2020, with 10 years of daily data available. It is determined that the less biased way of forecasting monthly is to forecast annually and seasonally adjust the forecasts to obtain monthly projections.

The forecasting accuracy measures and model performance metrics mainly used are MSE, RMSE, MAE and MAPE for each model in study.

GLOSARIO

ACF	Función de autocorrelación
ADF	Dickey y Fuller Aumentada
AR	Autorregresivo
ARMA	Autorregresivo con Media Móvil
ARIMA	Autorregresivo Integrado con Media Móvil
MA	Media móvil
MAE	Error Absoluto Medio
MAPE	Porcentaje de Error Medio Absoluto
MCO	Mínimos Cuadrados Ordinarios
MSE	Error Cuadrático Medio
PACF	Función de Autocorrelación Parcial
RMSE	Raíz del Error Cuadrático Medio
TM	Tráfico Mensual
TA	Tráfico Anual

CONTENIDO

AGRADECIMIENTOS	i
RESUMEN EJECUTIVO.....	i
ABSTRACT	iii
GLOSARIO	iv
1.INTRODUCCIÓN.....	1
1.1. Descripción e historia de la ruta (carretera).....	2
1.2. Composición de la carretera.....	3
1.3. Hitos de causa natural que han afectado los tráficos	4
1.3.1. Terremoto 27 de febrero 2010	4
1.3.2. Incendios forestales 2017 y su efecto en el tráfico de Ruta del Maule	7
1.4. Antecedentes del Estudio	9
1.5. Problema de investigación	11
1.6. Objetivos	12
1.6.1. Objetivo general	12
1.6.2. Objetivos específicos	12
2. MARCO TEÓRICO	13
2.2. Enfoques en la predicción del tráfico	13
2.3. Técnicas Estadísticas.....	14

2.3.1. Procesos Estocásticos	14
2.3.2. Series de Tiempo.....	14
2.3.2.1. Análisis de Regresión	15
2.3.2.2. Estacionariedad	18
2.3.2.3. Ruido Blanco.....	19
2.3.2.4. Caminata Aleatoria	19
2.3.2.5. Raíz Unitaria.....	20
2.3.2.6. Procesos Integrados I(d)	21
2.3.2.7. Estacionalidad.....	22
2.3.3. Pruebas Estadísticas.....	23
2.3.3.1. Función de autocorrelación (ACF)	23
2.3.3.2. Función de autocorrelación parcial (PACF).....	24
2.3.3.3. Test de Ljung-Box	24
2.3.3.4. Test Dickey-Fuller Aumentada	25
2.3.4. Tratamiento de Estacionalidad	26
2.3.5. Transformación de Poder de Cox-Box	27
2.3.6. Leverage	28
2.3.7. Distancia de Cook.....	29
2.3.8. Modelos Lineales Estacionarios	29
2.3.8.1. Suavizamiento Exponencial Doble Holt Winter	29

2.3.8.2. Modelo Autorregresivo (AR(p)).....	30
2.3.8.3. Modelo de Media Móvil (MA(q))	31
2.3.8.4. Modelo Autorregresivo con Media Móvil (ARMA (p, q))	31
2.3.8.5. Modelo Autorregresivo Integrado con Media Móvil (ARIMA (p, d, q) (P, D, Q))	31
2.4. Trabajos Relacionados con proyecciones de tráfico.....	32
2.5. Trabajos relacionados con la elección del mejor método de validación de modelos..	35
2.6. Métricas de Desempeño de Pronósticos.....	37
2.6.1. Desviación media absoluta (MAD)	37
2.6.2. Error cuadrado medio (MSE).....	37
2.6.3. Raíz cuadrada del error medio (RMSE)	37
2.6.4. Error porcentual absoluto medio (MAPE)	38
2.6.5. Coeficiente de determinación (R cuadrado)	38
2.6.6. Coeficiente de determinación ajustado (R cuadrado ajustado)	38
2.7. Técnicas de Evaluación de Desempeño de Modelos	38
2.7.1. Criterio de la información akaike (AIC).....	38
2.7.2. Validación cruzada.....	39
2.7.2.1. Validación cruzada tradicional	40
2.7.2.2. Validación cruzada estándar (muestra aleatoria)	40
2.7.2.3. Validación cruzada de series de tiempo (variación de K-Fold Cross-Validation)	41

2.7.2.4. Validación cruzada aplicada	42
3. METODOLOGÍA	43
3.1.1. Preamálisis de datos	44
3.1.2. Análisis de los datos.....	45
3.2. Definición de un grupo de modelos candidatos de regresión para todas las series de tiempo	48
3.2.1. Literatura sobre la elección de variables candidatas	48
3.2.2. Variable explicativa.....	48
3.2.3. Modelos de regresión propuestos para el estudio	49
3.3. Parametrización de modelos	50
3.3.1. Parametrización de los modelos de regresión	50
3.3.2. Suavizamiento exponencial doble de Holt-Winters.....	51
3.3.3. Media móvil	51
3.3.4. ARIMA.....	51
3.4. Análisis de datos atípicos y estructura de las series de tiempo.....	52
3.4.1. Datos atípicos	52
3.4.2. Estructura de las series de tiempo	53
3.5. Selección de los mejores modelos por métricas de desempeño por grupo de modelos	54
3.6. Generación de proyecciones, transformación inversa de Cox-Box.....	54

3.7. Aplicación de validación cruzada variación de k-fold, comparación de modelos (con métrica robusta).	55
3.8. Paso de iteración	55
3.9. Proyección y ajustes estacionales a las proyecciones anuales	55
4. Resultados	56
4.1. Modelos finales de regresión lineal utilizados para proyectar	56
4.1. Comparación de modelos por MAPE 2016	57
4.2. Proyecciones de tráfico finales	59
4.2.1. Proyecciones más robustas obtenidas de los modelos de regresión lineal	59
4.2.2. Resumen comparativo de modelos por MAPE y desempeño 2017	60
4.3. Proyecciones anuales ajustadas a índices estacionales mensuales	61
4.3.1. Medida de error de ajuste de las proyecciones mensuales	61
4.3.2. Rio Claro proyecciones ajustadas mensualmente	63
4.3.3. Retiro proyecciones ajustadas mensualmente	64
4.3.4. Laterales proyecciones ajustadas mensualmente	66
5. Análisis de Resultados	68
6. Conclusiones y Recomendaciones	71
6.1. Conclusión	71
6.2. Recomendaciones y mejoras	72
6.3. Limitantes de los modelos expuestos	73
6.3.1. Variables Omitidas	73

6.3.2. Causalidad Inversa.....	73
6.3.3. Malas mediciones.....	74
6.3.4. Focos demasiado limitados	74
BIBLIOGRAFÍA.....	75
ANEXOS	76
A.1. Resultados de entrenamiento y validación de modelos por ruta.....	76
A.1.1. Rio Claro	76
A.1.1.1. Motos	76
A.1.1.2. Livianos	82
A.1.1.3. Livianos con remolque	86
A.1.1.4. Camiones de dos ejes.....	90
A.1.1.5. Camiones de más de dos ejes	94
A.1.1.6. Buses de dos ejes	99
A.1.1.7. Buses de más de dos ejes	103
A.1.2. Retiro	108
A.1.2.1. Motos	108
A.1.2.2. Livianos	112
A.1.2.3. Livianos con remolque	116
A.1.2.4. Camiones de dos ejes.....	121
A.1.2.5. Camiones de más de dos ejes	125

A.1.2.6. Buses de dos ejes	129
A.1.2.7. Buses de más de dos ejes	133
A.1.3. Laterales	138
A.1.3.1. Motos	138
A.1.3.2. Livianos	142
A.1.3.3. Livianos con remolque	146
A.1.3.4. Camiones de dos ejes	151
A.1.3.5. Camiones de más de dos ejes	155
A.1.3.6. Buses de dos ejes	159
A.1.3.7. Buses de más de dos ejes	163
A.2. Décimas Importantes en el análisis de los modelos de proyección y ajuste estacional.....	167
A.2.1. Retiro	167
A.2.1.1. Motos	167
A.2.1.2. Livianos	168
A.2.1.3. Livianos con remolque	170
A.2.1.4. Camiones de dos ejes	172
A.2.1.5. Camiones de más de dos ejes	173
A.2.1.6. Buses de dos ejes	175
A.2.1.7. Buses de más de dos ejes	177
A.2.2. Rio Claro	178

A.2.2.1. Motos	178
A.2.2.2. Livianos	180
A.2.2.3. Livianos con remolque	181
A.2.2.4. Camiones de dos ejes	183
A.2.2.5. Camiones de más de dos ejes	185
A.2.2.6. Buses de dos ejes	186
A.2.2.7. Buses de más de dos ejes	188
A.2.3. Laterales	190
A.2.3.1. Motos	190
A.2.3.2. Livianos	191
A.2.3.3. Livianos con remolque	193
A.2.3.4. Camiones de dos ejes	195
A.2.3.5. Camiones de más de dos ejes	196
A.2.3.6. Buses de dos ejes	198
A.2.3.7. Buses de más de dos ejes	200

ÍNDICE DE TABLAS

Tabla 1 Kms Peajes Laterales	3
------------------------------------	---

Tabla 2 Kms Peajes Troncales	3
Tabla 3 Simbología modelos de regresión	50
Tabla 4 Rio Claro, Resultados de preanálisis, modelo y comienzo de ventana de entrenamiento....	56
Tabla 5 Retiro, Resultados de preanálisis, modelo y comienzo de ventana de entrenamiento	57
Tabla 6 Laterales, Resultados de preanálisis, modelo y comienzo de ventana de entrenamiento.....	57
Tabla 7 Rio Claro comparación MAPE 2016	57
Tabla 8 Retiro comparación MAPE 2016.....	58
Tabla 9 Laterales comparación MAPE 2016	58
Tabla 10 Resultados proyección de tráfico total anual.....	59
Tabla 11 Rio Claro Resultados proyección de tráfico anual	59
Tabla 12 Retiro Resultados proyección de tráfico anual.....	60
Tabla 13 Laterales Resultados proyección de tráfico anual	60
Tabla 14 Retiro Comparación MAPE de entrenamiento, validación y desempeño de los modelos de proyección.....	61
Tabla 15 Laterales Comparación MAPE de entrenamiento, validación y desempeño de los modelos de proyección	61
Tabla 16 Rio Claro Comparación MAPE de entrenamiento, validación y desempeño de los modelos de proyección.....	61
Tabla 17 Retiro Coeficiente de determinación ajuste mensual por tipo de Vehículo	62
Tabla 18 Rio Claro Coeficiente de determinación ajuste mensual por tipo de Vehículo.....	62
Tabla 19 Laterales Coeficiente de determinación ajuste mensual por tipo de Vehículo.....	62
Tabla 20 Rio Claro proyección de tráfico mensual Livianos y Motos.....	63
Tabla 21 Rio Claro proyección de tráfico mensual Livianos con remolque y Buses de dos ejes	63

Tabla 22 Rio Claro proyección de tráfico mensual Camiones de dos ejes y Buses de más de dos ejes	64
Tabla 23 Rio Claro proyección de tráfico mensual Camiones de más de dos ejes	64
Tabla 24 Retiro proyección de tráfico mensual Motos y Livianos	64
Tabla 25 Retiro proyección de tráfico mensual Livianos con remolque y Buses de dos ejes.....	65
Tabla 26 Retiro proyección de tráfico mensual Camiones de dos ejes y Buses de más de dos ejes.	65
Tabla 27 Retiro proyección de tráfico mensual Camiones de más de dos ejes	66
Tabla 28 Laterales proyección de tráfico mensual Motos y Livianos.....	66
Tabla 29 Laterales proyección de tráfico mensual Livianos con remolque y Buses de dos ejes	66
Tabla 30 Laterales proyección de tráfico mensual Camiones de dos ejes y Buses de más de dos ejes	67
Tabla 31 Laterales proyección de tráfico mensual Camiones de más de dos ejes	67
A.Tabla 32 Rio Claro Motos, entrenamiento hasta 2014 resultados tráfico en niveles	77
A.Tabla 33 Rio Claro Motos, entrenamiento hasta 2014 resultados medidas de error y desempeño	77
A.Tabla 34 Rio Claro Motos, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	77
A.Tabla 35 Rio Claro Motos, entrenamiento hasta 2015 resultados tráfico en niveles	78
A.Tabla 36 Rio Claro Motos, entrenamiento hasta 2015 resultados medidas de error y desempeño	79
A.Tabla 37 Rio Claro Motos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	79
A.Tabla 38 Rio Claro Motos, entrenamiento hasta 2016 resultados tráfico en niveles	80
A.Tabla 39 Rio Claro Motos, entrenamiento hasta 2016 resultados medidas de error y desempeño	81
A.Tabla 40 Rio Claro Motos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	81

A.Tabla 41 Rio Claro Livianos, entrenamiento hasta 2014 resultados tráfico en niveles.....	82
A.Tabla 42 Rio Claro Livianos, entrenamiento hasta 2014 resultados medidas de error y desempeño	83
A.Tabla 43 Rio Claro Livianos, entrenamiento hasta 2014, estimadores del mejor modelo de regresión.....	83
A.Tabla 44 Rio Claro Livianos, entrenamiento hasta 2015, resultados tráfico en niveles.....	84
A.Tabla 45 Rio Claro Livianos, entrenamiento hasta 2015, resultados medidas de error y desempeño	84
A.Tabla 46 Rio Claro Livianos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión.....	84
A.Tabla 47 Rio Claro Livianos con remolque, entrenamiento hasta 2014, resultados tráfico en niveles	87
A.Tabla 48 Rio Claro Livianos con remolque, entrenamiento hasta 2014, resultados medidas de error y desempeño	87
A.Tabla 49 Rio Claro Livianos con remolque, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	87
A.Tabla 50 Rio Claro Livianos con remolque, entrenamiento hasta 2015, resultados tráfico en niveles	88
A.Tabla 51 Rio Claro Livianos con remolque, entrenamiento hasta 2015, resultados medidas de error y desempeño	89
A.Tabla 52 Rio Claro Livianos con remolque, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	89
A.Tabla 53 Rio Claro Livianos con remolque, entrenamiento hasta 2016, resultados tráfico en niveles	89

A.Tabla 54 Rio Claro Livianos con remolque, entrenamiento hasta 2016, resultados medidas de error y desempeño	90
A.Tabla 55 Rio Claro Livianos con remolque, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	90
A.Tabla 56 Rio Claro Camiones de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles	91
A.Tabla 57 Rio Claro Camiones de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño	91
A.Tabla 58 Rio Claro Camiones de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	91
A.Tabla 59 Rio Claro Camiones de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles	92
A.Tabla 60 Rio Claro Camiones de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño	92
A.Tabla 61 Rio Claro Camiones de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	93
A.Tabla 62 Rio Claro Camiones de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles	93
A.Tabla 63 Rio Claro Camiones de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño	94
A.Tabla 64 Rio Claro Camiones de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	94
A.Tabla 65 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles	95

A.Tabla 66 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño	95
A.Tabla 67 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	95
A.Tabla 68 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles	96
A.Tabla 69 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño	97
A.Tabla 70 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	97
A.Tabla 71 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles	98
A.Tabla 72 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño	98
A.Tabla 73 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	98
A.Tabla 74 Rio Claro Buses de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles..	99
A.Tabla 75 Rio Claro Buses de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño.....	100
A.Tabla 76 Rio Claro Buses de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	100
A.Tabla 77 Rio Claro Buses de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles	101
A.Tabla 78 Rio Claro Buses de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño.....	101

A.Tabla 79 Rio Claro Buses de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	101
A.Tabla 80 Rio Claro Buses de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles	102
A.Tabla 81 Rio Claro Buses de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño.....	102
A.Tabla 82 Rio Claro Buses de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	102
A.Tabla 83 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles	103
A.Tabla 84 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño	104
A.Tabla 85 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	104
A.Tabla 86 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles	105
A.Tabla 87 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño	105
A.Tabla 88 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	105
A.Tabla 89 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles	106
A.Tabla 90 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño	107
A.Tabla 91 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	107

A.Tabla 92 Retiro Motos, entrenamiento hasta 2014, resultados tráfico en niveles	108
A.Tabla 93 Retiro Motos, entrenamiento hasta 2014, resultados medidas de error y desempeño..	109
A.Tabla 94 Retiro Motos, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	109
A.Tabla 95 Retiro Motos, entrenamiento hasta 2015, resultados tráfico en niveles	109
A.Tabla 96 Retiro Motos, entrenamiento hasta 2015, resultados medidas de error y desempeño..	110
A.Tabla 97 Retiro Motos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	110
A.Tabla 98 Retiro Motos, entrenamiento hasta 2016, resultados tráfico en niveles	111
A.Tabla 99 Retiro Motos, entrenamiento hasta 2016, resultados medidas de error y desempeño..	111
A.Tabla 100 Retiro Motos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	111
A.Tabla 101 Retiro Livianos, entrenamiento hasta 2014, resultados tráfico en niveles	112
A.Tabla 102 Retiro Livianos, entrenamiento hasta 2014, resultados medidas de error y desempeño	113
A.Tabla 103 Retiro Livianos, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	113
A.Tabla 104 Retiro Livianos, entrenamiento hasta 2015, resultados tráfico en niveles	114
A.Tabla 105 Retiro Livianos, entrenamiento hasta 2015, resultados medidas de error y desempeño	114
A.Tabla 106 Retiro Livianos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	114
A.Tabla 107 Retiro Livianos, entrenamiento hasta 2016, proyecciones	115
A.Tabla 108 Retiro Livianos, entrenamiento hasta 2016, resultados tráfico en niveles	115
A.Tabla 109 Retiro Livianos, entrenamiento hasta 2016, resultados medidas de error y desempeño	115

A.Tabla 110 Retiro Livianos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	116
A.Tabla 111 Retiro Livianos con remolque, entrenamiento hasta 2014, resultados tráfico en niveles	116
A.Tabla 112 Retiro Livianos con remolque, entrenamiento hasta 2014, resultados medidas de error y desempeño	117
A.Tabla 113 Retiro Livianos con remolque, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	117
A.Tabla 114 Retiro Livianos con remolque, entrenamiento hasta 2015, resultados tráfico en niveles	118
A.Tabla 115 Retiro Livianos con remolque, entrenamiento hasta 2015, resultados medidas de error y desempeño	118
A.Tabla 116 Retiro Livianos con remolque, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	118
A.Tabla 117 Retiro Livianos con remolque, entrenamiento hasta 2016, resultados tráfico en niveles	119
A.Tabla 118 Retiro Livianos con remolque, entrenamiento hasta 2016, resultados medidas de error y desempeño	120
A.Tabla 119 Retiro Livianos con remolque, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	120
A.Tabla 120 Retiro Camiones de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles	121
A.Tabla 121 Retiro Camiones de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño	122

A.Tabla 122 Retiro Camiones de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	122
A.Tabla 123 Retiro Camiones de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles	122
A.Tabla 124 Retiro Camiones de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño.....	123
A.Tabla 125 Retiro Camiones de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	123
A.Tabla 126 Retiro Camiones de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles	124
A.Tabla 127 Retiro Camiones de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño.....	124
A.Tabla 128 Retiro Camiones de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	124
A.Tabla 129 Retiro Camiones de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles	125
A.Tabla 130 Retiro Camiones de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño	126
A.Tabla 131 Retiro Camiones de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	126
A.Tabla 132 Retiro Camiones de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles	127
A.Tabla 133 Retiro Camiones de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño	127

A.Tabla 134 Retiro Camiones de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	127
A.Tabla 135 Retiro Camiones de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles	128
A.Tabla 136 Retiro Camiones de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño	128
A.Tabla 137 Retiro Camiones de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	129
A.Tabla 138 Retiro Buses de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles ...	129
A.Tabla 139 Retiro Buses de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño.....	130
A.Tabla 140 Retiro Buses de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión.....	130
A.Tabla 141 Retiro Buses de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles ...	131
A.Tabla 142 Retiro Buses de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño.....	131
A.Tabla 143 Retiro Buses de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión.....	131
A.Tabla 144 Retiro Buses de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles ...	132
A.Tabla 145 Retiro Buses de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño.....	133
A.Tabla 146 Retiro Buses de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión.....	133
A.Tabla 147 Retiro Buses de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles	134

A.Tabla 148 Retiro Buses de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño	134
A.Tabla 149 Retiro Buses de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	134
A.Tabla 150 Retiro Buses de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles	135
A.Tabla 151 Retiro Buses de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño	135
A.Tabla 152 Retiro Buses de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	136
A.Tabla 153 Retiro Buses de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles	137
A.Tabla 154 Retiro Buses de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño	137
A.Tabla 155 Retiro Buses de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	137
A.Tabla 156 Laterales Motos, entrenamiento hasta 2014, resultados tráfico en niveles	138
A.Tabla 157 Laterales Moto, entrenamiento hasta 2014, resultados medidas de error y desempeño	139
A.Tabla 158 Laterales Moto, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	139
A.Tabla 159 Laterales Motos, entrenamiento hasta 2015, resultados tráfico en niveles	139
A.Tabla 160 Laterales Motos, entrenamiento hasta 2015, resultados medidas de error y desempeño	140

A.Tabla 161 Laterales Motos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión.....	140
A.Tabla 162 Laterales Motos, entrenamiento hasta 2016, resultados tráfico en niveles	141
A.Tabla 163 Laterales Motos, entrenamiento hasta 2016, resultados medidas de error y desempeño	141
A.Tabla 164 Laterales Motos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión.....	141
A.Tabla 165 Laterales Livianos, entrenamiento hasta 2014, resultados tráfico en niveles.....	142
A.Tabla 166 Laterales Livianos, entrenamiento hasta 2014, resultados medidas de error y desempeño.....	143
A.Tabla 167 Laterales Livianos, entrenamiento hasta 2014, estimadores del mejor modelo de regresión.....	143
A.Tabla 168 Laterales Livianos, entrenamiento hasta 2015, resultados tráfico en niveles.....	144
A.Tabla 169 Laterales Livianos, entrenamiento hasta 2015, resultados medidas de error y desempeño.....	144
A.Tabla 170 Laterales Livianos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión.....	144
A.Tabla 171 Laterales Livianos, entrenamiento hasta 2016, resultados tráfico en niveles.....	145
A.Tabla 172 Laterales Livianos, entrenamiento hasta 2016, resultados medidas de error y desempeño.....	146
A.Tabla 173 Laterales Livianos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión.....	146
A.Tabla 174 Laterales Livianos con remolque, entrenamiento hasta 2014, resultados tráfico en niveles	147

A.Tabla 175 Laterales Livianos con remolque, entrenamiento hasta 2014, resultados medidas de error y desempeño	147
A.Tabla 176 Laterales Livianos con remolque, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	147
A.Tabla 177 Laterales Livianos con remolque, entrenamiento hasta 2015, resultados tráfico en niveles	148
A.Tabla 178 Laterales Livianos con remolque, entrenamiento hasta 2015, resultados medidas de error y desempeño	149
A.Tabla 179 Laterales Livianos con remolque, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	149
A.Tabla 180 Laterales Livianos con remolque, entrenamiento hasta 2016, resultados tráfico en niveles	150
A.Tabla 181 Laterales Livianos con remolque, entrenamiento hasta 2016, resultados medidas de error y desempeño	150
A.Tabla 182 Laterales Livianos con remolque, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	150
A.Tabla 183 Laterales Camiones de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles	151
A.Tabla 184 Laterales Camiones de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño	152
A.Tabla 185 Laterales Camiones de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	152
A.Tabla 186 Laterales Camiones de dos ejes, entrenamiento hasta 2015, proyecciones	152
A.Tabla 187 Laterales Camiones de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles	153

A.Tabla 188 Laterales Camiones de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño.....	153
A.Tabla 189 Laterales Camiones de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	153
A.Tabla 190 Laterales Camiones de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles	154
A.Tabla 191 Laterales Camiones de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño.....	154
A.Tabla 192 Laterales Camiones de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	154
A.Tabla 193 Laterales Camiones de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles.....	155
A.Tabla 194 Laterales Camiones de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño	156
A.Tabla 195 Laterales Camiones de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión.....	156
A.Tabla 196 Laterales Camiones de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles.....	157
A.Tabla 197 Laterales Camiones de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño	157
A.Tabla 198 Laterales Camiones de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión.....	157
A.Tabla 199 Laterales Camiones de más de dos ejes, entrenamiento hasta 2016, proyecciones....	157
A.Tabla 200 Laterales Camiones de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles.....	158

A.Tabla 201 Laterales Camiones de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño	158
A.Tabla 202 Laterales Camiones de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	158
A.Tabla 203 Buses de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles	159
A.Tabla 204 Buses de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño	160
A.Tabla 205 Buses de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	160
A.Tabla 206 Buses de dos ejes, entrenamiento hasta 2015, proyecciones	160
A.Tabla 207 Buses de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles	161
A.Tabla 208 Buses de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño	161
A.Tabla 209 Buses de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión	161
A.Tabla 210 Buses de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles	162
A.Tabla 211 Buses de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño	162
A.Tabla 212 Buses de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión	162
A.Tabla 213 Buses de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles ..	163
A.Tabla 214 Buses de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño	164
A.Tabla 215 Buses de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión	164

A.Tabla 216 Buses de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles..	165
A.Tabla 217 Buses de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño.....	165
A.Tabla 218 Buses de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión.....	165
A.Tabla 219 Buses de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles..	166
A.Tabla 220 Buses de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño.....	166
A.Tabla 221 Buses de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión.....	166
A.Tabla 222 Retiro Motos Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	167
A.Tabla 223 Retiro Motos R2 ajuste estacional aplicado a modelos anuales	167
A.Tabla 224 Retiro Motos Índices estacionales mensuales	168
A.Tabla 225 Retiro Livianos Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	169
A.Tabla 226 Retiro Livianos R2 ajuste estacional aplicado a modelos anuales	169
A.Tabla 227 Retiro Livianos Índices estacionales mensuales.....	169
A.Tabla 228 Retiro Livianos con remolque Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	170
A.Tabla 229 Retiro Livianos con remolque R2 ajuste estacional aplicado a modelos anuales.....	171
A.Tabla 230 Retiro Livianos con remolque Índices estacionales mensuales.....	171
A.Tabla 231 Retiro Camiones de dos ejes Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	172
A.Tabla 232 Retiro Camiones de dos ejes R2 ajuste estacional aplicado a modelos anuales.....	172

A.Tabla 233 Retiro Camiones de dos ejes Índices estacionales mensuales	173
A.Tabla 234 Retiro Camiones de más de dos ejes Dótimas y test de hipótesis aplicados al modelo de proyección más robusto	173
A.Tabla 235 Retiro Camiones de más de dos ejes R2 ajuste estacional aplicado a modelos anuales	174
A.Tabla 236 Retiro Camiones de más de dos ejes Índices estacionales mensuales.....	174
A.Tabla 237 Retiro Buses de dos ejes Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	175
A.Tabla 238 Retiro Buses de dos ejes R2 ajuste estacional aplicado a modelos anuales	176
A.Tabla 239 Retiro Buses de dos ejes Índices estacionales mensuales	176
A.Tabla 240 Retiro Buses de más de dos ejes Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	177
A.Tabla 241 Retiro Buses de más de dos ejes R2 ajuste estacional aplicado a modelos anuales ...	177
A.Tabla 242 Retiro Buses de más de dos ejes Índices estacionales mensuales	178
A.Tabla 243 Rio Claro Motos Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	178
A.Tabla 244 Rio Claro Motos R2 ajuste estacional aplicado a modelos anuales	179
A.Tabla 245 A.Tabla 230 Rio Claro Motos Índices estacionales mensuales.....	179
A.Tabla 246 Rio Claro Livianos Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	180
A.Tabla 247 Rio Claro Livianos R2 ajuste estacional aplicado a modelos anuales.....	181
A.Tabla 248 Rio Claro Livianos Índices estacionales mensuales.....	181
A.Tabla 249 Rio Claro Livianos con remolque Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	182

A.Tabla 250 Rio Claro Livianos con remolque R2 ajuste estacional aplicado a modelos anuales .	182
A.Tabla 251 Rio Claro Livianos con remolque Índices estacionales mensuales	182
A.Tabla 252 Rio Claro Camiones de dos ejes Décimas y test de hipótesis aplicados al modelo de proyección más robusto.....	183
A.Tabla 253 Rio Claro Camiones de dos ejes R2 ajuste estacional aplicado a modelos anuales ...	184
A.Tabla 254 Rio Claro Camiones de dos ejes Índices estacionales mensuales	184
A.Tabla 255 Rio Claro Camiones de más de dos ejes Décimas y test de hipótesis aplicados al modelo de proyección más robusto	185
A.Tabla 256 Rio Claro Camiones de más de dos ejes R2 ajuste estacional aplicado a modelos anuales.....	185
A.Tabla 257 Rio Claro Camiones de más de dos ejes Índices estacionales mensuales	186
A.Tabla 258 Rio Claro Buses de dos ejes Décimas y test de hipótesis aplicados al modelo de proyección más robusto.....	187
A.Tabla 259 Rio Claro Buses de dos ejes Décimas y test de hipótesis aplicados al modelo de proyección más robusto.....	187
A.Tabla 260 Rio Claro Buses de dos ejes Índices estacionales mensuales.....	187
A.Tabla 261 Rio Claro Buses de dos ejes Índice estacional mensual por año	188
A.Tabla 262 Rio Claro Buses de más de dos ejes Décimas y test de hipótesis aplicados al modelo de proyección más robusto.....	188
A.Tabla 263 Rio Claro Buses de más de dos ejes R2 ajuste estacional aplicado a modelos anuales	189
A.Tabla 264 Rio Claro Buses de más de dos ejes Índices estacionales mensuales.....	189
A.Tabla 265 Laterales Motos Décimas y test de hipótesis aplicados al modelo de proyección más robusto.....	190
A.Tabla 266 Laterales Motos R2 ajuste estacional aplicado a modelos anuales	190

A.Tabla 267 Laterales Motos Índices estacionales mensuales.....	191
A.Tabla 268 Laterales Livianos Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	192
A.Tabla 269 Laterales Livianos R2 ajuste estacional aplicado a modelos anuales.....	192
A.Tabla 270 Laterales Livianos Índices estacionales mensuales.....	192
A.Tabla 271 Laterales Livianos con remolque Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	193
A.Tabla 272 Laterales Livianos con remolque R2 ajuste estacional aplicado a modelos anuales..	194
A.Tabla 273 Laterales Livianos con remolque Índices estacionales mensuales	194
A.Tabla 274 Laterales Camiones de dos ejes Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	195
A.Tabla 275 Laterales Camiones de dos ejes R2 ajuste estacional aplicado a modelos anuales	195
A.Tabla 276 Laterales Camiones de dos ejes Índices estacionales mensuales	196
A.Tabla 277 Laterales Camiones de más de dos ejes Dótimas y test de hipótesis aplicados al modelo de proyección más robusto	197
A.Tabla 278 Laterales Camiones de más de dos ejes R2 ajuste estacional aplicado a modelos anuales.....	197
A.Tabla 279 Laterales Camiones de más de dos ejes Índices estacionales mensuales	197
A.Tabla 280 Laterales Buses de dos ejes Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	198
A.Tabla 281 Laterales Buses de dos ejes R2 ajuste estacional aplicado a modelos anuales	199
A.Tabla 282 Laterales Buses de dos ejes Índices estacionales mensuales.....	199
A.Tabla 283 Laterales Buses de más de dos ejes Dótimas y test de hipótesis aplicados al modelo de proyección más robusto.....	200

A.Tabla 284 Laterales Buses de más de dos ejes R2 ajuste estacional aplicado a modelos anuales	200
A.Tabla 285 Laterales Buses de más de dos ejes Índices estacionales mensuales.....	201

ÍNDICE DE FIGURAS

Figura 1 Mapa ruta del Maule.....	2
Figura 2 Representación Sismo 2010	4
Figura 3 Sector Copihue: Grave daño por colapso tablero poniente PS FFCC y terraplén de acceso norte.....	5
Figura 4 Enlace Retiro Daño Terraplenes de acceso.....	5
Figura 5 Enlace Villaseca: Colapso por licuefacción de terraplén poniente.	5
Figura 6 Simbología de datos.....	40
Figura 7 Partición de datos en validación cruzada tradicional agrupativa	40
Figura 8 Partición de datos en validación cruzada aleatoria	41
Figura 9 Partición de datos en k-fold validación cruzada	41
Figura 10 Ejemplo particionamiento de datos en la validación de este estudio	42
Figura 11 Partición de datos en el preanálisis	45

ÍNDICE DE GRÁFICOS

Gráfico 1 Vehículos por año. Febrero, 2008-2012.....	6
Gráfico 2 Vehículos por año. Marzo, 2008-2012.....	6
Gráfico 3 Vehículos por año. Abril, 2008-2012.....	7
Gráfico 4 Vehículos por año. Febrero, 2014-2018.....	8
Gráfico 5 Vehículos por año. Marzo, 2014-2018.....	9

Gráfico 6 Auto Correlación vs rezago.....	23
Gráfico 7 Función Autocorrelación y Parcial contra rezagos	46
Gráfico 8 Estacionalidad anual por mes.....	47
Gráfico 9 Estacionalidad mensual por año.....	47
Gráfico 10 Residuales estandarizados vs apalancamiento	53
Gráfico 11 Serie de tiempo con cambios estructurales	54
A.Gráfico 12 Rio Claro Motos entrenamiento hasta 2014, proyecciones.....	76
A.Gráfico 13 Rio Claro Motos entrenamiento hasta 2015, proyecciones.....	78
A.Gráfico 14 Rio Claro Motos entrenamiento hasta 2016, proyecciones.....	80
A.Gráfico 15 Rio Claro Livianos entrenamiento hasta 2014, proyecciones	82
A.Gráfico 16 Rio Claro Livianos entrenamiento hasta 2015, proyecciones	83
A.Gráfico 17 Rio Claro Livianos entrenamiento hasta 2016, proyecciones	85
A.Gráfico 18 Rio Claro Livianos, entrenamiento hasta 2016, resultados tráfico en niveles.....	85
A.Gráfico 19 Rio Claro Livianos, entrenamiento hasta 2016, resultados medidas de error y desempeño.....	86
A.Gráfico 20 Rio Claro Livianos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión.....	86
A.Gráfico 21 Rio Claro Livianos con remolque, entrenamiento hasta 2014, proyecciones	86
A.Gráfico 22 Rio Claro Livianos con remolque, entrenamiento hasta 2015, proyecciones	88
A.Gráfico 23 Rio Claro Livianos con remolque, entrenamiento hasta 2016, proyecciones	89
A.Gráfico 24 Rio Claro Camiones de dos ejes, entrenamiento hasta 2014, proyecciones.....	90
A.Gráfico 25 Rio Claro Camiones de dos ejes, entrenamiento hasta 2015, proyecciones.....	92
A.Gráfico 26 Rio Claro Camiones de dos ejes, entrenamiento hasta 2016, proyecciones.....	93
A.Gráfico 27 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2014, proyecciones ...	94

A.Gráfico 28 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2015, proyecciones ...	96
A.Gráfico 29 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2016, proyecciones ...	97
A.Gráfico 30 Rio Claro Buses de dos ejes, entrenamiento hasta 2014, proyecciones	99
A.Gráfico 31 Rio Claro Buses de dos ejes, entrenamiento hasta 2015, proyecciones	100
A.Gráfico 32 Rio Claro Buses de dos ejes, entrenamiento hasta 2016, proyecciones	101
A.Gráfico 33 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2014, proyecciones	103
A.Gráfico 34 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2015, proyecciones	104
A.Gráfico 35 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2016, proyecciones	106
A.Gráfico 36 Retiro Motos, entrenamiento hasta 2014, proyecciones.....	108
A.Gráfico 37 Retiro Motos, entrenamiento hasta 2015, proyecciones.....	109
A.Gráfico 38 Retiro Motos, entrenamiento hasta 2016, proyecciones.....	110
A.Gráfico 39 Retiro Livianos, entrenamiento hasta 2014, proyecciones.....	112
A.Gráfico 40 Retiro Livianos, entrenamiento hasta 2015, proyecciones.....	113
A.Gráfico 41 Retiro Livianos con remolque, entrenamiento hasta 2014, proyecciones	116
A.Gráfico 42 Retiro Livianos con remolque, entrenamiento hasta 2015, proyecciones	117
A.Gráfico 43 Retiro Livianos con remolque, entrenamiento hasta 2016, proyecciones	119
A.Gráfico 44 Retiro Camiones de dos ejes, entrenamiento hasta 2014, proyecciones	121
A.Gráfico 45 Retiro Camiones de dos ejes, entrenamiento hasta 2015, proyecciones	122
A.Gráfico 46 Retiro Camiones de dos ejes, entrenamiento hasta 2016, proyecciones	123
A.Gráfico 47 Retiro Camiones de más de dos ejes, entrenamiento hasta 2014, proyecciones	125
A.Gráfico 48 Retiro Camiones de más de dos ejes, entrenamiento hasta 2015, proyecciones	126
A.Gráfico 49 Retiro Camiones de más de dos ejes, entrenamiento hasta 2016, proyecciones	127
A.Gráfico 50 Retiro Buses de dos ejes, entrenamiento hasta 2014, proyecciones.....	129
A.Gráfico 51 Retiro Buses de dos ejes, entrenamiento hasta 2015, proyecciones.....	130

A.Gráfico 52 Retiro Buses de dos ejes, entrenamiento hasta 2016, proyecciones.....	132
A.Gráfico 53 Retiro Buses de más de dos ejes, entrenamiento hasta 2014, proyecciones.....	133
A.Gráfico 54 Retiro Buses de más de dos ejes, entrenamiento hasta 2015, proyecciones.....	135
A.Gráfico 55 Retiro Buses de más de dos ejes, entrenamiento hasta 2016, proyecciones.....	136
A.Gráfico 56 Laterales Motos, entrenamiento hasta 2014, proyecciones	138
A.Gráfico 57 Laterales Motos, entrenamiento hasta 2015, proyecciones	139
A.Gráfico 58 Laterales Motos, entrenamiento hasta 2016, proyecciones	140
A.Gráfico 59 Laterales Livianos, entrenamiento hasta 2014, proyecciones	142
A.Gráfico 60 Laterales Livianos, entrenamiento hasta 2015, proyecciones	143
A.Gráfico 61 Laterales Livianos, entrenamiento hasta 2016, proyecciones	145
A.Gráfico 62 Laterales Livianos con remolque, entrenamiento hasta 2014, proyecciones	146
A.Gráfico 63 Laterales Livianos con remolque, entrenamiento hasta 2015, proyecciones	148
A.Gráfico 64 Laterales Livianos con remolque, entrenamiento hasta 2016, proyecciones	149
A.Gráfico 65 Laterales Camiones de dos ejes, entrenamiento hasta 2014, proyecciones.....	151
A.Gráfico 66 Laterales Camiones de dos ejes, entrenamiento hasta 2015, proyecciones.....	153
A.Gráfico 67 Laterales Camiones de más de dos ejes, entrenamiento hasta 2014, proyecciones ..	155
A.Gráfico 68 Laterales Camiones de más de dos ejes, entrenamiento hasta 2015, proyecciones ..	156
A.Gráfico 69 Buses de dos ejes, entrenamiento hasta 2014, proyecciones.....	159
A.Gráfico 70 Buses de dos ejes, entrenamiento hasta 2016, proyecciones.....	161
A.Gráfico 71 Buses de más de dos ejes, entrenamiento hasta 2014, proyecciones.....	163
A.Gráfico 72 Buses de más de dos ejes, entrenamiento hasta 2015, proyecciones.....	164
A.Gráfico 73 Buses de más de dos ejes, entrenamiento hasta 2016, proyecciones.....	165
A.Gráfico 74 Retiro Motos Índice estacional mensual por año	168
A.Gráfico 75 Retiro Livianos Índice estacional mensual por año.....	170

A.Gráfico 76 Retiro Livianos con remolque Índice estacional mensual por año.....	171
A.Gráfico 77 Retiro Camiones de dos ejes Índice estacional mensual por año	173
A.Gráfico 78 Retiro Camiones de más de dos ejes Índice estacional mensual por año	175
A.Gráfico 79 Retiro Buses de dos ejes Índice estacional mensual por año	176
A.Gráfico 80 Retiro Buses de más de dos ejes Índice estacional mensual por año	178
A.Gráfico 81 Rio Claro Motos Índice estacional mensual por año.....	180
A.Gráfico 82 Rio Claro Livianos Índice estacional mensual por año	181
A.Gráfico 83 Rio Claro Livianos con remolque Índice estacional mensual por año	183
A.Gráfico 84 Rio Claro Camiones de dos ejes Índice estacional mensual por año	184
A.Gráfico 85 Rio Claro Camiones de más de dos ejes Índice estacional mensual por año	186
A.Gráfico 86 Rio Claro Buses de más de dos ejes Índice estacional mensual por año.....	189
A.Gráfico 87 Laterales Motos Índice estacional mensual por año.....	191
A.Gráfico 88 Laterales Livianos Índice estacional mensual por año	193
A.Gráfico 89 Laterales Livianos con remolque Índice estacional mensual por año	194
A.Gráfico 90 Laterales Camiones de dos ejes Índice estacional mensual por año	196
A.Gráfico 91 Laterales Camiones de más de dos ejes Índice estacional mensual por año	198
A.Gráfico 92 Laterales Buses de dos ejes Índice estacional mensual por año	199
A.Gráfico 93 Laterales Buses de más de dos ejes Índice estacional mensual por año.....	201

1.INTRODUCCIÓN

“Prediction is difficult, especially the future” Niels Bohr – (1885-1962). Ganador del premio nobel de física.

Incluso con el significativo incremento de poder de procesamiento computacional a la fecha no se ha encontrado una teoría general satisfactoria que pueda ser consistentemente aplicada a condiciones de flujo de tráfico real. Los modelos actuales utilizan una mezcla de técnicas empíricas y teóricas, estos son utilizados para desarrollar proyecciones de tráfico tomando en cuenta cambios locales y globales en los datos, tales como incrementos en el uso de vehículos, cambios en el comportamiento de uso de los caminos o incluso en los métodos de transporte (migración de buses a trenes o autos dependiendo de incremento y baja en costos de combustibles, etc.), e identificado áreas de congestionamiento en las redes de caminos en carreteras, que proponen ajustes a al planteamiento de modelos predictivos. En esta memoria es recopilada literatura a fin de aplicar los mejores modelos de predicción, menos sesgados y con mejor desempeño dentro de lo posible, aplicado a la predicción de tráfico vehicular en la carretera de Ruta del Maule, concesionada por Intervial Chile.

1.1. Descripción e historia de la ruta (carretera)

Ruta del Maule fue constituida originalmente como “Ruta 5, Tramo Talca Chillan S.A.”, es una carretera adjudicada por Intervial Chile (en ese entonces, bajo el nombre de Ferrovial Chile) en enero de 1996, e inició sus operaciones en 1998.

La Sociedad Concesionaria tiene como único objeto el diseño, la construcción, mantención, explotación y operación de la obra pública y fiscal denominada “Ruta 5 tramo Talca Chillan”.

La construcción de este tramo amplió la capacidad de la vía y produjo un significativo mejoramiento de sus niveles de servicio, ya que las obras contemplaron la ampliación a segundas calzadas en 88,3 kilómetros, incluyendo puentes.

La concesión cuenta con dos plazas de peaje troncales (Río Claro y Retiro) y 16 entradas y salidas laterales.

Además, cuenta con 74 puentes, 40 enlaces, 52 pasarelas peatonales, 10 pasos sobre y bajo línea férrea, 11 atraviesos, 180 paraderos de buses, 76 km de áreas de servicio, 3km de ciclovías, 58 citófonos de S.O.S. de emergencia, 4 áreas de servicios, 2 estacionamientos de camiones y 2 áreas de control.



Figura 1 Mapa ruta del Maule

1.2. Composición de la carretera

Peajes laterales	Kms
Varoli	253,1 Oriente
Tabaco	255,5 Oriente
Unihue	259,7 Oriente
Maule	263,7 Oriente
Colbún	269.3 Poniente
San Javier Norte	270.6 Poniente
San Javier Centro	273.3 Poniente
Constitución	277.2 Poniente
Villa Alegre	284.0 Poniente
Linares	300.7 Poniente
Parral	340.9 Oriente
San Carlos Norte	374.7 Poniente
San Carlos Sur	378.1 Oriente
Cocharcas	391.9 Poniente
Chillán Norte	396,5 Oriente
Chillán Sur	406,4 Oriente

Tabla 1 Kms Peajes Laterales

Plazas de Peajes Troncales	Kms
Plaza de Peaje Troncal Rio Claro	220,3
Plaza Peaje Troncal Retiro	322,5

Tabla 2 Kms Peajes Troncales

Esta concesión se encuentra emplazada entre las localidades de Camarico y Racapequén, abarcando la VII y VIII región de Chile (desde el Km 219,49 al KM 412,88 de la Ruta 5 Sur). En la zona de influencia de la concesión, los sectores determinantes en la generación del producto regional bruto son el agropecuario- silvícola, industria manufacturera y comercio.

1.3. Hitos de causa natural que han afectado los tráficos

1.3.1. Terremoto 27 de febrero 2010

Sucesos importantes de causa natural han afectado los tráficos de Ruta del Maule, uno de los casos fue el terremoto de magnitud 8,8 en escala de Richter el 27 de febrero del año 2010, que afectó a las Regiones del Maule y del Biobío, ya que, el epicentro se situó en la costa justo frente al límite de ambas regiones, específicamente frente a las localidades de Curanipe y Cobquecura.

Posteriormente al terremoto, ocurrió un tsunami y salida de mar que abarcó 500 km de la costa chilena, afectando instalaciones costeras.

Los daños que provocó este terremoto comprenden estructuras colapsadas y dañadas, fisuras, hundimientos y roturas de sistemas de drenaje y desvíos de aguas. Los



Figura 2 Representación Sismo 2010

tráficos se cortaron y se tuvo que desviar a los vehículos los primeros días.

Algunos de los daños fueron los siguientes:



Figura 4 Enlace Retiro Daño Terraplenes de acceso



Figura 3 Sector Copihue: Grave daño por colapso tablero poniente PS FFCC y terraplén de acceso norte



Figura 5 Enlace Villaseca: Colapso por licuefacción de terraplén poniente.



Observaciones sobre tráfico total en Ruta del Maule afectado por incidencias externas




Gráfico 1 Vehículos por año. Febrero, 2008-2012

Se observa en el gráfico que en el mes de febrero los tráficos disminuyeron en un 2% con respecto al mismo mes del año anterior, ya que, el terremoto afectó el último fin de semana de este mes.




Gráfico 2 Vehículos por año. Marzo, 2008-2012

El mes de marzo fue donde se presentó la mayor disminución, de un 98% con respecto al mismo mes del año anterior. Si el terremoto no hubiera afectado a Ruta del Maule con la intensidad que lo hizo, probablemente los tráficos hubiesen mantenido una tendencia de crecimiento positiva de alrededor de un 8% en el año 2010 y de 7% para el año 2011.

En el mes de abril se logra normalizar los tráficos, luego de que se hicieran las reparaciones correspondientes a los daños provocados por el terremoto, observando una disminución de solo un 4% en relación con el mismo mes del año anterior.




Gráfico 3 Vehículos por año. Abril, 2008-2012

Al cabo de 32 días posteriores al terremoto, el 31 de marzo, se reiniciaron las operaciones en el peaje Río Claro, y el 8 de abril en Retiro; sin embargo, el peaje de Parral correspondiente a laterales demoró mucho más reiniciando operaciones el 16 de agosto.

1.3.2. Incendios forestales 2017 y su efecto en el tráfico de Ruta del Maule

En el año 2017, en los meses de enero, febrero y marzo, se produjo una serie de incendios forestales en el sur de Chile, que afectó a las Regiones del Maule y Biobío con mayor intensidad. La propagación del fuego se vio potenciada por las condiciones climáticas, con temperaturas superiores a los 30°C, una baja humedad cercana al 30% y vientos de una velocidad cercana a 30 kilómetros por hora; hubo una ola de calor a niveles históricos, temperaturas registradas como las más altas desde 1912 (entre 37,3°C en Curicó y 44,9°C en Quillón).

En la Región del Maule, se considera que el incendio fue el más grande de la historia de Chile, con 183.946 hectáreas consumidas.

Todo esto afectó los tráficos de Ruta del Maule, precisamente en el mes de febrero y marzo, cuando las llamas de los incendios bordeaban la carretera, por los que los vehículos dejaron de pasar.

Desde el año 2014 al 2016, en los meses de febrero, se observa una tendencia positiva en el aumento de tráficos, comparando el mismo mes de cada año, y precisamente en el mes de febrero de 2017, hubo una disminución de un 2% en los tráficos totales, en comparación a febrero de 2016.




Gráfico 4 Vehículos por año. Febrero, 2014-2018

En el mes de marzo de 2017, en comparación al mismo mes del 2016, también se observa una disminución en los tráficos, alterando la tendencia que venía positiva de los años anteriores, con un crecimiento de solo un 1%, en relación con el año anterior.




Gráfico 5 Vehículos por año. Marzo, 2014-2018

A fines de marzo de 2017, los incendios pudieron ser controlados gracias a distintos tipos de ayuda y colaboración que se recibió, principalmente extranjeros, cerca de 17 países participaron, lo que conllevó a extinguir los incendios y normalizar los tráficos en abril del 2017.

1.4. Antecedentes del Estudio

Intentos por producir una teoría matemática para la explicación del flujo de tráfico datan de los años 90, con Frank Knight (1920) produciendo un análisis de equilibrio de tráfico la cuál fue afinada a los primeros y segundos principios de equilibrio de Wardrop en 1952.

Desarrollar una descripción macroscópica del flujo de tráfico no es una idea nueva. Thomson (1967), encontró relación entre la velocidad promedio y el flujo de tráfico utilizando datos obtenidos de las calles centrales de Londres. Wardrop (1968) determinó que esta relación entre velocidad promedio y flujo decrecía monótonamente, y Zahavi (1972) enriqueció la teoría de Wardrop analizando data real de tráfico recolectada de un gran número de ciudades y luego agrupada, saliéndose del sesgo del número de datos, obtenidos de varias ciudades de Estados Unidos.

(Hoogendoorn and Knoop) categoriza los modelos de flujo de tráfico utilizando varias dimensiones (determinísticas o estocásticas, continuas o discretas, analíticas o por simulaciones).

La mayoría de los esfuerzos en el desarrollo de metodologías es enfocada en identificar las características del flujo de tráfico como series de tiempo para producir proyecciones econométricas. (Vlahogianni 2014) crea una lista de los estudios enfocados a la predicción utilizando el enfoque Macroscópico de series de tiempo con dimensiones discretas y determinísticas.

(Fildes 2015) Plantea el problema de reglas de selección para la proyección de diversas series de tiempo en seleccionar el método de proyección adecuados para un largo número de series de tiempo, comparando circunstancias en las que selección individual de modelos es beneficiosa y cuando este acercamiento debe ser preferido a la selección agregada o combinación. La superioridad de cada proceso de selección es analizada en términos de características de los datos, existencias de métodos dominantes y estabilidad en el desempeño de la comparación de métodos de proyección.

En orden de analizar la eficiencia de la selección de modelos reglas simples son propuestas basadas en pruebas de modelos ajustados dentro de la muestra de datos y los mejores desempeños de proyección en diferentes horizontes.

Finalmente (Petropoulos) compara el desempeño de juicios y reglas de selección de modelos contra algoritmos basados en criterios de la información. Utilizando datos en sus estudios más de 700 participantes, prueba que al decidir la existencia de componentes estructurales en series de tiempo (tendencia y estacionalidad), simples combinaciones de juicios de selección basados en reglas y métodos estadísticos combinados superan el desempeño de ambos criterios por si solos.

Lo que compone el estudio de tráfico realizado en esta memoria.

1.5. Problema de investigación

Uno de los resultados del equilibrio entre las necesidades, deseos, ubicación, actividades y factores del transporte entre las personas particulares y transportistas es un cierto volumen de tráfico vehicular.

El flujo de tráfico en su medición puede ser pequeño (carretera libre), congestionado o incierto. En los últimos dos casos esto puede deberse a baja o alta resistencia al tráfico, concepto fundamental (Hoogendoorn and Knoop), pues este también depende de barreras, de forma directa a través del precio del peaje como lo es en una carretera concesionada, lo cual describe el caso en estudio en esta memoria, reparaciones, estado de la carretera, el tamaño de las pistas o hasta el mismo tráfico (congestión). Consecuentemente altas resistencias al transporte implican repercusiones negativas en los volúmenes de tráfico. Factores como el clima, políticas de expansión de carreteras y tecnologías de información (como sistemas de navegación) pueden influir en las características del flujo a través del comportamiento de los conductores.

Existen dos perspectivas del análisis del tráfico, la visión Microscópica que intenta reflejar y modelar el flujo del tráfico mediante el comportamiento de los conductores individuales interactuando con los vehículos en su entorno, combinación entre características del conductor y el vehículo, experiencia al volante, edad, genero, altura, tipo de vehículo, etc. E incorporan dichas variables al modelamiento. O este modelamiento puede ser visto desde la visión Macroscópica, que considera el estado promedio del tráfico, con variables como la velocidad, variabilidad de la velocidad y densidad de flujo (número de vehículos que se encuentran presente en una carretera por unidad de distancia) (Hoogendoorn and Knoop).

El objetivo de este estudio es el modelamiento y proyección del flujo vehicular en una carretera concesionada en niveles, o sea número de vehículos, se busca proyectar flujos anuales y mensuales para los años 2018, 2019 y 2020, en 3 rutas de peaje ubicadas en la Ruta del Maule. Se cuenta con 5 años de datos diarios y 7 tipos de vehículos, al disponer de este tipo de datos el enfoque dado a este estudio es el modelamiento Macroscópico, con modelamiento estadístico por series de tiempo, utilizando diversos modelos econométricos, tomando en cuenta factores externos que afecten el flujo de tráfico cómo lo fue el terremoto

acontecido en el año 2010, los incendios afectando la región el año 2017 y la estabilización de las series de tiempo por carreteras recién inauguradas. Se busca que las proyecciones tengan el mínimo de error, ajustado el mejor modelo que represente mejor los fenómenos estudiados.

1.6. Objetivos

1.6.1. Objetivo general

Pronosticar el flujo vehicular en la carretera de Ruta del Maule para los 2018, 2018 y 2020 mediante modelos econométricos.

1.6.2. Objetivos específicos

1. Identificar y analizar fenómenos influyentes en el flujo de tráfico y sus variables explicativas.
2. Analizar mediante series de tiempo la data dispuesta para el estudio.
3. Entrenar y validar los modelos propuestos.
4. Analizar y comparar los modelos obtenidos mediante indicadores econométricos.
5. Obtener el mejor modelo dentro de los propuestos que describa el fenómeno del tráfico.
6. Realizar proyecciones del flujo vehicular con el menor error posible.

2. MARCO TEÓRICO

2.2. Enfoques en la predicción del tráfico

Existen dos perspectivas del análisis del tráfico, la visión Microscópica que intenta reflejar y modelar el flujo del tráfico mediante el comportamiento de los conductores individuales interactuando con los vehículos en su entorno, combinación entre características del conductor y el vehículo, experiencia al volante, edad, género, altura, tipo de vehículo, etc. E incorporan dichas variables al modelamiento. O este modelamiento puede ser visto desde la visión Macroscópica, que considera el estado promedio del tráfico, con variables como la velocidad, variabilidad de la velocidad y densidad de flujo (número de vehículos que se encuentran presente en una carretera por unidad de distancia) (Hoogendoorn and Knoop).

Varias alternativas a los modelos clásicos para producir proyecciones han sido expuestas tales como redes neuronales, regresiones no paramétricas, filtro de Kalman, K-vecino más cercano, modelos de regresión con vector de soporte, algoritmos tabú y otros métodos de aprendizaje de máquinas. Sin embargo, los métodos de series de tiempo extrapolativos siguen vigentes y bastante atractivos. Esto debido a su éxito histórico empírico en la práctica (Gardner, 2006), así como su desempeño comparado con métodos más complejos (Makridakis and Hibon, 2000; Armstrong, 2006; Crone et al., 2011). Más aun, los métodos basados en series de tiempo son altamente intuitivos, lo cual los hace fáciles de especificar e implementar, esto realza su aceptación por los usuarios (Dietvorst et al., 2015; Alvarado-Valencia et al., 2017). Métodos complejos, así como algoritmos de aprendizaje de máquinas generalmente aparecen como cajas negras, y proveen limitada hasta nula percepción en como las proyecciones se encuentran compuestas y que elementos presentes en la data son importantes, dificultando el análisis y su interpretación. Estos atributos de las proyecciones son a menudo críticas para su uso, entendimiento de los fenómenos involucrados y su uso final por parte de los usuarios (Sagaert et al., 2018).

2.3. Técnicas Estadísticas

2.3.1. *Procesos Estocásticos*

Un proceso estocástico es un proceso aleatorio el cual usualmente es definido como el resultante de un conjunto de variables aleatorias, clasificadas en tipos de datos transversales u horizontales, así sea periodos de tiempo o algún parámetro horizontal como longitudes, etc.

Estos son utilizados en modelos matemáticos o fenómenos que se caracterizan por su comportamiento aleatorio. Destacan sus aplicaciones en ciencias como la biología, química, ecología, neurociencia, física, tecnología e ingeniería. Como procesamiento de imágenes, teorías de la información y telecomunicaciones.

En el caso de este estudio, la aplicación en series de tiempo para la predicción de tráfico vehicular.

J. Michael Steele (2001). Stochastic Calculus and Financial Applications

2.3.2. *Series de Tiempo*

Las series de tiempo comúnmente se definen como puntos de datos tomados de forma secuencial sucesivamente en intervalos de tiempo discretos iguales. Las series de tiempo poseen naturalmente un ordenamiento temporal o en su defecto los datos pueden ser ordenados cronológicamente. Esto diferencia el análisis de series de tiempo de estudios de datos transversales, casos en los cuales no existe un orden natural en las observaciones tomadas.

Ejemplos de series de tiempo son la medición de alturas de olas a nivel del mar, mediciones de trayectorias solares durante el tiempo y el valor de cierre diario de acciones en la bolsa, etc.

El análisis de datos en series de tiempo busca extraer significativa información estadística, características de los datos y hasta proyecciones futuras.

Como establecen (Lütkepohl y Krätzig 2004). El estudio de estas incluye desarrollo de metodologías recientes, tales como raíz unitaria y análisis de cointegración que juegan un

papel central en la materia. Otros temas incluyen vectores estructurales autorregresivos, heterocedasticidad condicional, y modelos de series de tiempo no lineales y no paramétricas. Un componente crucial en el trabajo empírico es el uso de softwares estadísticos, en el caso de lo desarrollado en este estudio el software estadístico R es utilizado como herramienta para generar el análisis.

Un modelo estocástico de series de time reflejará generalmente el hecho que las observaciones más contiguas, estarán más cercanamente relacionadas que las observaciones tomadas en intervalos lejanos.

2.3.2.1. Análisis de Regresión

El análisis de regresión es un grupo de procesos estadísticos dedicados a estimar relaciones entre variables las cuales incluyen diversas técnicas de modelamiento y de análisis de múltiples variables. El foco recae en establecer y analizar la relación entre una variable dependiente y una o más variables independientes (mejor llamadas predictoras).

Los métodos de análisis en la práctica dependen de la forma en la cual el proceso de generación de datos es realizado, realizar un contraste con la realidad, observar eventos que afecten el comportamiento regular de una serie de tiempo, sucesos, cambios y el punto de vista desde el cual se busca proyectar.

Ya que la verdadera forma en la cual se generan los datos o la razón de comportamiento real de los fenómenos es generalmente desconocida. En el caso de este trabajo las razones que impulsan o explican el flujo vehicular, los análisis de regresión dependen de realizar supuestos acerca de los procesos que busquen explicar estos comportamientos, cómo establecen (Armstrong, J. Scott (2012)) en su estudio, éstos supuestos pueden ser puestos a prueba si existen datos suficientes disponibles.

Cabe destacar que la correlación de un análisis de regresión no necesariamente implica causalidad, lo que se denomina correlación espúrea. Por lo que hay ser rigurosos en establecer causalidad lógica y ser cuidadoso al momento de proyectar basado en supuestos.

El modelo de regresión múltiple es la base de este tipo de análisis y es definida en términos de un número finito de parámetros conocidos los cuales son estimados desde la data utilizada.

De forma matemática existen p variables independientes, asociadas a parámetros desconocidos denominados β_p los cuales son representados en un escalar o vector.

Sea $i \in I, I \subset \mathbb{N}_0$.

Sea X_{ip} el grupo de p variables independientes con I datos.

Sea Y_i la variable dependiente explicada con I datos.

$$Y_i = \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \varepsilon_i$$

Donde X_{ip} representa el dato i -ésimo de la p -ésima variable independiente. En el caso de que la primera variable independiente tome el valor de 1 para todo i , $X_{i1} = 1$, entonces β_1 representará el intercepto. En este trabajo contemplaremos la regresión múltiple con intercepto pues reduce el sesgo de los modelos.

Donde,

$$\varepsilon_i = Y_i - \hat{\beta}_1 X_{i1} - \dots - \hat{\beta}_p X_{ip}$$

Representan el término del error o residuales.

Un método de estimación para los valores de β_p , el cual será utilizado, es basado en minimizar la varianza, a través de minimizar la suma de los residuales al cuadrado, mínimos cuadrados ordinarios.

Resolviendo las ecuaciones normales,

$$\sum_{i=1}^I \sum_{j=1}^J X_{ij} X_{ip} \hat{\beta}_p = \sum_{i=1}^I X_{ip} Y_i, p = 1 \dots P, j, i, p \in \mathbb{N}$$

Minimizando,

$$SSR = \sum_{i=1}^I \varepsilon_i^2$$

Una vez que un modelo de regresión ha sido construido es de importancia confirmar como parte del análisis de regresión una serie de condiciones que establecen cuan “bueno” es el modelo, entre ellos.

La bondad de ajuste del modelo, comunmente es utilizado *R – cuadrado ajustado* debido a que con este estimador es posible comparar modelos con número distinto de variables independientes.

La significancia estadística de los parámetros estimados, como análisis de dócima global a través del estadístico prueba *F*, seguido de análisis individual de significancia de los parámetros individuales, a través de una prueba de t-student.

Además de esto, existen tres supuestos que deben cumplirse para llevar a cabo una regresión lineal, estos son:

La varianza debe ser homocedástica, esto quiere decir que la distribución de la varianza debe ser constante. Una forma de saltar esta condición implica agregar a los modelos de regresión el error como variable llevando a los modelos de tipo GARCH y ARCH, los cuales no serán necesarios en este trabajo, pero cabe destacar que existen en la literatura.

Los errores se distribuyen de forma normal con media 0, no existe correlación entre ellos.

No existe multicolinealidad entre las variables explicativas, esto quiere decir que no se encuentra presencia de correlación fuerte entre las variables explicativas o combinación lineal de ellas.

Todo lo anterior es probado en este estudio de forma gráfica con ayuda del software estadístico R.

Estas condiciones son suficientes para que el estimador de mínimos cuadrados ordinarios posea las propiedades deseadas, insesgado, consistente y eficiente. En la clase de

estimadores lineales insesgados. Según (Armstrong, J. Scott (2012)), el trabajo con datos reales rara vez satisface estos supuestos.

2.3.2.2. Estacionariedad

Una serie de tiempo estacionaria es aquella cuyas propiedades, media y varianza, no dependen del tiempo en el cual la series observada.

Un proceso estocástico de serie de tiempo es llamado estacionario si su primer y segundo momento, son invariantes respecto al tiempo. En otras palabras, Y_t representando la serie, es estacionario si se cumple que:

1. $E(Y_t) = \mu_y \quad \forall t \in T$
2. $E[(Y_t - \mu_y)(Y_{t-h} - \mu_y)] = Y_h \quad \forall t \in T \quad \wedge \quad h \in Z_0 / (t - h) \in T$

La primera condición establece que todos los miembros de un proceso estocástico poseen la misma media constante. Por lo cual, una serie de tiempo generada por un proceso estocástico debe fluctuar en torno a una media y no posee tendencia. La segunda condición asegura que la varianza total también sea invariable respecto al tiempo, ya que, para $h = 0$, la varianza,

$$\sigma_y^2 = E[Y_t - \mu_y]^2 = Y_0, \text{ es independiente de } t, \text{ más aún las covarianzas,}$$

$E[(Y_t - \mu_y)(Y_{t-h} - \mu_y)] = Y_h$, no dependen de t , solo de la distancia en tiempo h de los dos miembros del proceso estacionario. HELMUT LUTKEPOHL y MARKUS KRATZIG (2005)

Existen dos tipos de proceso estacionario, fuerte y débil, el anterior descrito responde al fuerte, sin embargo, hay casos en los que se acepta el segundo momento constante y un primer momento con tendencia, fluctuando respecto a la varianza, esto es considerado como proceso estacionario débil.

2.3.2.3. Ruido Blanco

En procesos estocásticos de series de tiempo, en el caso de tiempo discretos, el ruido blanco es una señal discreta resultado de una secuencia de variables aleatorias no relacionadas serialmente, con media 0 y varianza finita.

Dependiendo del contexto, puede ser requerido que las muestras tengan idéntica distribución de probabilidad en otras palabras que sean independientes y variables aleatorias idénticamente distribuidas.

Sea ε_t un proceso con las características descritas anteriormente, la independencia del tiempo implica que ε_t no está correlacionada, teniendo una función de autocovarianza de la siguiente forma:

$$\gamma_k = E[\varepsilon_t \varepsilon_{t+k}] = \begin{cases} \sigma_\varepsilon^2, & k = 0 \\ 0, & k \neq 0 \end{cases}$$

En el caso de que su comportamiento sea descrito como una distribución normal con media 0, se dice que el proceso se encuentra representado por un proceso de Ruido Blanco Gaussiano.

$$\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$$

Si la correlación entre los valores del ruido blanco es distinta de 0, entonces los estimadores del modelo analizado siguen siendo insesgados, sin embargo, los estimadores de incerteza (tales como intervalos de confianza de alguna proyección) estarán sesgados (no serán precisos en promedio). Esto también es verdad si es que se prueba que el ruido blanco es heterocedástico, lo que significa que se distribuye con diferente varianza para distintos puntos de datos.

2.3.2.4. Caminata Aleatoria

Es un proceso estocástico que describe un camino consistente de una sucesión secuencial de pasos aleatorios dentro de un espacio matemático determinado.

Matemáticamente según (Tsay 2005) una serie de tiempo sea Y_t , se define como caminata aleatoria si satisface que:

$$Y_t = Y_{t-1} + a_t$$

Donde Y_0 representa el valor de partida del proceso y a_t error aleatorio con propiedades bien restringidas llamado ruido blanco (definido en el punto 2.3.2.3). Las caminatas aleatorias se caracterizan por tener largos períodos de tendencia al alza o a la baja y cambios repentinos e impredecibles en su dirección, dada su característica de aleatoriedad. Los modelos de caminata aleatoria son ampliamente utilizados para data no estacionaria y es el modelo precursor de los métodos ingenuos.

Definido con deriva:

$$Y_t - Y_{t-1} = c + e_t$$

Donde c representa el promedio entre observaciones consecutivas. Este es el modelo detrás del método con deriva para la creación de modelos.

2.3.2.5. Raíz Unitaria

Una raíz unitaria, es una característica de algunos procesos estocásticos, que puede causar problemas en inferencia estadística.

Para comprobar si una serie de tiempo Y_t sigue un comportamiento de caminata aleatoria o caminata aleatoria con deriva son empleados los modelos:

$$Y_t = \phi_t Y_{t-1} + e_t \quad (2.53)$$

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + e_t \quad (2.54)$$

Donde e_t denota el término del error, y considera la hipótesis nula $H_0: \phi_1 = 1$, de ocurrir esto queda un modelo autorregresivo, por lo cual, se decide que la caminata aleatoria tiene raíz unitaria. En el caso contrario, contra la hipótesis alternativa $H_a: |\phi_1| < 1$, se asevera que es una serie estacionaria (Tsay, 2005).

Este es un buen conocido problema de prueba de raíz unitaria, Dickey and Fuller (1979).

Cabe destacar que es posible para una serie de tiempo, ser no estacionaria, y no tener raíz unitaria, pero ser estacionaria con tendencia, en las series de tiempo analizadas en este estudio, se da el caso de varias estacionarias con tendencia. En ambos casos, de raíz unitaria o procesos de tendencia estacionaria, es posible para la media crecer o decrecer en el tiempo; sin embargo, en presencia de un shock, los procesos con tendencia estacionaria se revierten a la media, convergerán de nuevo hacia la media con su tasa de crecimiento respectiva, lo que conlleva a que son menos propensos en presencia de shocks atípicos, por el contrario, los procesos con raíz unitaria absorben el impacto permanente en su media.

Una prueba estadística conveniente es el t ratio, se basa en el estimador de mínimos cuadrados para estimar ϕ_1 , bajo la hipótesis nula $H_0: \phi_1 = 1$, de ocurrir esto queda un modelo autorregresivo, por lo cual, la caminata aleatoria posee raíz unitaria. En el caso contrario, contra la hipótesis alternativa $H_a: |\phi_1| < 1$, se asevera que es una serie estacionaria (Tsay, 2005). Es determinado con la siguiente expresión:

$$\hat{\phi}_1 = \frac{\sum_{t=1}^T Y_{t-1} * Y_t}{\sum_{t=1}^T Y_{t-1}^2}, \sigma_e^2 = \frac{\sum_{t=1}^T (Y_{t-1} - \phi_1 * Y_{t-1})^2}{T - 1},$$

Donde $Y_0 = 0$ y T representa el tamaño de la muestra. Se define:

$$DF = t - ratio = \frac{\hat{\phi}_1 - 1}{std(\hat{\phi}_1)} = \frac{\sum_{t=1}^T Y_{t-1} * e_t}{\sigma_e \sqrt{\sum_{t=1}^T Y_{t-1}^2}}$$

Que es comúnmente referido como prueba de Dickey-Fuller.

2.3.2.6. Procesos Integrados I(d)

Los procesos integrados son procesos en los cuales se puede remover la componente tendencia de la serie de tiempo analizada, utilizando primeras diferencias, tanto sea estocástico como determinístico o ambos.

En la literatura, la transformación ha sido usada con éxito para varias series de tiempo económicas, tanto así que la terminología terminó siendo aceptada. (Lütkepohl y Krätzig, 2004).

Un proceso estocástico se dice integrado de orden d ($I(d)$) si es necesario aplicar las primeras diferencias d veces para convertir al proceso en uno estacionario.

Un proceso que puede hacerse estacionario realizando primeras diferencias, puede llamarse integrado de tipo $I(1)$. Siendo Y_t , la serie de tiempo analizada, si Y_t es un proceso integrado de este tipo se denota ($Y_t \sim I(1)$), quiere decir que Y_t no es un proceso estacionario, pero su primera diferencia ΔY_t , si lo es. Una serie de tiempo de ser estacionaria sin necesidad de diferencias es denotada un proceso $I(0)$.

Se describe como procesos integrados de orden d , $I(d)$, a la siguiente definición:

Con operador L de rezago ($LX_t = X_{t-1}$, $L^2X_t = X_{t-2}$).

$$\Delta^d X_t = (1 - L)^d X_t$$

2.3.2.7. Estacionalidad

Como (Tsay 2005) define, la estacionalidad es la presencia de variaciones que ocurren en intervalos regulares específicos y se repiten en menos de un año, tales como semanalmente, mensualmente, o cuatrimestralmente. La estacionalidad puede ser causada por varios factores, tales como el clima, vacaciones, feriados, y consiste en sucesos periódicos, repetitivos y generalmente regulares y predecibles en series de tiempo. Estas fluctuaciones son generadas por condiciones económicas y a veces relacionadas con ciclos de negocios, tales como la venta de helados en verano o el alza en el nivel de compras a fin de mes.

En series de tiempo la estacionalidad puede ser fácilmente identificada de forma gráfica con las funciones de ACF y PACF, definidas más abajo en este estudio. La siguiente imagen muestra un claro patrón estacional identificado por la función ACF.




Gráfico 6 Auto Correlación vs rezago

El procedimiento de remover la estacionalidad de una serie de tiempo es referido cómo ajuste estacional.

2.3.3. Pruebas Estadísticas

2.3.3.1. Función de autocorrelación (ACF)

La función de autocorrelación mide la correlación lineal entre dos variables separadas por k períodos, considera la dependencia creada por los rezagos intermedios existentes entre ambos periodos.

La correlación entre dos variables es expresada de la siguiente forma:

Sean X, Y , variables aleatorias.

$$\rho_{x,y} = \frac{COV(X,Y)}{\sqrt{Var(X)Var(Y)}}$$

Donde $\rho_{x,y}$ es el factor de autocorrelación lineal de Pearson.

A modo de medir autocorrelación, se calcula este coeficiente con la variable estudiada y su rezago k , quedando el factor de Pearson función de $Y_t, Y_{t-k}, \rho_{y_t, y_{t-k}}$.

Para una serie estacionaria débil se cumple que la $Var(Y_t) = Var(Y_{t-k})$.

Para que una serie no sea estacionaria, se cumple que:

$$\rho_k = 0 \forall k > 0$$

Al análisis gráfico para cada rezago se le llama función de autocorrelación.

2.3.3.2. Función de autocorrelación parcial (PACF)

La PACF de una serie de tiempo es una función de ACF y es utilizada para encontrar el orden o número de rezagos e importancia de estos dependiendo de la significancia, de un modelo autorregresivo. Una efectiva forma de representar la PACF es considerar los siguientes modelos autorregresivos en orden:

Siendo Y_t la serie de tiempo estudiada y k su rezago,

$$Y_t = \phi_{0,1} + \phi_{1,1}Y_{t-1} + e_{1,t} ,$$

$$Y_t = \phi_{0,2} + \phi_{1,2}Y_{t-1} + \phi_{2,2}Y_{t-2} + e_{2,t} ,$$

$$Y_t = \phi_{0,3} + \phi_{1,3}Y_{t-1} + \phi_{2,3}Y_{t-2} + \phi_{3,3}Y_{t-3} + e_{3,t} ,$$

$$Y_t = \phi_{0,4} + \phi_{1,4}Y_{t-1} + \phi_{2,4}Y_{t-2} + \phi_{3,4}Y_{t-3} + \phi_{4,4}Y_{t-4} + e_{4,t} ,$$

Etc.

Donde $\phi_{0,k}$, $\phi_{i,k}$ y $\{e_{k,t}\}$, son respectivamente, el término constante, el coeficiente de Y_{t-i} y el término del error de un modelo $AR(j)$. Estos modelos se encuentran de la forma de regresión lineal múltiple y son estimados con el método de mínimos cuadrados ordinarios. Se encuentran ordenados en orden secuencial a modo de utilizar la prueba global F.

Esto es utilizado para poder cuantificar la correlación de variables aleatorias sin absorber el componente de rezagos intermedios cómo están presentes en la función ACF. De forma gráfica generalmente se entregan los valores de la función para posterior análisis. (Tsay 2005).

2.3.3.3. Test de Ljung-Box

La prueba de Ljung Box busca la presencia de autocorrelación lineal con el estimador $\hat{\rho}_k$ en la data de una serie de tiempo, de forma global con el rezago k , para un número total

de rezagos h , donde n representa el tamaño de la muestra y se compara con una distribución χ^2 -cuadrado (h), para un nivel de significancia α , de forma matemática:

$$Q = n(n+2) \sum_{k=1}^h \frac{\hat{\rho}_k^2}{n-k}$$

Donde la región crítica para el rechazo de la hipótesis es representada por,

$$Q > \chi^2_{1-\alpha, h}$$

H_0 : La data se encuentra independientemente distribuida.

H_a : La data exhibe un comportamiento de correlación serial.

(Ljung, G. M. & Box, G. E. P. (1978)). On a measure of lack of fit in time-series models, *Biometrika* 65: 297–303.

Aplicaciones financieras generalmente requieren probar conjuntamente que las autocorrelaciones de Y_t sean cero.

2.3.3.4. Test Dickey-Fuller Aumentada

Para probar estadísticamente la estacionariedad de un proceso estocástico utilizando raíz unitaria, es utilizada la prueba de Augmented Dickey-Fuller (1979). Esta a diferencia de la prueba Dickey-Fuller es aplicada sobre el modelo, toma de forma global las posibilidades de raíz unitaria con deriva, sin deriva y tendencia determinística, de forma matemática:

Siendo Y_t , la serie de tiempo estudiada.

H_0 : $\phi = 0$, posee raíz unitaria.

H_1 : $\phi < 0$, es un proceso estacionario.

$$\Delta Y_t = \phi Y_{t-1} + \sum_{j=1}^{p-1} a_{j+1} \Delta Y_{t-j} + \mu_t$$

El coeficiente ϕ , es estimado mediante mínimos cuadrados ordinarios.

2.3.4. Tratamiento de Estacionalidad

El análisis de series de tiempo estacionales tiene una amplia historia. En algunas aplicaciones, la estacionalidad es de importancia secundaria para las proyecciones o análisis de los datos y esta es removida de la data, resultando en series de tiempo ajustadas estacionalmente, lo cual posteriormente es utilizado para realizar inferencia sin la presencia de la variabilidad entregada por esta. Cómo en el caso del estudio actual de tráfico.

La data graficada contra por patrones individuales “Estaciones” en las cuales es observada (con ayuda de la función ACF). Un gráfico en el tiempo excepto que la data de cada temporada se encuentra superpuesta, habilita al patrón estacional ser visto más claramente y también permite que cualquier cambio en el patrón estacional (puede que cambie anualmente, como en el caso de este estudio cambia levemente) sea identificado más fácilmente. (Hyndman and Athanasopoulos (2012)).

En este estudio de tráfico una “Estación” es representada por un mes, con patrones recurrentes y ligeramente cambiantes anualmente.

Posteriormente a ser identificada en los datos (mensual en este caso). Luego se procede a promediar los datos por grupo (todos los eneros, febreros, etc.), se define el promedio de cada grupo como (w_i) y estos resultados son promediados resultando en un gran promedio (W).

Se define el índice estacional total para cada mes como:

$$S_i = \frac{w_i}{W}$$

En series de tiempo multiplicativas, los componentes son multiplicados juntos (tendencia, estacionalidad y factor aleatorio) conformando la serie de tiempo. En el caso de tener tendencia creciente, la amplitud de la actividad estacional incrementa. Todo cambio es más exagerado, esto es apreciable de forma gráfica, analizando los residuales o el comportamiento de la serie.

$$Y_t = T_t * S_t * \mu_t$$

En series de tiempo de tipo aditivas, los componentes son sumados juntos para componer la serie de tiempo. En caso de tener tendencia incremental, los cambios en la serie no son tan abruptos y en promedio alcanzarán la misma forma (cambios relativamente bajos), estas series usualmente son descompuestas por series Fourier o puede ser identificado de forma gráfica.

$$Y_t = T_t + S_t + \mu_t$$

Siendo Y_t la serie de tiempo estudiada, S_t representando el componente estacional, T_t el componente tendencia y μ_t el componente aleatorio de la serie o ruido blanco.

Si la estacionalidad tiende a ser constante en el tiempo, el modelo aditivo es sugerido. Sin embargo, si la estacionalidad tiende a incrementar con el tiempo estamos en presencia de un modelo multiplicativo (Hyndman and Athanasopoulos (2012)).

Las diferentes descomposiciones producen diferentes distribuciones de residuales. Se necesita del análisis gráfico de estos a modo de identificar cuál descomposición representa mejor a la serie de tiempo.

2.3.5. Transformación de Poder de Cox-Box

Las transformaciones de poder son una familia de funciones que son aplicadas para crear una transformación monótonica de los datos utilizando funciones de poder, como aplicar logaritmos, raíces cuadradas, etc. A un grupo de datos. Generalmente son aplicadas a las series de tiempo y van enfocadas a estabilizar la varianza y hacer la distribución de la data más parecida a una distribución normal, lo que mejora la validez de las mediciones de asociación, cómo el índice de correlación de Pearson entre variables y con otros procedimientos de estabilización cómo primeras diferencias.

El propósito de estos ajustes y transformaciones es simplificar patrones en datos históricos removiendo fuentes de variación conocidas o haciendo los patrones más consistentes a lo largo de la muestra total de datos. Patrones simples generalmente conllevan a proyecciones más robustas.

Una familia de transformaciones que incluye ambos, logaritmos y transformadas de poder o potencias es la familia de las transformaciones de Cox-Box, según (Box, George E. P.; Cox, D. R. (1964)) dependen del parámetro λ y son definidas como:

$$w_t = \begin{cases} \ln(Y_t), & \lambda = 0; \\ \frac{Y_t^\lambda - 1}{\lambda}, & \lambda \neq 0; \end{cases}$$

Esto es aplicado a los datos, se realizan las proyecciones y después se debe reversar el proceso de transformación para obtener las proyecciones en la escala original. El proceso inverso de Cox-Box es dado por:

$$Y_t = \begin{cases} \exp(w_t), & \lambda = 0 \\ (\lambda w_t + 1)^{1/\lambda}, & \lambda \neq 0 \end{cases}$$

Siendo Y_t la serie de tiempo estudiada y w_t el resultado de la transformación, en el caso de algunos datos $Y_t \leq 0$ no es posible realizar transformaciones de poder a menos de agregar una constante a todo el grupo de datos la cual puede ser sustraída posteriormente a la proyección.

Cabe destacar que en el caso de estudio esta transformada es representativa, ya que, no promediamos proyecciones con distintas magnitudes, en el caso de ocurrir esto se necesita un ajuste al sesgo puesto que ya no se basa en la mediana sino en la media.

2.3.6. Leverage

El Leverage es una medida de cuán lejos se encuentran los valores una observación de la variable independiente de los otros datos.

$$h_{ii} = \frac{d\hat{y}_i}{dy_i}$$

Sea h_{ii} el coeficiente de Leverage para el dato i – ésimo, para la serie de tiempo Y_i y su valor proyectado $\hat{Y}_i$.

$$0 \leq h_{ii} \leq 1$$

Las observaciones con altos valores de Leverage son aquellas con valores altos extremos (aportan bastante error) lejos de valores cercanos en el modelo de regresión.

2.3.7. Distancia de Cook

La Distancia de Cook es un estimador utilizado comúnmente para estimar la influencia de observaciones en un modelo de regresión, cuando es utilizada la técnica de análisis de regresión por mínimos cuadrados ordinarios.

Sea h_{ii} el coeficiente de Leverage para el dato i –ésimo, para la serie de tiempo Y_i y p variables, n observaciones.

$$h_{ii} = \frac{d\hat{y}_i}{dy_i}$$

Se define el estimador Distancia de Cook

$$D_i = \frac{\varepsilon_i^2}{s^2 p} \left[\frac{h_i}{(1 - h_i)^2} \right]$$

$$s^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

Indica datos influyentes que particularmente vale la pena analizar más profundamente su validez.

2.3.8. Modelos Lineales Estacionarios

2.3.8.1. Suavizamiento Exponencial Doble Holt Winter

El suavizamiento exponencial doble surge dado que el suavizamiento exponencial simple no tiene buen rendimiento en presencia de tendencia en la data, lo cual genera inconvenientes al momento de proyectar. La idea básica de eliminar este problema es introducir un término que capture la implicancia de esta tendencia, este componente de pendiente es actualizado en sí mismo a través del suavizamiento exponencial. Holt (1957).

Consiste en dos parámetros α y β (que toman valores entre 0 y 1). Que minimicen el cuadrado medio del error.

Siendo Y_t , una serie de tiempo, donde el pronóstico es representado por:

$$\hat{Y}_{t+h|t} = l_t + hb_t$$

El estimado de constante del modelo lineal en el tiempo t :

$$l_t = \alpha Y_t + (1 - \alpha)(l_{t-1} + b_{t-1})$$

EL estimado de la pendiente del modelo lineal en el tiempo t :

$$b_t = \dot{\beta}(l_t - l_{t-1}) + (1 - \dot{\beta})b_{t-1}$$

Ecuación de observación:

$$Y_t = l_{t-1} + b_{t-1} + e_t$$

Ecuaciones de estado:

$$l_t = l_{t-1} + b_{t-1} + \alpha e_t$$

$$b_t = b_{t-1} + \beta e_t$$

$$\beta = \alpha \dot{\beta}$$

$$e_t = Y_t - (l_{t-1} + b_{t-1}) = Y_t - \hat{Y}_{t|t-1}$$

Es necesario estimar minimizando el error cuadrático medio:

$$\alpha, \beta, l_0, b_0$$

2.3.8.2. Modelo Autorregresivo (AR(p))

Es una forma de modelar un proceso de serie de tiempo Y_t , proceso estocástico en el cual la variable que se desea predecir se plantea como combinación lineal de sus valores pasados (Tsay 2005).

$$Y_t = \phi_0 + \phi_k Y_{t-k} + \varepsilon_t$$

Donde ε_t se asume ruido blanco con media 0 y varianza σ_ε^2 . k representa el rezago autorregresivo con el cual se formula el modelo. De forma general agregando n rezagos, pudiendo no ser sucesivos.

$$Y_t = \phi_0 + \sum_{k=1}^n \phi_k Y_{t-k} + \varepsilon_t$$

2.3.8.3. Modelo de Media Móvil (MA(q))

Este modelo se trata como un modelo AR con ciertas restricciones de parámetro, si es expresable de la forma (2.3.4.2), requiere unicidad donde $|\theta_1| < 1$, para las limitantes de este estudio sólo se definirá de la forma.

$$Y_t = \phi_0 + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}$$

2.3.8.4. Modelo Autorregresivo con Media Móvil (ARMA (p, q))

Generalmente se utiliza para describir procesos estocásticos débiles por su incapacidad de capturar tendencia estocástica o si ésta no se encuentra autocorrelacionada. Está compuesto por la combinación de los dos modelos mencionados anteriormente, la parte autorregresiva AR(p) involucra los rezagos de la variable sobre sus valores pasados y su parte MA(q) adhiere el modelamiento del término del error, cómo combinación lineal de los errores que ocurren rezagados.

$$Y_t = \phi_0 + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \sum_{i=1}^n \phi_k Y_{t-i}$$

Las condiciones en los coeficientes aseguran estacionalidad e invertibilidad.

2.3.8.5. Modelo Autorregresivo Integrado con Media Móvil (ARIMA (p, d, q) (P, D, Q))

Es aplicado en los casos donde la data de una serie de tiempo Y_t presenta evidencia de no ser estacionaria. Es la combinación de los modelos ARMA luego de ser agregado el factor diferenciación I(d), definido previamente a modo de estacionalizar el proceso estocástico. Con notación matemática.

$$\Delta^d Y_t \sim ARMA(p, q)$$

Definiendo el operador de rezago L como.

$$LY_t = Y_{t-1}$$

Se define el modelo ARMA (p' , q) después de operar primeras diferencias.

$$\left(1 - \sum_{i=1}^{p'} \phi_i L^i\right) Y_t = \left(1 + \sum_{i=1}^q \theta_i L^i\right) \varepsilon_t$$

Agregando estacionalidad con factor autorregresivo, media móvil y diferencias estacionales.

$$\phi(L)Y_t = c + \theta(B)\varepsilon_t$$

Donde:

$$\phi(B) = 1 - \phi_1 L - \dots - \phi_p L^p$$

$$\theta(B) = 1 + \theta_1 L + \dots + \theta_q L^q$$

Modelo ARIMA queda expresado ARIMA (p , d , q) (P , D , Q). Incorporando el componente estacional.

$$(1 - \phi_1 L)(1 - \phi_1 L^4)(1 - L)(1 - \theta_1 L^4)Y_t = (1 + \theta_1 L)(1 + \theta_1 L^4)\varepsilon_t$$

2.4. Trabajos Relacionados con proyecciones de tráfico

La proyección del tráfico es una parte integral del proceso de diseño de carreteras, comenzando desde los estudios de factibilidad de inversión, estructuración de deuda óptima a fin de conseguir menores tasas, hasta el desarrollo de planes de trabajo futuros.

En cuanto a la recopilación de datos, tarea fundamental en un estudio de proyección de tráfico (Chrobokdiss) plantea sistemas basados en el conocimiento y la heurística. Son métodos que descansan en el supuesto de que existen condiciones de tráfico similares en días similares. Se propone que si todas las influencias en una cierta fecha son conocidas y si existen mediciones de datos en dichos días con la misma influencia, esta data es utilizada

cómo una aproximación del nuevo día. Analizando datos históricos sistemáticamente, subdividiéndolos en eventos tales como:

- Principio o término de vacaciones escolares.
- Principio o término de fines de semana largos.
- Grandes eventos como ferias, exhibiciones, eventos deportivos.
- Áreas de construcción conocidas.
- Tiempos y periodos cuando mensajes en la ruta indican complicaciones o tomar vías alternativas.

Incluso dividiendo datos diarios de forma horaria:

- Noche (21:00-4:00).
- Periodo de incremento (5:00-7:00).
- Hora punta mañana (8:00-11:00).
- Tarde (12:00-15:00).
- Hora punta tarde (16:00-20:00).

Debido a la no linealidad y estacionalidad del tráfico en carreteras, muchos modelos de proyección avanzados han sido diseñados para predecir el flujo de tráfico.

Recientemente los modelos de Máquinas de Vectores de Soporte (SVR), que son un tipo de regresión lineal con curvas no lineales de separación que asegura la equidistancia entre puntos minimizando el error, representados por funciones Kernel mediante un hiperplano. Han sido exitosamente aplicados con algoritmos de Búsqueda de Tabú (optimización matemática) para predecir tráfico mensual en carreteras en Taiwan. (Hong, Wei-Chiang & Pai, 2016). La búsqueda Tabú es aplicada a la búsqueda de los parámetros del vector de soporte con prohibiciones basadas en soluciones ya encontradas.

Cabe destacar lo probado por (Hastie et al., 1993), que los métodos de regresión lineal son preferidos sobre regresiones de Kernel para datos de distribución irregular.

Otro enfoque para los estudios de tráfico son los modelos ARIMA en los casos donde no existe data suficiente. Para superar este problema existen esquemas de predicción basados en

técnicas de Filtro de Kalman (KFT), lo cual ya fue propuesto y evaluado en bajo requerimiento con datos de entrada limitados. (Kumar 2017).

En la literatura (kamarianakis 2005), también se ha utilizado la visión de no presentar los datos como series de tiempo, sino variables compuestas por tiempo y espacio como son los casos de los modelos STARIMA (modelos de espacio y tiempo autorregresivos integrados de media móvil), metodología enfocada a representar patrones en el flujo de tráfico. Los datos de flujo de tráfico representados en forma de series de tiempo espacio temporales son recolectados en locaciones específicas en intervalos de tiempo constantes.

En el ámbito de inteligencia artificial existen resoluciones a la problemática de flujo de tráfico, uno de los primeros acercamientos en proyecciones de tráfico a través de técnicas de regresión no paramétrica fue propuesta por Davis and Nihan (1991), método k-NN (k vecino más cercano) una visión microscópica de la resolución de los problemas, con variables de flujo de tráfico agregado por minuto y ocupación de líneas.

Florio y Mussone (1996) utilizan el acercamiento de Redes Neuronales para la predicción de tráfico con una visión Macroscópica con datos más complejos de entrada a la red, no sólo número de vehículos, densidad de tráfico y velocidad, sino también porcentaje de vehículos pesados, iluminación diaria (1 oscuridad, 6 luz brillante), visibilidad(s) desde $s=0$ m hasta $s > 520$ m, tres diferentes condiciones climáticas en la ruta (despejado, lluvia, nieve/hielo) y el estado de mensajes en la ruta (ausencia, accidente, congestión, niebla).

En la visión de problema de optimización la determinación del transporte y distribución del viaje de vehículos son determinados bajo un grupo de factores intercorrelacionados. La simulación de la distribución del tráfico es basada en el principio internacional aceptado de “modelo de equilibrio de usuarios” (Frank Knight, 1924). Se basa en el hecho de que los humanos escogen una ruta para minimizar su tiempo de viaje, en el supuesto de que este comportamiento a nivel individual crea un equilibrio en el sistema o red (optimización interna), esto es utilizado para desarrollar ecuaciones de restricción y una función objetivo a optimizar.

Este principio implica que el tiempo utilizado en un viaje depende del tráfico en distintas secciones de la red de carretera (caminos, rutas) y el conductor escoge rutas de viaje

considerando el tiempo utilizado. Esta visión permite tomar en cuenta no solo la estructura de la red de rutas dentro de una carretera y distancias de las rutas, sino también retrasos asociados con la intensidad del flujo de tráfico [Federal Road Agency (Rosavtodor) of the Ministry of Transport of the Russian Federation (2003)]. Finalmente caracterizando la distribución de la demanda de transporte.

(Dombalyan kocherga 2017) plantean en su estudio maximización de la entropía identificando los valores más probables de movilidad de vehículos dentro de restricciones de volumen de llegadas y salidas, considerando los efectos de tiempos de viajes.

2.5. Trabajos relacionados con la elección del mejor método de validación de modelos.

La correcta medición y comparación de modelos de proyección siempre ha sido un tema de estudio, de mejoras continuas, sin respuesta empírica que abarque la solución a todos los tipos de datos y problemas presentes en estos que dificultan su proyección. Debido a lo cual existen bastantes publicaciones en la materia con variedad de enfoques.

A modo de simular de forma precisa “proyecciones del mundo real, en las cuales nos paramos en el presente y predigamos el futuro” (Tashman 2000).

En su búsqueda de mejores pronósticos Makridakis and Winkler (1989) y más adelante Pant y Starbuck (1990), argumentan sobre si existe realmente relación entre la comparación del desempeño de los modelos, “dentro de la muestra” de data contra el desempeño de las proyecciones “fuera de la muestra” de data. Con resultados controversiales argumentando que no existe una relación significativa.

Por el contrario, Billah, King, Snyder, and Koehler (2006) quienes compitiendo en la competencia de proyecciones mundial M3, prueban en la selección de modelos para una data finita dentro de la clase de suavizamiento exponencial, que existe un modelo general eficiente, aplicable a todas las series de tiempo.

Sus resultados para un subgrupo de datos demostraron que los criterios de la información para la selección de modelos se desempeñan mucho mejor que el uso de datos de validación, cómo ejemplo, los utilizados en una validación cruzada.

Las diferencias son pequeñas en la selección de modelos, así llegar a una conclusión razonable sería aceptar que esto sólo aplica a su data particular y los modelos extrapolativos que fueron considerados.

Crone and Kourentzes (2011) Agregan trabajo adicional a la discusión, utilizando diferentes grupos de datos demuestran los beneficios de usar validación fuera de la muestra de datos utilizada para el entrenamiento de los modelos, basándose en medidas de error fuera de la muestra.

En resumen, las investigaciones entregan resultados conflictivos. Si el ajuste dentro de la muestra es inadecuado, como estos autores han descrito, entonces un método distinto de selección es necesario. Aunque estos métodos prueben mejor rendimiento con entrenamiento dentro de la muestra de data disponible, esto dependerá estrictamente del análisis de esta y cómo se compone. La proyección basada en reglas de comportamiento intenta solucionar la problemática, Shah (1997) and Meade (2000), propuso utilizar características de los datos para predecir rendimiento y complejas reglas de decisión.

Collopy and Armstrong (1992). También utilizaron características para desarrollar reglas que combinan varios modelos de predicción dependiendo de condiciones en la data. Demostrando buen rendimiento en varias condiciones empíricas.

Según (R. Fildes and F. Petropoulos 2015) El analista de pronósticos debe retener toda la data de los eventos que ocurren cronológicamente después de los eventos utilizados para ajustar los modelos. Por lo cual, en vez de utilizar “*k-fold cross validation*”, para datos de series de tiempo se utiliza “*hold-out cross validation*”, donde subgrupos de datos (seccionados temporalmente) son reservados para validar el rendimiento de los modelos. Donde los datos de validación vienen después del subgrupo de entrenamiento.

Como plantean (Varma and Simon 2006), un procedimiento de validación cruzada anidada provee un estimado del error real, casi insesgado.

A modo de conclusión debe adaptarse la proyección a los datos con análisis exhaustivo de éstos y que representan para la serie de tiempo, utilizando reglas de decisión, criterios del pronosticador y finalmente para series de tiempo una validación cruzada encadenada, validada con métricas de desempeño de pronósticos.

2.6. Métricas de Desempeño de Pronósticos

Una gran diversidad de medidas de error son encontradas disponibles en la literatura, Davydenko and Fildes (2013) resumen los argumentos que establecen sus diferencias. En el estudio presente se diferencian dependiendo de qué tipo de error que se busca medir, que representan los modelos analizados, que modelos se someterán a comparación y la estructura de los datos de las series de tiempo analizadas.

2.6.1. Desviación media absoluta (MAD)

El MAD es una medida de dispersión estadística, es un estadístico robusto siendo más resiliente a datos atípicos que la desviación estándar, ya que, estos tienen mayor efecto (cuadrático) en la varianza que este estadístico, por lo que es utilizado en métodos como señal de rastreo, para resaltar la presencia de estos datos atípicos.

$$\frac{1}{n} \sum_{i=1}^n |Y_i - m(Y)|$$

Dependiendo de los datos y lo buscado a analizar $m(Y)$ puede tomar el valor del promedio, mediana o la moda.

2.6.2. Error cuadrado medio (MSE)

Mide el promedio de los cuadrados del error, representa una medida de calidad, calculando el sesgo de los modelos respecto a los valores reales.

$$MSE = \frac{1}{n} \sum_i^n (Y_i - f_i)^2$$

2.6.3. Raíz cuadrada del error medio (RMSE)

Representa la raíz del error cuadrado medio.

$$RMSE = \sqrt{\frac{1}{n} \sum_i^n (Y_i - f_i)^2}$$

2.6.4. Error porcentual absoluto medio (MAPE)

Representa precisión cómo porcentaje, es fácil de interpretar y es útil en proyecciones grandes y que no contienen ceros, es uno de los estimadores más robusto de tendencia central y dispersión.

$$MAPE = \frac{1}{n} \sum_i^n \left| \frac{Y_i - f_i}{Y_i} \right|$$

2.6.5. Coeficiente de determinación (R cuadrado)

Representa la proporción de la varianza en la variable dependiente que es explicada por las variables independientes. Sea Y_i serie de tiempo con n observaciones, promedio $\bar{y}$ y f_i valores proyectados de un modelo econométrico.

$$R^2 = 1 - \frac{\sum_i^n (f_i - \bar{y})^2}{\sum_i^n (Y_i - \bar{y})^2}$$

2.6.6. Coeficiente de determinación ajustado (R cuadrado ajustado)

Representa la proporción de la varianza en la variable dependiente que es explicada por las variables independientes, ajustada al número de variables independientes presentes en el modelo, y el número de datos, matemáticamente, sea p el número de variables independientes presentes en el modelo.

$$\bar{R}^2 = 1 - (1 - R^2) \frac{n - 1}{n - p - 1}$$

2.7. Técnicas de Evaluación de Desempeño de Modelos

2.7.1. Criterio de la información akaike (AIC)

Este criterio es basado en la función de máxima verosimilitud, (akaike, 1973). Es un estimador de calidad relativa de modelos estadísticos para una determinada data, dada una colección de modelos para la data en análisis, AIC estima su calidad relativa a otros modelos, con el objetivo de la selección del mejor modelo.

Sea k el número de parámetros estimados en el modelo. Sea L , el valor máximo estimado de la función de máxima verosimilitud para el modelo:

$$AIC = 2K - 2\ln(L)$$

En su versión corregida para muestras pequeñas:

$$AICc = AIC + \frac{2k^2 + 2k}{n - k - 1}$$

Se busca minimizar la pérdida de información estimada, suponiendo que existen R modelos candidatos, se denotan sus valores AIC de dichos modelos:

$$AIC_1, AIC_2, AIC_3, \dots AIC_R,$$

Sea AIC_{min} , el mínimo de aquellos valores.

Entonces,

$$P = e^{\frac{AIC_{min} - AIC_i}{2}}$$

Puede ser interpretada como proporcional a la probabilidad de que el modelo i -ésimo, minimiza el estimado de pérdida de información.

2.7.2. Validación cruzada

La validación cruzada es un método estadístico para evaluar y comparar algoritmos de aprendizaje, consiste en dividir la data disponible en dos partes, una dedicada al entrenamiento (regresión y ajuste) de los modelos y otra parte dedicada a la validación (data que será dedicada a probar el rendimiento de los modelos).

Existen dos clases de validación cruzada, métodos exhaustivos y métodos no exhaustivos que se diferencian en la capacidad computacional requerida para las estimaciones.

El primero siendo “*Leave-p-out cross-validation*” el cuál involucra utilizar p observaciones como grupo de validación y las observaciones restantes como subgrupo de entrenamiento (ajuste a los modelos). Esto es repetido con todas las formas posibles a fin de cortar el grupo original de datos en un set de validación de p observaciones y un subgrupo de

data de entrenamiento. Lo que origina una distribución binominal combinatorial que es computacionalmente exhaustiva. Generalmente no se computan todas las combinaciones de división de la muestra original, estos métodos son aproximaciones del “*Leave-p-out cross-validation*”.

Los segundos siendo los métodos no exhaustivos, “*k-fold cross-validation*” y “*Hold-out method*”, La muestra original de datos es particionada de forma aleatoria en k submuestras de igual número de datos. De estas submuestras, una es retenida como data de validación de los modelos, y las restantes $k - 1$ muestras son utilizadas como data de entrenamiento (ajuste de los modelos). Este proceso de validación es cruzada es repetido k veces y sus resultados pueden ser promediados a fin de producir una sola estimación más robusta.

De forma gráfica:

Data de entrenamiento ●
Data de validación ●

Figura 6 Simbología de datos

2.7.2.1. Validación cruzada tradicional

Se secciona en dos grupos, datos de entrenamiento y datos de validación, en el entrenamiento de ajustan modelos a los datos y en el grupo de validación se comparan las proyecciones con métricas de desempeño de pronósticos.



Figura 7 Partición de datos en validación cruzada tradicional agrupativa

2.7.2.2. Validación cruzada estándar (muestra aleatoria)

La selección de datos ocurre de forma aleatoria, usualmente utilizada para analizar variables aleatorias no secuenciales en el tiempo (que el tiempo no genere sesgo o afecte su comportamiento) y posteriormente se procede como una validación cruzada tradicional. Es comúnmente utilizado con tipos de datos no secuenciales.




Figura 8 Partición de datos en validación cruzada aleatoria

2.7.2.3. Validación cruzada de series de tiempo (variación de *K-Fold Cross-Validation*)




Figura 9 Partición de datos en *k-fold* validación cruzada

Para la validación cruzada en series de tiempo se define según (Hyndman and Athanasopoulos (2012)) el siguiente procedimiento.

Sea k el mínimo número de observaciones dedicado a la data a entrenamiento y T el número total de observaciones.

Seleccionar $k + i$ observaciones para los datos de entrenamiento, utilizar las observaciones en secuencia $1, 2, \dots, k + i - 1$ para estimar los modelos. Calcular el error para la proyección en el tiempo $k + i$. Calcular medidas de rendimiento y desempeño sobre todos los errores. Repetir para $i = 0, 1, \dots, T - k$.

Las medidas de rendimiento MAE, MSE, RMSE, todas dependen del tamaño de las muestras.

MAPE no depende del tamaño de la muestra, sin embargo, es sensible si la serie de tiempo Y_t es

$Y_t \gg 0 \forall t$ y si dentro de la serie existen 0 naturales.

2.7.2.4. Validación cruzada aplicada

La validación cruzada aplicada en este estudio es una combinación de la validación cruzada de series de tiempo (variación de K-Fold Cross-Validation), con un leve cambio, por la estructura del problema de tráfico y los datos. Existen carreteras recién inauguradas desde los años 2003, que deben estabilizarse para poder generar un comportamiento normal e identificar patrones, es por esto por lo que también se iteró acortando las $k + i$ observaciones para los datos de entrenamiento, combinatorialmente probando todas las combinaciones dependiendo la estructura de la serie. Quitando las primeras observaciones probando las combinaciones que estabilizasen los pronósticos. Calculando las medidas de rendimiento y desempeño sobre todos los errores.




Figura 10 Ejemplo particionamiento de datos en la validación de este estudio

3. METODOLOGÍA

El objeto de este capítulo será explicar los procedimientos aplicados para la formulación de modelos de proyección utilizando los enfoques y técnicas previamente definidas, así como la comparación de los modelos con métricas de evaluación de desempeño.

En el caso de estudio de proyección de tráfico por los datos dispuestos el criterio será analizar 21 series de tiempo individualmente, una para cada tipo de vehículo, de los cuales se cuenta con 7 clasificaciones, en 3 tramos de carretera. Se determinó que la mejor forma de tomar los datos a fin de proyectar es de forma anual y con ayuda del ajuste estacional generar los pronósticos mensuales requeridos.

La toma de decisiones es basada en la observación, investigación de las causales del fenómeno en estudio, que generalmente resultan en aspectos analíticos de observaciones del pasado, identificando irregularidades y regularidades. *“Ahí es cuando proyectar se hace posible, asumiendo que las regularidades pasadas determinarán los comportamientos futuros”*. (Petropoulos y Nikolopoulos).

Parte del análisis de los modelos es proceder cambio en las ventanas de entrenamiento de los datos, evaluando los modelos descritos anteriormente siendo entrenados:

- Hasta el año 2014, validados en los años 2015, 2016.
- Hasta el año 2015, validados en el año 2016.
- Hasta el año 2016.

Comparando su rendimiento en el año 2017.

En el caso de este estudio de tráfico fueron aplicados 4 tipos de modelos:

- Suavizamiento exponencial doble de Holt-Winters.
- Media móvil (3).
- ARIMA.
- Modelos de regresión lineal.

Para el desarrollo metodológico de este estudio se definieron los siguientes pasos:

1. Análisis de datos.
2. Definición de un grupo de modelos candidatos para todas las series de tiempo.
3. Parametrización de los modelos de regresión.
4. Análisis de datos atípicos y estructura de la serie de tiempo.
5. Selección de los mejores modelos por métricas de desempeño por grupo de modelos.
6. Generación de proyecciones, transformación inversa de Cox-Box.
7. Aplicación de validación cruzada variación de k-fold, comparación de modelos (con métrica robusta).
8. Paso de iteración.
9. Con los mejores modelos, proyección y ajustes estacionales a las proyecciones anuales.

3.1.1. Preamálisis de datos

A modo de determinar la estabilidad de la series de tiempo es pre-aplicada una validación cruzada al análisis estructural de los datos.

La validación cruzada aplicada en este estudio es una combinación de la validación cruzada de series de tiempo (variación de K-Fold Cross-Validation), con un leve cambio, por la estructura del problema de tráfico y los datos. Existen carreteras recién inauguradas desde los años 2003, que deben estabilizarse para poder generar un comportamiento normal e identificar patrones, por lo que también se iteró acortando las $k+i$ observaciones para los datos de entrenamiento, combinatorialmente probando todas las combinaciones dependiendo la estructura de la serie. Quitando las primeras observaciones probando las combinaciones que estabilizasen los pronósticos, comparando vía MAPE y R cuadrado-ajustado, sus cambios proporcionales y estabilidad de estas agregando o quitando observaciones. Calculando las medidas de rendimiento y desempeño sobre todos los errores, finalmente se

obtuvo los años desde los cuales entrenar los modelos para cada tipo de vehículo para cada tramo de carretera.

Ejemplo de ventanas de preanálisis




Figura 11 Partición de datos en el preanálisis

3.1.2. Análisis de los datos

La tarea de seleccionar un apropiado método de proyección es condicionada por el contexto y la data hábil. Armstrong (2001).

Ruta del Maule, la carretera en análisis, cuenta con dos plazas de peaje troncales (Río Claro y Retiro) y 16 entradas y salidas laterales. La recolección de datos dados por los sistemas de peaje debido la estructura de cobro de este, son datos de tipo diario a contar desde el año 2003 hasta el año 2017 seccionados por tipo de vehículo, entre ellos motos, vehículos livianos, vehículos livianos con remolque, buses de dos ejes, buses de más de dos ejes, camiones de dos ejes y camiones de más de dos ejes. Así mismo estas variables se agrupan en tres grandes categorías, Río Claro, Retiro y Laterales (en sumatoria de tráfico agrupados en uno, a pesar de ser 16 entradas y salidas).

Se define una serie de tiempo por cada tipo de vehículo por cada categoría y se procede a ingresarlas a Microsoft Excel y luego exportadas a la herramienta R estudios cómo series de tiempo a través del paquete XLConnect de R. Datos anuales y datos mensuales de flujo de tráfico. (Fuente: <https://cran.r-project.org/web/packages/XLConnect/index.html>).

Los datos fueron analizados con las funciones PACF y ACF cómo descrito en el punto (2.3.3.1 y 2.3.3.2), función en R `acf()`, `pacf()`, a modo de verificar estacionalidad, y fueron desestacionalizados según el procedimiento descrito en el punto (2.3.4), excepto para el análisis con modelos SARIMA.

Ejemplo de análisis por función PACF, ACF.




Gráfico 7 Función Autocorrelación y Parcial contra rezagos

Es aplicada la transformación de Cox-Box descrita en el punto (2.3.5) a todas las series con λ óptimo encontrado por la función `Box.test()` de R, luego aplicada la transformación en Excel y los datos exportados a R.

La estacionalidad también es graficada para ser estudiada siendo ordenada por mes a modo de apreciar el cambio mensual y por año, de forma de analizar su comportamiento mensual en variación anual. Se determinó para el ajuste estacional mensual de las proyecciones anuales para todas las series de tiempo, debe ser utilizado el índice calculado.

Ejemplo análisis estacional por mes




Gráfico 8 Estacionalidad anual por mes

Ejemplo análisis estacional anual




Gráfico 9 Estacionalidad mensual por año

3.2. Definición de un grupo de modelos candidatos de regresión para todas las series de tiempo

3.2.1. Literatura sobre la elección de variables candidatas

Evidencia empírica concluye que al incrementar la complejidad de modelos de regresión típicamente es reducido el rendimiento de las proyecciones. (Armstrong 1985, pp. 225-232).

Zellner (2001) Comprobó en su estudio que al agregar más variables al modelo, apreciando la complejidad ya vista por el fenómeno del tráfico, cambiando la composición de la explicación de este, agregando variables como “feriados por año”, “fines de semana largos” e “ingreso por localidad cerca de la autopista” sólo indujo en un incremento en la varianza de los modelos, decreciendo su capacidad de proyección y explicación del fenómeno.

Las predicciones basadas en regresiones son más efectivas con pequeños números de variables explicativas, donde se espera que los cambios son grandes y predecibles, utilizando relaciones causales bien establecidas. (Armstrong, J. Scott (2012)) prueba esto en su trabajo "Ilusiones en el análisis por regresión".

Esto ya indica indicios que los mejores modelos serán los basados en regresión, siempre y cuando la causalidad sea bien justificada.

3.2.2. Variable explicativa

Cómo variable explicativa de forma lógica se establece causalidad en indicadores económicos como el INACER (Índice de actividad regional económica) y el IMACEC con el flujo de tráfico, debido a que mayor ingreso y actividad motiva a mayor actividad empresarial en el sector de Ruta del Maule. Mayores transportistas aumenta el tráfico, mayor flujo de bienes y mayor poder adquisitivo por parte de los consumidores.

El banco central establece en cuanto al IMACEC que no se refiere a valores agregados sectoriales, toda la información disponible corresponde a indicadores de oferta, sin contar con antecedentes sobre el consumo intermedio de las actividades. Sin embargo, se considera

como un indicador anticipado de la evolución del valor agregado y del PIB, bajo el supuesto que dichos indicador de oferta evolucionan de manera similar al valor agregado de las correspondientes actividades.

(Fuente:<https://si3.bcentral.cl/estadisticas/Principal1/Metodologias/CCNN/imacec/serieestudios42.pdf>).

En el caso de este estudio, al ser realizado para un concesionaria, se cuenta con proyecciones exactas del PIB, asesoría comprada y realizadas por un organismo de peso, la Latin American Forecast Asociation (LAFA) y validados por Bloomberg. Por lo cual para las proyecciones de tráfico vehicular se utilizará en los modelos de regresión los datos disponibles para el 2018, 2019 y 2020. Será elegido el PIB como variable explicativa.

3.2.3. Modelos de regresión propuestos para el estudio

Se definieron los siguientes modelos de regresión basados en el PIB a modo de probar su desempeño.

Modelos de regresión

$$(1) TMDA = a + b * PIB + D$$

$$(2) TMDA = a + b * Ln(PIB) + D$$

$$(3) Ln(TMDA) = a + b * PIB + D$$

$$(4) Ln(TMDA) = a + b * Ln(PIB) + D$$

$$(5) TMDA = a + b * PIB + c * \Delta PIB + D$$

$$(6) Ln(TMDA) = a + b * Ln(Pib) + c * Ln(\Delta PIB + c) + D$$

$$(7) Ln(TMDA) = a + b * Ln(Pib) + c * \Delta TMDA_{-1} + D$$

$$(8) Ln(TMDA) = a + b * Ln(Pib) + c * Ln(\Delta PIB + c) + d * \Delta TMDA_{-1} + D$$

$$(9) Ln(TMDA) = a + b * Ln(Pib) + c * \Delta TMDA_{-1} + D$$

$$(10) Ln(TMDA) = a + b * Ln(Pib) + c * Ln(\Delta TMDA_{-1} + u) + D$$

$$(11) Ln(TMDA) = a + b * Ln(Pib) + c * Ln(\Delta PIB + c) + d * Ln(\Delta TMDA_{-1} + u) + D$$

$$(12) Ln(TMDA) = a + b * Ln(Pib) + c * Ln(\Delta PIB + c) + d * Ln(TMDA_{-1} + u) + D$$

$$(13) Ln(TMDA) = a + b * Ln(Pib) + Ln(\Delta PIB + c) + +D$$

$$(14) Ln(TMDA) = a + b * Ln(Pib) + c * \Delta TMDA_{-1} + d * Ln(\Delta TMDA_{-1} + u) + D$$

$$(15) \ln(TMDA) = a + b * PIB + c * \Delta PIB + D$$

Simbología

Variables	
PIB	Producto interno bruto encadenado 2003.
vpib	Variación del PIB a 1 periodo.
lnpib	Logaritmo en base Cox-Box del PIB.
lnvpibc	Logaritmo en base Cox-Box de la variación del PIB a 1 periodo.
lnvtmpac	Logaritmo en base Cox-Box del tráfico anual más una constante.
lnvtmpa-1	Logaritmo en base Cox-Box del tráfico anual a 1 periodo.
vtmda-1	Variación del tráfico anual a 1 periodo.
lnvtmpa-1	Logaritmo en base Cox-Box de la variación del tráfico anual a 1 periodo.
R2	Explicación porcentual del error explicado por el modelo.
R2ajustado	Explicación porcentual del error explicado por el modelo ajustado a la muestra.
Simbología	*** = p-value<0; ** = p-value<0,001; * = p-value<0,01; ' ' = p-value null. D, variable dummy enfocada a aislar la varianza de muestras atípicas graves. TMDA = tráfico en niveles.

Tabla 3 Simbología modelos de regresión

3.3. Parametrización de modelos

3.3.1. Parametrización de los modelos de regresión

Cómo fue expuesto en el punto (2.3.2.1) se encontró los parámetros que minimicen el error cuadrático. A los cuales posteriormente se les calculó R cuadrado individual y R ajustado y las dójimas de significancia, verificando normalidad del error con dójima Jarke-Bera.

Utilizando la herramienta R, `jb.norm.test()` y `summary()`.

3.3.2. Suavizamiento exponencial doble de Holt-Winters.

Fue aplicada la definición desarrollada en el punto (2.3.8.1), a través de Microsoft Excel, encontrando los coeficientes alfa y beta que minimicen el error cuadrático medio con la extensión Solver. La primera proyección es obtenida (2018) y se mantiene la última tendencia registrada para las dos siguientes proyecciones (2019-2020).

3.3.3. Media móvil

La metodología de media móvil descrita en el punto (2.3.8.3) es aplicada. Para todos los casos se utilizó con $q = 3$, MA (3), debido a que este modelo no representa el fenómeno estudiado. Es incluido a modo de Benchmark estadístico.

3.3.4. ARIMA

Para la implementación de los modelos ARIMA y encontrar el mejor método se utilizó la herramienta `auto.arima()` del paquete ‘forecast’ de R, los datos ingresados a este modelo fueron en niveles brutos sin desestacionalizar. La cual minimiza a través de criterio de información AIC el error basado en la función de máxima verosimilitud, se busca valor máximo estimado de la función para el modelo, el objetivo es minimizar la pérdida de información estimada, suponiendo que existen R modelos candidatos.

AIC y criterios de información como el BIC (criterio de información bayesiana), contrastan el intercambio de beneficio y costo entre complejidad y bondad de ajuste del modelo. Asumiendo distribución normal del error, minimizar el AIC es asintóticamente equivalente a minimizar un paso adelante la proyección del error cuadrado medio (Petropoulos 2015).

Cómo establece Davydenko and Fildes (2013), una de las metodologías más robustas es el error porcentual absoluto medio (MAPE) y una medida de error relativo de forma de forma de comprobar la validez de los hallazgos. El MAPE aparece en la literatura cómo la forma de medición más adoptada en la práctica (Fildes and Goodwin, 2007). Las medidas

relativas de error tienen la ventaja de negar el efecto de datos atípicos. Hyndman and Athanasopoulos (2012).

3.4. Análisis de datos atípicos y estructura de las series de tiempo

3.4.1. Datos atípicos

Los modelos de predicción son usualmente útiles incluso si algunos supuestos son moderadamente violados aunque puedan no desempeñarse de forma óptima. De todas formas en aplicaciones especialmente con pequeños efectos o análisis de causalidad. Los métodos de regresión pueden llevar a resultados sesgados. Es por esto que la violación de estos supuestos debe ser tratada con cuidado.

Puntos de datos con residuales grandes y/o alto Leverage pueden afectar el resultado y la precisión del modelo de regresión. La Distancia de Cook mide el efecto de borrar estas observaciones. Puntos con alta Distancia de Cook son ameritan un análisis más exhaustivo en la examinación de los datos de la regresión.

Por lo cual es agregada una variable D, dummy al modelo, en el caso de desastres naturales como el terremoto ocurrido en el 2010, captando la varianza total del suceso si es que este afecta el comportamiento estructural de la series y la regresión.

Esto es analizado de forma gráfica con el paquete de R llamado ‘forecast’. En el cuál son comparadas las curvas de Distancia de Cook en un gráfico de residuales estandarizados contra la medida Leverage. Con la herramienta R, la función `tsdisplay()`. Y se toma atención al análisis de la observación que no se encuentre en los límites. (Fuente: <https://cran.r-project.org/web/packages/forecast/forecast.pdf>).

Ejemplo de serie analizada.




Gráfico 10 Residuales estandarizados vs apalancamiento

3.4.2. Estructura de las series de tiempo

Existen series que necesitan estabilizarse antes de poder proyectar, analizar su comportamiento y cambio en los estimadores, por lo cual se procede a cambiar las ventanas de entrenamiento de toma de datos a modo de obtener estimaciones más robustas y se realiza la comparación de sus medidas de error con los cambios de ventana.

Ejemplo de serie con cambio estructural



Gráfico 11 Serie de tiempo con cambios estructurales

3.5. Selección de los mejores modelos por métricas de desempeño por grupo de modelos

Se realizó los cálculos de las métricas establecidas en el punto (2.6), entre ellas R-cuadrado, R-cuadrado ajustado, MAD, MSE, RMSE y MAPE.

Para los modelos de regresión lineal, estos son comparadas por su significancia, por criterio de R-cuadrado en caso de tener el mismo números de variables y por R-cuadrado ajustado en caso de tener distinto número de variables explicativas.

Los modelos ARIMA fueron comparados por criterio de la información AIC.

3.6. Generación de proyecciones, transformación inversa de Cox-Box

Se realizan las proyecciones a 3 años con datos anuales para los años 2015, 2016 y 2017 de los modelos de regresión lineal basados en datos reales, entrenados hasta el año 2014. Lo mismo para los modelos ARIMA, Suavizamiento exponencial de Holt Winters y Media móvil. Finalmente se reversan las transformaciones de poder según lo descrito en el punto (2.3.5).

Se realizan las proyecciones con datos anuales para los años 2016 y 2017, entrenados hasta el año 2015.

Se realizan las proyecciones con datos anuales el año 2017 con los modelos entrenados hasta el año 2016.

3.7. Aplicación de validación cruzada variación de k-fold, comparación de modelos (con métrica robusta).

Se realiza la comparación de modelos mediante validación cruzada, método expuesto en el punto (2.7.2). Estas evaluaciones se realizan mediante los indicadores MAD, MSE, RMSE y MAPE. Tomando como factor clave de decisión el indicador MAPE, contrastado con el desempeño y el comportamiento de las proyecciones en el año 2017. Se procede a guardar los resultados obtenidos.

3.8. Paso de iteración

Vuelta al paso 3.3, cambiando la ventana del set de entrenamiento quitando la primera observación, manteniendo el grupo de modelos. (a modo de evitar los cambios estructurales y la inestabilidad de la serie de tiempo, se itera hasta obtener los modelos para cada serie de tiempo con las proyecciones más robustas con mejor desempeño por criterio MAPE). También se observa el cambio en los errores y el rendimiento de los modelos en el año 2017, además de su estabilidad de pronóstico (que no exista alta variación en este), así seleccionando la mejor ventana que represente el fenómeno en estudio y sea robusta.

3.9. Proyección y ajustes estacionales a las proyecciones anuales

Como (Fildes, 2001) establece, si el modelo más apropiado para cada serie de tiempo es determinado, la precisión y el desempeño de los modelos de predicción puede ser significativamente mejorado, típicamente cerca de un 25%-30% (Fildes and Petropoulos, 2015).

Se guardan los mejores modelos de proyección dados los criterios anteriores, basados en el MAD, MSE, RMSE y MAPE. Tomando como factor clave de decisión el indicador MAPE y el desempeño de estos en el año 2017, se procede a aplicar la estacionalidad mensual

a la serie anual para describir su comportamiento mensual en las proyecciones y se compara su R-cuadrado en las mediciones mensuales reales para los años 2015, 2016 y 2017, utilizando los modelos más robustos seleccionados.

4. Resultados

Se procede a exponer los resultados más relevantes generales en esta sección y respectivos a cada ruta organizados por tipo de vehículo (serie de tiempo analizada), el resto de los resultados que son utilizados como apoyo en el análisis para llegar a las conclusiones de este estudio son presentados en el Anexo.

4.1. Modelos finales de regresión lineal utilizados para proyectar

En esta sección se presentarán los modelos de regresión lineal que presentan la mayor estabilidad en la varianza de los estimadores y de las medidas de error expuestas anteriormente, comparados en las distintas ventanas de análisis, representan los modelos más robustos de acuerdo con los criterios utilizados en este estudio expuestos en el punto 3.

Rio Claro		
Tipos de vehículos	Año óptimo de toma de datos	Modelo
Motos	2007	x6
Livianos	2008	x16
Liv. con Rem.	2007	x6
Bus 2E	2008	x6
Cam 2E	2007	x3
Bus +2E	2007	x5
Cam +2E	2008	x16

Tabla 4 Rio Claro, Resultados de preanálisis, modelo y comienzo de ventana de entrenamiento

Retiro		
Tipos de vehículos	Año óptimo de toma de datos	Modelo
Motos	2008	x6
Livianos	2007	x16
Liv. con Rem.	2008	x16

Bus 2E	2008	x16
Cam 2E	2008	x3
Bus +2E	2008	x5
Cam +2E	2008	x3

Tabla 5 Retiro, Resultados de preanálisis, modelo y comienzo de ventana de entrenamiento

Laterales		
Tipos de vehículos	Año óptimo de toma de datos	Modelo
Motos	2008	x5
Livianos	2008	x5
Liv. con Rem.	2008	x16
Bus 2E	2009	x6
Cam 2E	2007	x4
Bus +2E	2009	x4
Cam +2E	2009	x16

Tabla 6 Laterales, Resultados de preanálisis, modelo y comienzo de ventana de entrenamiento

4.1. Comparación de modelos por MAPE 2016

Rio Claro					
Tipo	Modelo menor MAPE	Mape Proy	Mape Arima	Mape Suav	Mape Media móvil
Motos	Proy	4,27	5,49	9,25	33,59
Livianos	Proy	3,11	3,52	3,30	21,25
Liv. con Rem.	Proy	3,09	3,93	4,17	22,92
Bus 2E	Proy	3,62	4,43	5,02	18,28
Cam 2E	Proy	1,62	3,18	3,25	9,00
Bus +2E	Proy	6,19	6,20	15,79	48,20
Cam +2E	Proy	2,51	6,53	4,73	12,35

Tabla 7 Rio Claro comparación MAPE 2016


Retiro					
Tipos	Modelo menor MAPE	Mape Proy	Mape Arima	Mape Suav	Mape Media móvil
Motos	Proy	4,69	9,81	10,08	36,08
Livianos	Proy	3,98	6,10	4,62	20,29
Liv. con Rem.	Proy	3,72	6,54	5,18	26,08
Bus 2E	Proy	4,65	5,59	6,38	21,28
Cam 2E	Proy	3,07	5,86	5,07	11,21
Bus +2E	Proy	6,70	7,79	17,01	48,28

Cam +2E	Proy	1,02	5,19	3,92	10,92
---------	------	------	------	------	-------

Tabla 8 Retiro comparación MAPE 2016

Laterales					
Tipos	Modelo menor MAPE	Mape Proy	Mape Arima	Mape Suav	Mape Media móvil
Motos	Proy	0,30	6,44	8,59	29,13
Livianos	Proy	3,07	3,95	4,28	18,37
Liv. con Rem.	Suav	4,07	5,02	3,88	26,20
Bus 2E	Proy	1,22	5,02	3,88	26,20
Cam 2E	Proy	1,94	3,54	2,93	6,27
Bus +2E	Proy	6,49	7,14	17,35	31,48
Cam +2E	Proy	1,52	5,36	5,42	5,43

Tabla 9 Laterales comparación MAPE 2016



4.2. Proyecciones de tráfico finales

Esta sección se exponen los resultados de las proyecciones finales con los modelos seleccionados bajo los criterios establecidos en el punto 3.

4.2.1. Proyecciones más robustas obtenidas de los modelos de regresión lineal

Tráfico Total Anual							
Tipo	2017	2018	2019	2020	Crec.2017-2018 (%)	Crec. 2018-2019 (%)	Crec. 2019-2020 (%)
Motos	121341	130737	144920	161603	7,74	10,85	11,51
Livianos	22348409	22631759	24729451	27289986	1,27	9,27	10,35
Liv. con Rem.	127165	129577	143957	161653	1,90	11,10	12,29
Bus 2E	895199	879528	801377	747347	-1,75	-8,89	-6,74
Cam 2E	1411635	1423583	1481707	1545857	0,85	4,08	4,33
Bus +2E	832045	855717	939503	1031259	2,85	9,79	9,77
Cam +2E	3181873	3278653	3441605	3619328	3,04	4,97	5,16
Total	28917667	29329554	31682518	34557034	1,42	8,02	9,07

Tabla 10 Resultados proyección de tráfico total anual

RIO CLARO Tráfico Anual							
Tipo	2017	2018	2019	2020	Crec.2017-2018 (%)	Crec. 2018-2019 (%)	Crec. 2019-2020 (%)
Motos	32628	35308	40637	47233	8,21	15,09	16,23
Livianos	6248375	6297211	6911037	7666701	0,78	9,75	10,93
Liv. con Rem.	51117	51953	57228	63409	1,64	10,15	10,80
Bus 2E	177512	150926	123874	95081	-14,98	-17,92	-23,24
Cam 2E	525630	539617	565600	594630	2,66	4,82	5,13
Bus +2E	373461	388587	426290	467724	4,05	9,70	9,72
Cam +2E	1430355	1482921	1559732	1643746	3,68	5,18	5,39
Total	8839078	8946524	9684399	10578525	1,22	8,25	9,23

Tabla 11 Rio Claro Resultados proyección de tráfico anual

RETIRO Tráfico Anual							
Tipo	2017	2018	2019	2020	Crec.2017-2018 (%)	Crec. 2018-2019 (%)	Crec. 2019-2020 (%)
Motos	22120	25002	28403	32490	13,03	13,61	14,39
Livianos	4525574	4575939	5043029	5618559	1,11	10,21	11,41
Liv. con Rem.	44024	45961	51251	57899	4,40	11,51	12,97
Bus 2E	103581	105634	92806	80280	1,98	-12,14	-13,50
Cam 2E	385080	387784	406546	427514	0,70	4,84	5,16
Bus +2E	325523	332667	365467	401438	2,19	9,86	9,84
Cam +2E	1273176	1301669	1368332	1443036	2,24	5,12	5,46
Total	6679078	6774655	7355835	8061215	1,43	8,58	9,59

Tabla 12 Retiro Resultados proyección de tráfico anual

LATERALES Tráfico Anual							
Tipo	2017	2018	2019	2020	Crec.2017-2018 (%)	Crec. 2018-2019 (%)	Crec. 2019-2020 (%)
Motos	66593	70427	75879	81879	5,76	7,74	7,91
Livianos	11574460	11758610	12775386	14004727	1,59	8,65	9,62
Liv. con Rem.	32024	31663	35477	40345	-1,13	12,05	13,72
Bus 2E	614106	622967	584697	571986	1,44	-6,14	-2,17
Cam 2E	500925	496182	509560	523714	-0,95	2,70	2,78
Bus +2E	133061	134463	147745	162097	1,05	9,88	9,71
Cam +2E	478342	494063	513541	532546	3,29	3,94	3,70
Total	13399511	13608375	14642285	15917294	1,56	7,60	8,71

Tabla 13 Laterales Resultados proyección de tráfico anual

4.2.2. Resumen comparativo de modelos por MAPE y desempeño 2017

Retiro							
Tipo de análisis/vehículo	Motos	Livianos	Liv. con Rem.	Bus 2E	Cam 2E	Bus +2E	Cam +2E
Entrenamiento 2014	4,58	3,67	3,46	4,61	2,68	8,13	2,15
Validación 2015-2016	8,56	9,57	7,44	10,41	4,19	3,29	3,51
Desempeño 2017	-1,63	-12,01	-7,71	23,66	-5,88	-7,98	-2,97
Entrenamiento 2015	4,43	3,55	3,59	4,70	2,58	7,15	2,07
Validación 2016	9,87	9,98	7,24	8,43	6,74	6,05	4,98
Desempeño 2017	0,25	-9,86	-5,51	17,80	-6,64	-8,09	-4,17
Entrenamiento 2016	4,69	3,98	3,72	4,65	3,07	6,70	2,51
Desempeño 2017	4,11	-6,43	-2,66	14,10	-4,56	-5,86	-2,61

Tabla 14 Retiro Comparación MAPE de entrenamiento, validación y desempeño de los modelos de proyección

Laterales							
Tipo de análisis/vehículo	Motos	Livianos	Liv. con Rem.	Bus 2E	Cam 2E	Bus +2E	Cam +2E
Entrenamiento 2014	3,69	2,53	3,14	1,12	1,70	7,61	1,70
Validación 2015-2016	1,67	7,55	11,20	3,11	2,83	3,01	2,83
Desempeño 2017	-0,91	-11,75	-16,14	5,39	-4,77	-2,65	-4,77
Entrenamiento 2015	3,25	2,86	3,73	1,40	1,63	6,99	1,44
Validación 2016	2,38	7,50	9,11	0,05	4,19	3,42	4,93
Desempeño 2017	-0,62	-9,74	-12,68	2,83	-5,48	-4,29	-6,24
Entrenamiento 2016	3,13	3,07	4,07	1,22	1,94	6,49	1,52
Desempeño 2017	0,30	-6,92	-9,32	2,85	-4,31	-3,24	-4,17

Tabla 15 Laterales Comparación MAPE de entrenamiento, validación y desempeño de los modelos de proyección

Rio Claro							
Tipo de análisis/vehículo	Motos	Livianos	Liv. con Rem.	Bus 2E	Cam 2E	Bus +2E	Cam +2E
Entrenamiento 2014	2,55	2,09	1,38	2,74	1,43	7,02	0,56
Validación 2015-2016	12,49	11,13	10,24	10,40	2,50	3,30	2,80
Desempeño 2017	-7,74	-13,06	-11,81	7,26	-2,29	-5,52	-3,42
Entrenamiento 2015	3,52	2,65	2,06	3,17	1,50	6,44	0,57
Validación 2016	10,71	10,36	9,00	7,48	3,59	5,73	4,75
Desempeño 2017	4,43	-9,97	-9,21	2,26	-3,08	-5,88	-4,07
Entrenamiento 2016	4,27	3,11	3,09	3,62	1,62	6,19	1,02
Desempeño 2017	-0,92	-6,00	-6,44	-0,38	-2,00	-3,94	-2,21

Tabla 16 Rio Claro Comparación MAPE de entrenamiento, validación y desempeño de los modelos de proyección

4.3. Proyecciones anuales ajustadas a índices estacionales mensuales

En esta sección se exponen los resultados de las proyecciones finales escogidas de los modelos determinados más robustos ajustadas mensualmente mediante factor estacional.

4.3.1. Medida de error de ajuste de las proyecciones mensuales

Se presentan los resultados de los ajustes mensuales sobre los datos históricos reales.

Retiro	
Modelo	R2
Motos	0,973
Livianos	0,953
Livianos con remolque	0,981
Camiones de dos ejes	0,889
Camiones de más de dos ejes	0,745
Buses de dos ejes	0,933
Buses de más de dos ejes	0,928

Tabla 17 Retiro Coeficiente de determinación ajuste mensual por tipo de Vehículo

Rio Claro	
Modelo	R2
Motos	0,969
Livianos	0,936
Livianos con remolque	0,982
Camiones de dos ejes	0,884
Camiones de más de dos ejes	0,831
Buses de dos ejes	0,930
Buses de más de dos ejes	0,926

Tabla 18 Rio Claro Coeficiente de determinación ajuste mensual por tipo de Vehículo

Laterales	
Modelo	R2
Motos	0,938
Livianos	0,899
Livianos con remolque	0,977
Camiones de dos ejes	0,884
Camiones de más de dos ejes	0,621
Buses de dos ejes	0,926
Buses de más de dos ejes	0,831

Tabla 19 Laterales Coeficiente de determinación ajuste mensual por tipo de Vehículo

4.3.2. Rio Claro proyecciones ajustadas mensualmente

RIO CLARO TRÁFICO MENSUAL						
Mes/Año	Motos			Livianos		
	2018	2019	2020	2018	2019	2020
Enero	5241	6032	7011	714196	799445	897881
Febrero	5222	6011	6986	848305	949561	1066481
Marzo	4455	5128	5960	534837	598676	672392
Abril	2317	2667	3100	486925	545045	612157
Mayo	1553	1787	2077	471068	527296	592223
Junio	1003	1154	1341	426446	477347	536124
Julio	997	1147	1333	547951	613356	688879
Agosto	1314	1512	1758	455820	510229	573053
Septiembre	2327	2679	3113	557984	624586	701492
Octubre	3040	3499	4067	514650	576080	647014
Noviembre	3792	4364	5073	490823	549409	617058
Diciembre	3047	4658	5414	572452	654977	735625

Tabla 20 Rio Claro proyección de tráfico mensual Livianos y Motos

RIO CLARO TRÁFICO MENSUAL						
Mes/Año	Liv. con Rem.			Bus 2E		
	2018	2019	2020	2018	2019	2020
Enero	8135	9074	10199	17608	17885	18166
Febrero	10170	11345	12751	17422	17696	17975
Marzo	4193	4677	5256	15090	15328	15569
Abril	3298	3679	4135	14405	14632	14863
Mayo	3081	3437	3863	14068	14289	14514
Junio	2589	2888	3245	12814	13016	13221
Julio	3625	4044	4545	14273	14498	14726
Agosto	2912	3248	3650	13727	13943	14162
Septiembre	3699	4126	4637	13784	14001	14221
Octubre	3647	4068	4573	15847	16097	16350
Noviembre	3638	4058	4561	15757	16005	16257
Diciembre	4628	5186	5829	15513	15223	15463

Tabla 21 Rio Claro proyección de tráfico mensual Livianos con remolque y Buses de dos ejes

RIO CLARO TRÁFICO MENSUAL						
Mes/Año	Cam 2E			Bus +2E		
	2018	2019	2020	2018	2019	2020
Enero	48582	50921	53534	34423	37762	41433
Febrero	45011	47179	49600	34604	37962	41652
Marzo	48881	51235	53865	32311	35446	38891
Abril	45943	48155	50626	30381	33329	36568
Mayo	43009	45080	47394	30892	33889	37183
Junio	39613	41521	43652	29642	32518	35679
Julio	40472	42420	44597	33877	37164	40776

Agosto	41828	43842	46093	31507	34564	37924
Septiembre	40206	42142	44305	31673	34746	38123
Octubre	45753	47956	50417	32716	35890	39378
Noviembre	47645	49939	52502	32094	35208	38630
Diciembre	46563	55211	58044	33531	37812	41488

Tabla 22 Rio Claro proyección de tráfico mensual Camiones de dos ejes y Buses de más de dos ejes

RIO CLARO TRÁFICO MENSUAL			
Mes/Año	Cam +2E		
	2018	2019	2020
Enero	123201	129083	135388
Febrero	125266	131247	137658
Marzo	144234	151121	158502
Abril	138644	145264	152359
Mayo	126667	132715	139198
Junio	113305	118715	124513
Julio	113369	118782	124583
Agosto	114504	119972	125831
Septiembre	106938	112044	117516
Octubre	114730	120208	126079
Noviembre	118234	123880	129930
Diciembre	126202	129350	135668

Tabla 23 Rio Claro proyección de tráfico mensual Camiones de más de dos ejes

4.3.3. Retiro proyecciones ajustadas mensualmente

RETIRO TRÁFICO MENSUAL						
Mes/Año	Motos			Livianos		
	2018	2019	2020	2018	2019	2020
Enero	4131	4694	5369	532555	587820	656153
Febrero	4175	4743	5425	664818	733808	819112
Marzo	3073	3491	3994	367236	405346	452466
Abril	1586	1802	2061	323204	356744	398215
Mayo	1037	1178	1347	309778	341925	381673
Junio	623	708	810	276318	304992	340447
Julio	621	706	807	379182	418531	467184
Agosto	754	857	980	296228	326968	364978
Septiembre	1565	1778	2034	379189	418539	467193
Octubre	2057	2337	2673	341496	376934	420752
Noviembre	2558	2906	3324	324284	357936	399545
Diciembre	2157	3205	3666	396529	442697	494159

Tabla 24 Retiro proyección de tráfico mensual Motos y Livianos

RETIRO TRÁFICO MENSUAL						
Mes/Año	Liv. con Rem.			Bus 2E		
	2018	2019	2020	2018	2019	2020
Enero	7389	8240	9308	10339	9236	8067
Febrero	9322	10395	11743	10570	9443	8247
Marzo	3492	3894	4399	8059	7199	6288
Abril	2802	3124	3530	7206	6438	5623
Mayo	2584	2882	3256	7021	6272	5478
Junio	2102	2344	2648	6404	5721	4997
Julio	2989	3333	3765	7613	6801	5940
Agosto	2318	2585	2920	6714	5997	5238
Septiembre	3063	3415	3858	6903	6166	5386
Octubre	2982	3325	3756	8017	7162	6255
Noviembre	3053	3404	3845	8012	7158	6252
Diciembre	3966	4311	4870	8175	7035	6145

Tabla 25 Retiro proyección de tráfico mensual Livianos con remolque y Buses de dos ejes

RETIRO TRÁFICO MENSUAL						
Mes/Año	Cam 2E			Bus +2E		
	2018	2019	2020	2018	2019	2020
Enero	38510	40373	42455	34435	41442	50151
Febrero	33765	35399	37225	35462	42678	51647
Marzo	34893	36582	38468	32443	39044	47250
Abril	32397	33965	35716	30522	36732	44452
Mayo	29791	31233	32844	31067	37389	45247
Junio	27492	28822	30308	29730	35780	43299
Julio	27935	29286	30797	34165	41117	49758
Agosto	28610	29994	31541	31574	37998	45984
Septiembre	27660	28998	30494	31653	38094	46099
Octubre	31982	33530	35259	32412	39008	47205
Noviembre	34343	36005	37862	31979	38486	46574
Diciembre	33461	42360	44545	33632	41300	49979

Tabla 26 Retiro proyección de tráfico mensual Camiones de dos ejes y Buses de más de dos ejes

RETIRO TRÁFICO MENSUAL			
Mes/Año	Cam +2E		
	2018	2019	2020
Enero	114169	120016	126568
Febrero	110170	115812	122135
Marzo	121323	127536	134499
Abril	113943	119779	126318
Mayo	111783	117508	123923
Junio	102009	107233	113087
Julio	104188	109524	115504
Agosto	105963	111390	117472
Septiembre	96806	101764	107320

Octubre	102302	107541	113412
Noviembre	105712	111125	117192
Diciembre	112320	119104	125606

Tabla 27 Retiro proyección de tráfico mensual Camiones de más de dos ejes

4.3.4. Laterales proyecciones ajustadas mensualmente

LATERALES TRÁFICO MENSUAL						
Mes/año	Motos			Livianos		
	2018	2019	2020	2018	2019	2020
Enero	8563	9226	9955	1038257	1128036	1236583
Febrero	7934	8548	9224	1004948	1091847	1196913
Marzo	7746	8346	9006	991534	1077272	1180935
Abril	5312	5723	6175	935413	1016299	1114094
Mayo	4452	4797	5176	949668	1031786	1131072
Junio	2940	3167	3418	891632	968732	1061951
Julio	2943	3171	3422	960116	1043137	1143516
Agosto	3676	3961	4274	949943	1032085	1131400
Septiembre	5092	5486	5920	959804	1042799	1143144
Octubre	6149	6625	7149	1001982	1088624	1193379
Noviembre	7297	7862	8483	989082	1074609	1178016
Diciembre	6077	8968	9677	1086232	1180160	1293723

Tabla 28 Laterales proyección de tráfico mensual Motos y Livianos

LATERALES TRÁFICO MENSUAL						
Mes/año	Liv. con Rem.			Bus 2E		
	2018	2019	2020	2018	2019	2020
Enero	2796	3133	3562	50674	48883	47039
Febrero	2706	3032	3448	46150	44518	42839
Marzo	2670	2992	3402	52122	50280	48383
Abril	2519	2822	3210	50013	48245	46424
Mayo	2557	2865	3258	50910	49111	47258
Junio	2401	2690	3059	48968	47237	45455
Julio	2585	2897	3294	49933	48168	46351
Agosto	2558	2866	3259	50826	49029	47179
Septiembre	2585	2896	3293	47825	46134	44394
Octubre	2698	3023	3438	50907	49108	47255
Noviembre	2663	2984	3394	50831	49034	47184
Diciembre	2925	3277	3727	51861	50028	48141

Tabla 29 Laterales proyección de tráfico mensual Livianos con remolque y Buses de dos ejes

LATERALES TRÁFICO MENSUAL						
Mes/año	Cam 2E			Bus +2E		
	2018	2019	2020	2018	2019	2020

Enero	47571	49000	50470	12680	13817	15057
Febrero	44249	45578	46946	12043	13124	14301
Marzo	46905	48314	49763	12536	13660	14886
Abril	44815	46161	47546	12093	13178	14360
Mayo	41065	42298	43567	12549	13675	14902
Junio	37758	38892	40058	12088	13172	14354
Julio	38130	39275	40453	12956	14118	15385
Agosto	39562	40751	41973	12713	13853	15096
Septiembre	38708	39871	41067	12312	13416	14620
Octubre	42205	43472	44776	13016	14184	15456
Noviembre	44778	46123	47507	12760	13904	15151
Diciembre	44563	52214	53780	13049	14687	16004

Tabla 30 Laterales proyección de tráfico mensual Camiones de dos ejes y Buses de más de dos ejes

LATERALES TRÁFICO MENSUAL			
Mes/año	Cam +2E		
	2018	2019	2020
Enero	42671	44353	45994
Febrero	41145	42767	44350
Marzo	45336	47123	48867
Abril	47583	49459	51289
Mayo	44708	46470	48190
Junio	39392	40945	42460
Julio	38671	40195	41683
Agosto	37631	39114	40562
Septiembre	34780	36151	37489
Octubre	38580	40101	41585
Noviembre	40735	42341	43908
Diciembre	42632	44522	46169

Tabla 31 Laterales proyección de tráfico mensual Camiones de más de dos ejes

5. Análisis de Resultados

Esta sección corresponde al análisis de los resultados obtenidos expuestos en el punto 4, complementando el análisis con los resultados expuestos en el anexo.

En el desarrollo de los resultados fueron utilizados los modelos de regresión para realizar los pronósticos para los años 2018, 2019 y 2020, puesto que en el análisis demostraron ser más robustos y consistentes en el tiempo, esto es evidenciable en el punto A.1. perteneciente al anexo.


En primera instancia el comportamiento de las series de tiempo evidencia ser similar respecto al tipo de rutas, existen cambios en magnitudes, sin embargo, no se observan grandes cambios en el comportamiento de las medidas de error de las 3 rutas analizadas. Por otro lado es apreciable en la comparación de las medidas de error ajustadas al entrenamiento de los modelos, que su varianza ante el cambio de ventanas de entrenamiento es bastante baja (alrededor de un 1% de cambio), esto generalizado para todos los modelos de regresión, los cuales fueron utilizados para proyectar, representa evidencia clara de que los parámetros de selección son apropiados para darle representatividad a las series de tiempo en estudio y existe estabilidad en los pronósticos, esta afirmación es extensible para las ventanas de validación de los modelos, donde su variación máxima es de un 3%. El desempeño en la proyección del año 2017 sujeto a la variación de las ventanas de entrenamiento para Motos, Livianos, Livianos con remolque y Buses de dos ejes, aumenta constantemente con el número de datos, con un incremento general de 3% y de un 5% promedio para Buses de dos ejes, esto es esperable debido al reducido número de datos disponibles en este estudio, los parámetros son bastante sensibles al número de datos, debilidad latente en los ajustes, a mayor número

de datos aumenta la capacidad predictiva de los modelos, sin embargo, el análisis evidencia que estas series son amigablemente proyectables bajo los supuestos asumidos, con incremento constante en su desempeño. En el análisis de Camiones de dos ejes, su desempeño en el año 2017 varía en torno al 1%, esto evidencia que la serie no es completamente representada por el alcance de este estudio, ya que no existe un incremento constante en su desempeño, sin embargo, al ser esta variación pequeña demuestra que la predictibilidad del tráfico sigue siendo robusta. Para Buses y Camiones de más de dos ejes, si bien su error de validación disminuye con el número de datos, la variación en el desempeño de la predicción para el año 2017 es entorno al 2% con el aumento del número de datos.

El peor desempeño promedio en el año 2017 es de un 18,52% para Buses de dos ejes en la ruta de Retiro, sin embargo, para esta misma serie de tiempo en las rutas de Laterales y Rio Claro, este representa un 3%-3,6%. Al ser los datos muy sensibles por su número reducido, evidencia que debe existir un dato atípico influenciado por algún suceso externo en esta ruta. En general entre las rutas la variación del desempeño promedio se encuentra en torno al 1%-2%. El mejor desempeño promedio pertenece a la series de tiempo Motos, para las 3 rutas analizadas.

Cabe destacar que en los ajustes mensuales como es apreciable en el punto A.2. del anexo, la estacionalidad de las series independientemente de la ruta presenta un marcado comportamiento estacional, los ajustes mensuales aplicados a Motos, Livianos y Livianos con remolque en promedio tuvieron un coeficiente de determinación de 0,956, evidencia que es una forma efectiva de tratar las proyecciones anuales para obtener los valores mensuales de tráfico, esto se debe a la poca variabilidad presente en la estacionalidad, cómo se observa gráficamente en el punto A.2. del anexo. Para los Camiones de dos ejes y Camiones de más

de dos ejes, cómo es observable gráficamente presentan estacionalidad variable, esta afecta el rendimiento del ajuste mensual de las proyecciones que no solo depende de la bondad de ajuste de las proyecciones anuales, sino también de la estabilidad de los índices estacionales en el tiempo, es por esto que presentan bajos coeficientes de determinación en torno al 0,88 para Camiones de dos ejes y en promedio 0,73 para Camiones de más de dos ejes, por otro lado Buses de dos ejes y de más de dos ejes presentan un estable coeficiente de 0,93, excepto en el caso de la Laterales, Buses de más de dos ejes que al presentar mal ajuste de la proyección anual, expuesto en el párrafo anterior, presenta mal ajuste mensual con un coeficiente de 0,83.



6. Conclusiones y Recomendaciones

6.1. Conclusión

Los análisis de regresión proveen una objetiva y sistemática forma de analizar datos. Como resultado las decisiones basadas en regresiones son menos probables de adquirir sesgos y son consistentes en caso de que los métodos sean aplicados correctamente, la base de las decisiones pueden ser completamente explicadas y generalmente prueban ser útiles. Sus beneficios son ampliamente documentados en la literatura al ser comparados con otros modelos bajo el mismo contexto de datos, sin embargo dos ilusiones, la significancia estadística y las correlaciones pueden reducir el valor que entregan los análisis basados en regresiones (Armstrong, 2012).

En el análisis de este estudio fueron analizadas 3 rutas de carreteras concesionadas y 7 tipos de vehículos representados por series de tiempo. Los modelos de regresión probaron ser buenos estimadores de largo plazo superando ampliamente en robustez y capacidad de estimación referente a los otros modelos econométricos clásicos expuestos, esto comprobado en el análisis de entrenamiento y validación cruzada con el cambio de ventanas de toma de datos. El PIB prueba ser una variable que describe el comportamiento del tráfico vehicular en carreteras, dada su característica de medida de actividad económica anualmente. Gracias a las características de las series de tiempo analizadas de estacionalidad marcada y baja variabilidad, fue posible adaptar los pronósticos y tener estimaciones mensuales de tráfico, cabe destacar que esto es sólo debido al comportamiento de las series de tiempo y características propias de estas.

Puede ser demandante en términos de tiempo realizar un estudio a priori de la estructura de los datos, cambios en esta en el tiempo y de factores externos históricos que afecten el comportamiento de las series, sin embargo, como se prueba en los resultados las estimaciones perciben una mejora considerable en el desempeño, cómo fue demostrado en el beneficio de los cambios de ventana de análisis y la captura de la influencia de datos atípicos, cómo los incendios forestales del año 2007 y el terremoto ocurrido en la región en el año 2010.

6.2. Recomendaciones y mejoras

Una complicación importante es que la robustez de los métodos depende del PIB, gran consideración puesto que las proyecciones son bastante sensibles a este y este en sí es sensible y difícil de proyectar, a modo de cambiar esto es recomendable comprar el acceso a más datos para representar mejor el fenómeno de tráfico, tanto así cómo tomar en cuenta el índice de actividad económica regional, variables del sector productivo propio de la región, acceder al registro de patentes de las regiones cercanas a las rutas e implementar variables del sector industrial propio de las rutas cercanas a la carretera de Ruta del Maule. En caso de querer implementar el PIB nuevamente, tomar en cuenta que es una medida global de actividad económica y actualizar sus proyecciones e influencia nuevamente en los pronósticos.

Combinaciones de proyecciones pueden resultar en mejoras significativas en cuanto a el desempeño de estas Armstrong (2001), como este plantea, generar combinaciones de modelos, promediar respuestas medias y analizar sus desempeños en validaciones cruzadas.

Existe evidencia empírica de que combinar algoritmos de proyección con indicadores basados en juicio humano puede ofrecer beneficios sustanciales. Blattberg and Hoch (1990)

utilizaron una simple combinación de (50-50%) y encontraron mejoras sustanciales en sus estudios de proyección. Cómo lo son los indicadores basados en sentimientos del Banco Central, sus resultados han sido repetidamente confirmados en la literatura. Franses and Legerstee (2011), Petropoulos et al. (2016).

6.3. Limitantes de los modelos expuestos

6.3.1. Variables Omitidas

Es necesario tener un modelo robusto, basado teóricamente en supuestos correctos, recurriendo a variables que expliquen realmente el comportamiento de la variable dependiente, en el caso en estudio al utilizar solo 1 variable explicativa y bastante sensible como el PIB, aun siento una variable de actividad económica significativa y haber comprobado en este estudio que representa bastante el fenómeno de tráfico, aún existe el peligro de que la correlación sea espúrea lo cual puede ser probado mediante dúcimas de cointegración.

6.3.2. Causalidad Inversa.

Diversos modelos teóricos predicen causalidad bidireccional, una variable dependiente puede causar cambio en una o más variables explicativas. A modo de ejemplo, altos ingresos habilitan a las personas a invertir más en su propia educación, lo que en retorno incrementa sus ganancias. Esto complica la forma en que las regresiones deberían ser estimadas, técnicas más avanzadas deben ser aplicadas en este tipo de relación, así como el modelo de Vector de Corrección de Error, que incorpora estas implicancias bidireccionales en el modelo mismo. En el caso en estudio un incremento en la actividad económica explica aumentos en el tráfico en las carreteras y en el caso de implementar a los modelos variables de actividad económica local como el INACER, decisiones económicas de mayor producción

por ende de tráfico también tendrán un gran efecto en la actividad económica regional y por ende en este índice.

6.3.3. Malas mediciones

Factores pueden ser medidos incorrectamente o difíciles de medir. Debido al número reducido de datos en el modelo este es sensible al cambio en éstos por ende malas políticas de toma de mediciones en los puestos de peaje, imperfectos de equipo o anomalías en la ruta y medición, pueden tener un gran efecto detrimental considerable en la robustez de los modelos, a modo de proyectar a futuro.

6.3.4. Focos demasiado limitados

Los coeficientes de regresión proveen información solo acerca de pequeños cambios en la variable dependiente, que puede que no la expliquen completamente, como en este caso el PIB para proyectar tráfico, no es el único factor que influye en el flujo vehicular. Los coeficiente no contemplan cambios drásticos, ni grandes o cambios de su interacción entre ellas en el tiempo. A veces el foco puede darse en aislar y explicar pequeños efectos pero no fenómenos que se encuentran en constante cambio.

BIBLIOGRAFÍA

- Makridakis, Spyros & L. Winkler, Robert. (1989). Sampling Distributions of Post-Sample Forecasting Errors. *Journal of the Royal Statistical Society. Series C. Applied Statistics*. 38. 10.2307/2348063.
- Pant, Narayan & Starbuck, William. (1990). Innocents in the Forest: Forecasting and Research Methods. *Journal of Management - J MANAGE*. 16. 433-460. 10.1177/014920639001600209.
- D Snyder, Ralph & Ord, Keith. (2009). Working Paper 4/09 Exponential Smoothing and the Akaike Information Criterion.
- Sagaert, Yves & Aghezzaf, El-Houssaine & Kourentzes, Nikolaos & Desmet, Bram. (2017). Tactical sales forecasting using a very large set of macroeconomic indicators. *European Journal of Operational Research*. 10.1016/j.ejor.2017.06.054.
- Varma, Sudhir & Simon, Richard. (2006). Bias in Error Estimation When Using Cross-Validation for Model Selection." *BMC Bioinformatics*, 7(1), 91. *BMC bioinformatics*. 7. 91. 10.1186/1471-2105-7-91.
- Davydenko, Andrey & Fildes, Robert. (2013). Measuring Forecasting Accuracy: The Case Of Judgmental Adjustments To Sku-Level Demand Forecasts. *International Journal of Forecasting*. 29. 510–522. 10.1016/j.ijforecast.2012.09.002.
- Akaike, H. (1973), "Information theory and an extension of the maximum likelihood principle", in Petrov, B. N.; Csáki, F., 2nd International Symposium on Information Theory, Tsahkadsor, Armenia, USSR, September 2-8, 1971, Budapest: Akadémiai Kiadó, pp. 267–281.
- Armstrong, J. S. (2012). *Illusions_in_Regression_Analysis @ upenn.academia.edu*, 2012(3), 961–967. Retrieved from http://upenn.academia.edu/JArmstrong/Papers/1162346/Illusions_in_Regression_Analysis
- Ripley, B. D. (2002) Time series in R 1.5.0. *R News*, 2/2, 2–7. https://www.r-project.org/doc/Rnews/Rnews_2002-2.pdf

ANEXOS

A.1. Resultados de entrenamiento y validación de modelos por ruta

Se presentan los resultados por ruta y tipo de vehículo para cada uno de los modelos en estudio, con distintas ventanas de entrenamiento, validación y su rendimiento en el año 2017, se obtienen las principales medidas de error expuestas previamente y su ajuste.

A.1.1. Rio Claro

A.1.1.1. Motos

A.1.1.1.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 12 Rio Claro Motos entrenamiento hasta 2014, proyecciones

Modelos	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	26107	28498	30102	-8,42	-13,64	-7,74
ARIMA	25924	28249	30574	-9,06	-14,39	-6,29

Suavizamiento con tasa de crec.	28195	32820	38203	-1,10	-0,54	17,09
Media móvil	20680	20680	20680	-27,46	-37,33	-36,62
Real	28508	32999	32628	-	-	-
Steer Davies	28470	29646	30660	-0,13	-10,16	-6,03

Tabla 32 Rio Claro Motos, entrenamiento hasta 2014 resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,956	4423,8	22994120	4795,2	32,38	48,71	-36,62
Suavizamiento con tasa de crec.	0,944	1216,9	2154774	1467,9	11,57	0,55	17,09
ARIMA	0,955	784,2	1288537	1135,1	5,27	13,39	-6,29
Regresión mejor R2	0,995	281,3	161467	401,8	2,55	12,49	-7,74

Tabla 33 Rio Claro Motos, entrenamiento hasta 2014 resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-40,75	1,46E-04
lnpib	4,26	6,32E-05
lnvpibc	-0,12	7,16E-03
D	0,09	2,54E-01

Tabla 34 Rio Claro Motos, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.1.1.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 13 Rio Claro Motos entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,52	26905	29464	31181	10,71	-4,43
ARIMA	5,44	26247	31156	33804	5,58	3,61
Suavizamiento con tasa de crec.	10,26	28195	33373	39500	1,13	21,06
Media móvil	33,29	24375	24375	24375	26,13	-25,29
Steer Davies	-	28508	29646	30660	10,16	-6,03
Real	-	28508	32999	32628	-	-

Tabla 35 Rio Claro Motos, entrenamiento hasta 2015 resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,984	2517,5	7731020	2780,47	15,62	26,13	25,29
Suavizamiento con tasa de crec.	0,966	1103,9	1897635	1377,55	10,26	1,13	4,43
ARIMA	0,967	924,2	1794452	1339,57	5,44	5,58	3,61
Regresión mejor R2	0,986	570,7	584451	764,49	3,52	10,71	4,43

Tabla 36 Rio Claro Motos, entrenamiento hasta 2015 resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-42,53	1,68E-05
lnpib	4,41	6,06E-06
lnvpibc	-0,13	3,86E-03
D	0,09	2,53E-01

Tabla 37 Rio Claro Motos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión



A.1.1.1.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 14 Rio Claro Motos entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	4,27	27722	30492	32327	7,60	-0,92
ARIMA	5,49	26247	31156	33804	5,58	3,61
Suavizamiento con tasa de crec.	9,25	28163	33334	39058	1,02	19,71
Media móvil	33,29	20680	24375	28369	26,13	-13,05
Real	-	28508	32999	32628	-	-
Steer Davies	-	28508	29646	30660	10,16	-6,03

Tabla 38 Rio Claro Motos, entrenamiento hasta 2016 resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,984	5510,1	35802259	5983,5	33,59	-13,05
Suavizamiento con tasa de crec.	0,980	1022,0	1701832	1304,5	9,25	19,71
ARIMA	0,980	1016,1	1954624	1398,1	5,49	3,61
Regresión mejor R2	0,981	822,3	1256930	1121,1	4,27	-0,92

Tabla 39 Rio Claro Motos, entrenamiento hasta 2016 resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-44,41	2,66E-06
lnpib	4,57	8,23E-07
lnvpibc	-0,14	2,49E-03
D	0,09	2,63E-01

Tabla 40 Rio Claro Motos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión



A.1.1.2. Livianos

A.1.1.2.1 Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 15 Rio Claro Livianos entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	2,09	5022210	5249662	5432106	-6,50	-13,28	-13,06
ARIMA	3,14	4984395	5292313	5600232	-7,20	-12,57	-10,37
Suavizamiento con tasa de crec.	4,30	5312191	5810470	6355486	-1,10	-4,01	1,71
Media móvil	16,06	4403150	4403150	4403150	-18,03	-27,26	-29,53
Real	-	5371397	6053280	6248375	-	-	-
Steer Davies	-	5371340	5572716	5795470	0,00	-7,94	-7,25

Tabla 41 Rio Claro Livianos, entrenamiento hasta 2014 resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación n 2015- 2016	Desempeño o 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,934	699173,2	499308239063	706617,5	20,08	29,73	-29,53
Suavizamiento con tasa de crec.	0,957	149918,1	31160392142	176523,1	4,30	1,76	1,71

ARIMA	0,94 6	116398, 7	23184466040	152264, 5	3,14	11,07	-10,37
Regresión mejor R2	0,98 2	73633,8	7938286734	89097,1	2,09	11,13	-13,06

Tabla 42 Rio Claro Livianos, entrenamiento hasta 2014 resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	13,01	8,03E-06
PIB	0,00	1,86E-03
vpib	-1,27	1,70E-01
D	0,01	8,99E-01

Tabla 43 Rio Claro Livianos, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.1.2.2 Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 16 Rio Claro Livianos entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Proyección con regresión mejor R2	2,65	5164916	5426209	5625165	10,36	-9,97
ARIMA	3,33	5039681	5734602	6097806	5,26	-2,41

Suavizamiento con tasa de crec.	3,68	5348415	5924893	6563505	2,12	-0,05
Media móvil	20,46	4834627	4834627	4834627	20,13	-22,63
Steer Davies	-	5371340	5572716	5795470	7,94	7,25
Real	-	5371397	6053280	6248375	-	-

Tabla 44 Rio Claro Livianos, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,984	322081	124186214595	352401	8,33	20,13	-22,63
Suavizamiento con tasa de crec.	0,974	129993	26907202578	164034	3,68	2,12	-9,97
ARIMA	0,952	135944	36333245571	190613	3,33	5,26	-2,41
Proyección con regresión mejor R2	0,975	108547	17125071593	130863	2,65	10,36	-9,97

Tabla 45 Rio Claro Livianos, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,88	2,53E-07
PIB	0,00	2,34E-04
vpib	-1,56	9,64E-02
D	0,02	7,60E-01

Tabla 46 Rio Claro Livianos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.1.2.3 Entrenamiento hasta 2016, rendimiento 2017




Gráfico 17 Rio Claro Livianos entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,11	5340881	5654959	5873597	-6,58	-6,00
ARIMA	3,52	5079515	5774436	6456319	-4,61	3,33
Suavizamiento con tasa de crec.	3,30	5401688	5998293	6670636	-0,91	6,76
Media móvil	20,46	4403150	4834627	5367051	-20,13	-14,10
Real	-	5371397	6053280	6248375	-	-
Steer Davies	-	5371340	5572716	5795470	7,94	7,25

Gráfico 18 Rio Claro Livianos, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)

Media móvil	0,976	830599	736641480956	858278	21,25	-14,10
Suavizamiento con tasa de crec.	0,983	120635	24479382771	156459	3,30	6,76
ARIMA	0,970	152724	42169681939	205353	3,52	3,33
Regresión mejor R2	0,961	142449	40798308202	201986	3,11	-6,00

Gráfico 19 Rio Claro Livianos, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,72	2,34E-08
PIB	0,00	6,44E-05
vpib	-2,06	5,97E-02
D	0,04	6,04E-01

Gráfico 20 Rio Claro Livianos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.1.3. Livianos con remolque

A.1.1.3.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 21 Rio Claro Livianos con remolque, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,38	41286	43433	45081	-7,00	-11,47	-11,81
ARIMA	4,65	42901	45815	48729	-3,36	-6,61	-4,67
Suavizamiento con tasa de crec.	4,82	44924	50544	56866	1,19	3,03	11,25
Media móvil	19,25	36088	36088	36088	-18,71	-26,44	-29,40
Real	-	44394	49058	51117	-	-	-
Steer Davies	-	44530	46116	47815	0,31	-6,00	-6,46

Tabla 47 Río Claro Livianos con remolque, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,919	6104	45735687	6763	23,10	29,4791388	-29,40
Suavizamiento con tasa de crec.	0,959	1194	1892373	1376	4,82	1,37308328	11,25
ARIMA	0,954	1301	2735714	1654	4,65	5,27877882	-4,67
Proyección con regresión mejor R2	0,994	387	310748	557	1,38	10,2391446	-11,81

Tabla 48 Río Claro Livianos con remolque, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-22,50	8,21E-05
lnpib	2,77	1,83E-05
lnvpibc	-0,06	7,93E-03
D	-0,01	6,62E-01

Tabla 49 Río Claro Livianos con remolque, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.1.3.2 Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 22 Rio Claro Livianos con remolque, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	2,06	42324	44644	46411	9,00	-9,21
ARIMA	4,43	43088	47495	50596	3,19	-1,02
Suavizamiento con tasa de crec.	4,36	44924	50469	56699	2,88	-0,11
Media móvil	23,09	40232	40232	40232	17,99	-21,29
Steer Davies	-	44530	46116	47815	6,00	6,46
Real	-	44394	49058	51117	-	-

Tabla 50 Rio Claro Livianos con remolque, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,979	3150	12305589	3508	10,47	17,99	-21,29
Suavizamiento con tasa de crec.	0,975	1111	1690948	1300	4,36	2,88	-9,21
ARIMA	0,971	1281	2648417	1627	4,43	3,19	-1,02
Regresión mejor R2	0,989	632	796809	893	2,06	9,00	-9,21

Tabla 51 Rio Claro Livianos con remolque, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-23,96	2,18E-05
lnpib	2,90	3,66E-06
lnvpibc	-0,06	9,61E-03
D	-0,01	7,57E-01

Tabla 52 Rio Claro Livianos con remolque, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.1.3.3 Entrenamiento hasta 2016, rendimiento 2017




Gráfico 23 Rio Claro Livianos con remolque, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,09	43391	45937	47826	-6,36	-6,44
ARIMA	3,93	43659	48801	53722	-0,52	5,10
Suavizamiento con tasa de crec.	4,17	44349	49768	55756	1,45	9,08
Media móvil	23,09	36088	40232	44480	-17,99	-12,98
Real	-	44394	49058	51117	-	-
Steer Davies	-	44530	46116	47815	6,00	6,46

Tabla 53 Rio Claro Livianos con remolque, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,951	6807	53653127	7325	22,92	-12,98
Suavizamiento con tasa de crec.	0,984	1104	1580478	1257	4,17	9,08
ARIMA	0,975	1093	2549730	1597	3,93	5,10
Regresión mejor R2	0,984	1027	1688894	1300	3,09	-6,44

Tabla 54 Rio Claro Livianos con remolque, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-25,530	7,22E-06
Inpib	3,031	9,59E-07
Invpibc	-0,068	1,06E-02
D	-0,009	8,73E-01

Tabla 55 Rio Claro Livianos con remolque, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.1.4. Camiones de dos ejes

A.1.1.4.1 Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 24 Rio Claro Camiones de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,43	495320	503570	513584	2,09	-2,87	-2,29
ARIMA	3,95	466239	466239	466239	-3,90	-10,07	-11,30
Suavizamiento con tasa de crec.	3,71	504686	527435	551210	4,02	1,73	4,87
Media móvil	8,27	465752	465752	465752	-4,00	-10,16	-11,39
Real	-	485159	518442	525630	-	-	-
Steer Davies	-	485085	497760	511000	-0,02	-3,99	-2,78

Tabla 56 Rio Claro Camiones de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015- 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,539	39213	2151007451	46379	9,92	7,74	-11,39
Suavizamiento con tasa de crec.	0,860	15616	276101499	16616	3,71	1,86	4,87
ARIMA	0,816	15702	525006569	22913	3,95	7,62	-11,30
Regresión mejor R2	0,970	6173	60312274	7766,10	1,43	2,51	-2,29

Tabla 57 Rio Claro Camiones de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	11,81	4,52E-10
PIB	0,00	5,10E-05
D	-0,05	1,03E-01

Tabla 58 Rio Claro Camiones de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.1.4.2 Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 25 Rio Claro Camiones de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,50	491864	499815	509461	3,59	-3,08
ARIMA	3,06	480988	499908	514657	3,57	-2,09
Suavizamiento con tasa de crec.	3,73	504686	527337	551006	1,72	-0,05
Media móvil	8,96	474691	474691	474691	8,44	-9,69
Steer Davies	-	343465	351726	359890	32,16	31,53
Real	-	485159	518442	525630	-	-

Tabla 59 Rio Claro Camiones de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,871	16035	484890475	22020	3,85	8,44	-9,69
Suavizamiento con tasa de crec.	0,873	16105	289250392	17007	3,73	1,72	-3,08
ARIMA	0,864	12642	313082700	17694	3,06	3,57	-2,09
Regresión mejor R2	0,974	6517	59424874	7709	1,50	3,59	-3,08

Tabla 60 Rio Claro Camiones de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	11,84	4,65E-12
PIB	0,00	5,85E-06
D	-0,05	8,66E-02

Tabla 61 Rio Claro Camiones de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.1.4.3 Entrenamiento hasta 2016, rendimiento 2017




Gráfico 26 Rio Claro Camiones de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,62	496573	504945	515109	-2,60	-2,00
ARIMA	3,18	483047	501967	535250	-3,18	1,83
Suavizamiento con tasa de crec.	3,25	497266	518696	541596	0,05	3,04
Media móvil	8,96	465752	474691	489947	-8,44	-6,79
Real	-	485159	518442	525630	-	-
Steer Davies	-	343465	351726	359890	32,16	31,53

Tabla 62 Rio Claro Camiones de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,733	37032	1863690264	43170	9,00	-6,79
Suavizamiento con tasa de crec.	0,910	13821	241265036	15533	3,25	3,04
ARIMA	0,892	13437	312308436	17672	3,18	1,83
Regresión mejor R2	0,972	7341	80311715	8962	1,62	-2,00

Tabla 63 Rio Claro Camiones de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	11,79	1,08E-13
PIB	0,00	9,18E-07
D	-0,05	9,82E-02

Tabla 64 Rio Claro Camiones de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.1.5. Camiones de más de dos ejes

A.1.1.5.1 Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 27 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	0,56	1341259	1352013	1381420	1,31	-4,14	-3,42
ARIMA	5,56	1307724	1307724	1307724	-1,22	-7,28	-8,57
Suavizamiento con tasa de crec.	4,49	1384445	1411061	1438188	4,57	0,05	0,55
Media móvil	10,78	1278021	1278021	1278021	-3,47	-9,38	-10,65
Real	-	1323909	1410347	1430355	-	-	-
Steer Davies	-	1323855	1357860	1392110	0,00	-3,72	-2,67

Tabla 65 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015- 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,858	145166	23011433253	151695,20	13,47	6,97	-10,65
Suavizamiento con tasa de crec.	0,806	50270	3704628219	60865,66	4,49	1,47	0,55
ARIMA	0,720	59389	6115205212	78199,78	5,56	4,54	-8,57
Regresión mejor R2	0,997	6420	57517375	7584,02	0,56	2,80	-3,42

Tabla 66 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,786	1,33E-07
PIB	0,000	1,99E-04
vpib	0,820	1,91E-02
D	-0,093	5,47E-03

Tabla 67 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.1.5.2 Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 28 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,50	491864	499815	509461	3,59	-3,08
ARIMA	3,06	480988	499908	514657	3,57	-2,09
Suavizamiento con tasa de crec.	3,73	504686	527337	551006	1,72	-0,05
Media móvil	8,96	474691	474691	474691	8,44	-9,69
Steer Davies	-	343465	351726	359890	32,16	31,53
Real	-	485159	518442	525630	-	-

Tabla 68 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,871	16035	484890475	22020	3,85	8,44	-9,69
Suavizamiento con tasa de crec.	0,873	16105	289250392	17007	3,73	1,72	-3,08
ARIMA	0,864	12642	313082700	17694	3,06	3,57	-2,09

Regresión mejor R2	0,974	6517	59424874	7709	1,50	3,59	-3,08
--------------------	-------	------	----------	------	------	------	-------

Tabla 69 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	11,84	4,65E-12
PIB	0,00	5,85E-06
D	-0,05	8,66E-02

Tabla 70 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.1.5.3 Entrenamiento hasta 2016, rendimiento 2017




Gráfico 29 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,02	1354031	1368285	1398743	-2,98	-2,21
ARIMA	5,19	1307724	1323909	1410347	-6,13	-1,40
Suavizamiento con tasa de crec.	3,92	1374935	1392404	1479712	-1,27	3,45

Media móvil	11,50	1278021	1305293	1347327	-7,45	-5,80
Real	-	1323909	1410347	1430355	-	-
Steer Davies	-	1323855	1357860	1392110	3,72	-2,67

Tabla 71 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,874	121934	17531285739	132406	10,92	-5,80
Suavizamiento con tasa de crec.	0,860	45063	3183026559	56418	3,92	3,45
ARIMA	0,819	57594	5615546506	74937	5,19	-1,40
Regresión mejor R2	0,984	12822	357938284	18919	1,02	-2,21

Tabla 72 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,74	1,29E-10
PIB	0,00	1,41E-05
vpib	0,65	8,30E-02
D	-0,09	1,53E-02

Tabla 73 Rio Claro Camiones de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.1.6. Buses de dos ejes

A.1.1.6.1 Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 30 Rio Claro Buses de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	2,74	206731	197458	190399	10,81	12,41	7,26
ARIMA	4,00	178699	147996	117294	-4,21	-15,75	-33,92
Suavizamiento con tasa de crec.	5,82	187019	158372	134113	0,25	-9,84	-24,45
Media móvil	13,76	241520	241520	241520	29,46	37,49	36,06
Real	-	186558	175658	177512	-	-	-
Steer Davies	-	186515	174948	162790	-0,02	-0,40	-8,29

Tabla 74 Rio Claro Buses de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,897	52399	2857319654	53454	17,21	25,0132494	36,06
Suavizamiento con tasa de crec.	0,925	17268	361632108	19017	5,82	3,72038899	-24,45
ARIMA	0,946	11113	213821077	14623	4,00	11,5444393	-33,92
Regresión mejor R2	0,976	7305	84208039	9176	2,74	10,3992393	7,26

Tabla 75 Rio Claro Buses de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	44,00	1,13E-03
lnpiib	-2,66	2,95E-03
lnvpibc	0,04	1,83E-01
D	-0,16	9,52E-02

Tabla 76 Rio Claro Buses de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.1.6.2 Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 31 Rio Claro Buses de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,17	198800	188794	181533	7,48	2,26
ARIMA	3,94	179821	156978	127399	10,63	-28,23
Suavizamiento con tasa de crec.	5,03	186977	166580	148408	5,17	-16,40
Media móvil	18,32	214412	214412	214412	22,06	20,79
Steer Davies	-	186515	174948	162790	0,40	-8,29
Real	-	186558	175658	177512	-	-

Tabla 77 Rio Claro Buses de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,948	29711	1005595355	31711	10,63	22,06	20,79
Suavizamiento con tasa de crec.	0,942	14868	309997938	17607	5,03	5,17	-16,40
ARIMA	0,961	10565	193711446	13918	3,94	10,63	-28,23
Regresión mejor R2	0,975	7782	110082133	10492	3,17	7,48	2,26

Tabla 78 Rio Claro Buses de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	46,79	1,74E-04
lnpib	-2,90	5,67E-04
lnvpibc	0,05	1,30E-01
D	-0,17	8,57E-02

Tabla 79 Rio Claro Buses de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.1.6.3 Entrenamiento hasta 2016, rendimiento 2017




Gráfico 32 Rio Claro Buses de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,62	194723	184187	176842	4,86	-0,38
ARIMA	4,43	182156	159313	148413	-9,30	-16,39
Suavizamiento con tasa de crec.	5,02	187666	167194	157425	-4,82	-11,32
Media móvil	18,32	241520	214412	190539	22,06	7,34
Real	-	186558	175658	177512	-	-
Steer Davies	-	186515	174948	162790	0,40	-8,29

Tabla 80 Rio Claro Buses de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,956	50552	2658666402	51562	18,28	7,34
Suavizamiento con tasa de crec.	0,957	14053	280853215	16759	5,02	-11,32
ARIMA	0,967	10948	206111135	14357	4,43	-16,39
Regresión mejor R2	0,976	8881	122248654	11057	3,62	-0,38

Tabla 81 Rio Claro Buses de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	48,42	1,62E-05
lnpib	-3,04	6,69E-05
lnvpibc	0,06	6,84E-02
D	-0,18	5,76E-02

Tabla 82 Rio Claro Buses de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.1.7. Buses de más de dos ejes

A.1.1.7.1 Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 33 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	7,02	318565	337503	352828	0,94	-5,37	-5,52
ARIMA	6,77	334636	370279	405922	6,03	3,82	8,69
Suavizamiento con tasa de crec.	16,61	364590	424153	493445	15,52	18,92	32,13
Media móvil	48,62	255945	255945	255945	-18,90	-28,24	-31,47
Real	-	315608	356657	373461	-	-	-
Steer Davies	-	315725	331596	346020	0,04	-7,03	-7,35

Tabla 83 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,969	74592	5673663049	75324	58,34	31,33	-31,47
Suavizamiento con tasa de crec.	0,979	17811	391558622	19788	16,61	9,78	32,13
ARIMA	0,977	10482	168818424	12993	6,77	4,68	8,69

Regresión mejor R2	0,977	9346	162904910	12763	7,02	3,30	-5,52
--------------------	-------	------	-----------	-------	------	------	-------

Tabla 84 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-759252,60	4,69E-04
PIB	7,59	2,10E-04
vpib	-495286,60	1,60E-01
D	24082,41	3,16E-01

Tabla 85 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.1.7.2 Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 34 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	6,44	317452	336224	351484	5,73	-5,88
ARIMA	6,68	332258	348873	382137	2,18	2,32
Suavizamiento con tasa de crec.	16,98	346507	370764	396719	3,96	6,23
Steer Davies	-	315725	331596	346020	7,03	-7,35

Media móvil	52,50	291439	291439	291439	18,29	-21,96
Real	-	315608	356657	373461	-	-

Tabla 86 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,990	35404	1310182687	36196	23,68	18,29	-21,96
Suavizamiento con tasa de crec.	0,975	19873	531416620	23052	16,98	3,96	-5,88
ARIMA	0,978	11432	185262101	13611	6,68	2,18	2,32
Regresión mejor R2	0,983	8601	145410441	12059	6,44	5,73	-5,88

Tabla 87 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-754908,7	4,60E-05
PIB	7,548558	1,41E-05
vpib	-486289,8	1,10E-01
D	23891,75	2,60E-01

Tabla 88 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.1.7.3 Entrenamiento hasta 2016, rendimiento 2017




Gráfico 35 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	6,19	323270	343197	358730	-3,77	-3,94
ARIMA	6,20	333123	349738	390787	-1,94	4,64
Suavizamiento con tasa de crec.	15,79	342496	366081	410606	2,64	9,95
Media móvil	52,50	255945	291439	323753	-18,29	-13,31
Real	-	315608	356657	373461	-	-
Steer Davies	-	315725	331596	346020	7,03	-7,35

Tabla 89 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)

Media móvil	0,980	71120	5168768048	71894	48,20	-13,31
Suavizamiento con tasa de crec.	0,982	19070	487136579	22071	15,79	9,95
ARIMA	0,983	10981	172122243	13120	6,20	4,64
Regresión mejor R2	0,985	9729	158371041	12585	6,19	-3,94

Tabla 90 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-776674,50	6,86E-06
PIB	7,75	1,37E-06
vpib	-561680,60	5,79E-02
D	25842,67	2,18E-01

Tabla 91 Rio Claro Buses de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.2. Retiro

A.1.2.1. Motos

A.1.2.1.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 36 Retiro Motos, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	4,58	19341	20644	21759	-4,01	-11,47	-1,63
ARIMA	11,58	19133	20776	22419	-5,04	-10,90	1,35
Suavizamiento con tasa de crec.	11,62	22069	25825	30221	9,53	10,75	36,63
Media móvil	31,98	15907	15907	15907	-21,05	-31,78	-28,09
Real	-	20148	23318	22120	-	-	-
Steer Davies	-	20075	20862	21900	-0,36	-10,53	-0,99

Tabla 92 Retiro Motos, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,890	4101	18068989	4251	39,98	36,62	-28,09
Suavizamiento con tasa de crec.	0,847	1289	2552108	1598	11,62	6,14	36,63
ARIMA	0,778	1236	3300847	1817	11,58	8,77	1,35

Regresión mejor R2	0,930	526	1144683	1070	4,58	8,56	-1,63
--------------------	-------	-----	---------	------	------	------	-------

Tabla 93 Retiro Motos, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-35,83	2,22E-04
lnpib	3,83	1,08E-04
lnvpibc	-0,06	1,53E-02
D	-0,08	7,46E-02

Tabla 94 Retiro Motos, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.2.1.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 37 Retiro Motos, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	4,43	19644	21016	22176	9,87	0,25
ARIMA	10,60	19278	21936	23724	5,93	7,25
Suavizamiento con tasa de crec.	11,24	21173	24642	28678	5,68	29,65
Media móvil	37,31	17952	17952	17952	23,01	-18,84
Steer Davies	-	20075	20862	21900	0,36	-10,53
Real	-	20148	23318	22120	-	-

Tabla 95 Retiro Motos, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,917	1821	4485079	2118	14,10	23,01	-18,84
Suavizamiento con tasa de crec.	0,900	1288	2468795	1571	11,24	5,68	29,65
ARIMA	0,853	1191	2906583	1705	10,60	5,93	7,25
Regresión mejor R2	0,951	556	1057474	1028	4,43	9,87	0,25

Tabla 96 Retiro Motos, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-36,94	1,75E-05
lnpib	3,93	6,79E-06
lnvpibc	-0,07	6,77E-03
D	-0,08	7,62E-02

Tabla 97 Retiro Motos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.2.1.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 38 Retiro Motos, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017

Regresión mejor R2	4,69	20240	21778	23029	-6,60	4,11
ARIMA	9,81	19451	22109	25279	-5,19	14,28
Suavizamiento con tasa de crec.	10,08	20777	23868	27471	2,36	24,19
Media móvil	37,31	15907	17952	20319	-23,01	-8,14
Real	-	20148	23318	22120	-	-
Steer Davies	-	20075	20862	21900	0,36	-10,53

Tabla 98 Retiro Motos, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,908	4335	19842194	4454	36,08	-8,14
Suavizamiento con tasa de crec.	0,935	1149	2270493	1507	10,08	24,19
ARIMA	0,905	1173	2671847	1635	9,81	14,28
Regresión mejor R2	0,955	680	1314734	1147	4,69	4,11

Tabla 99 Retiro Motos, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-39,28	1,00E-05
lnpib	4,12	3,28E-06
lnvpibc	-0,08	1,19E-02
D	-0,07	2,89E-01

Tabla 100 Retiro Motos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.2.2. Livianos

A.1.2.2.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 39 Retiro Livianos, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015	2016	2017	diff real 2015	diff real 2016	diff real 2017
Regresión mejor R2	4,50	3659452	3839082	3982008	- 5,18%	- 12,02%	- 12,01%
ARIMA	6,27	3599322	3828475	4057628	- 6,74%	- 12,27%	- 10,34%
Suavizamiento con tasa de crec.	6,84	3691222	3858956	4034312	- 4,36%	- 11,57%	- 10,86%
Steer Davies	-	3859510	4011360	4180345	0,00%	-8,07%	-7,63%
Real	0	3859522	4363724	4525574	0,00%	0,00%	0,00%

Tabla 101 Retiro Livianos, entrenamiento hasta 2014, resultados tráfico en niveles

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,67	3659452	3839082	3982008	-5,18	-12,02	-12,01
ARIMA	6,25	3581865	3793562	4005258	-7,19	-13,07	-11,50

Suavizamiento con tasa de crec.	5,65	3895817	4291769	4727963	0,94	-1,65	4,47
Media móvil	15,90	3173104	3173104	3173104	-17,79	-27,28	-29,89
Real	-	3859522	4363724	4525574	-	-	-
Steer Davies	-	3859510	4011360	4180345	0,00	-8,07	-7,63

Tabla 102 Retiro Livianos, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,51	1,06E-07
PIB	0,00	9,80E-05
vpib	-1,41	7,01E-02
D	-0,02	7,27E-01

Tabla 103 Retiro Livianos, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.2.2.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 40 Retiro Livianos, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,55	3733503	3928435	4079478	9,98	-9,86
ARIMA	6,15	3616572	4105925	4352329	5,91	-3,83
Suavizamiento con tasa de crec.	5,07	3881393	4290046	4741725	1,69	-0,05

Media móvil	19,51	3491017	3491017	3491017	20,00	-22,86
Steer Davies	-	3859510	4011360	4180345	8,07	7,63
Real	-	3859522	4363724	4525574	-	-

Tabla 104 Retiro Livianos, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,955	248115	77905358310	279115	9,14	20,00	-22,86
Suavizamiento con tasa de crec.	0,946	127516	25312539007	159099	5,07	1,69	-9,86
ARIMA	0,890	163963	49366519731	222186	6,15	5,91	-3,83
Regresión mejor R2	0,948	96916	23620974620	153691	3,55	9,98	-9,86

Tabla 105 Retiro Livianos, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,44	2,59E-09
PIB	0,00	8,96E-06
vpib	-1,57	4,17E-02
D	-0,01	7,88E-01

Tabla 106 Retiro Livianos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.2.2.3. Entrenamiento hasta 2016, rendimiento 2017




Tabla 107 Retiro Livianos, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,98	3846907	4071876	4234384	-6,69	-6,43
ARIMA	6,10	3645217	4134570	4638772	-5,25	2,50
Suavizamiento con tasa de crec.	4,62	3903766	4317006	4784231	-1,07	5,72
Media móvil	19,51	3173104	3491017	3864472	-20,00	-14,61
Real	-	3859522	4363724	4525574	-	-
Steer Davies	-	3859510	4011360	4180345	8,07	7,63

Tabla 108 Retiro Livianos, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,903	552271	361592333537	601325	20,29	-14,61
Suavizamiento con tasa de crec.	0,965	119674	22882486824	151270	4,62	5,72
ARIMA	0,930	170479	48518513855	220269	6,10	2,50
Regresión mejor R2	0,948	118709	33582088627	183254	3,98	-6,43

Tabla 109 Retiro Livianos, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,32	3,33E-10
PIB	0,00	3,21E-06
vpib	-1,96	3,47E-02
D	0,00	9,70E-01

Tabla 110 Retiro Livianos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.2.3. Livianos con remolque

A.1.2.3.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 41 Retiro Livianos con remolque, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,46	36679	38979	40630	-4,43	-9,28	-7,71
ARIMA	8,00	37066	39701	42337	-3,43	-7,60	-3,83
Suavizamiento con tasa de crec.	6,22	39802	44929	50717	3,70	4,56	15,20
Media móvil	21,75	31031	31031	31031	-19,15	-27,78	-29,51
Real	-	38381	42968	44024	-	-	-
Steer Davies	-	38325	39894	41610	-0,15	-7,15	-5,48

Tabla 111 Retiro Livianos con remolque, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,902	6266	40503262	6364	27,19	31,08	-29,51
Suavizamiento con tasa de crec.	0,896	1405	3585332	1893	6,22	2,65	15,20
ARIMA	0,798	1887	6987919	2643	8,00	5,89	-3,83
Regresión mejor R2	0,927	814	2798529	1673	3,46	7,44	-7,71

Tabla 112 Retiro Livianos con remolque, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	7,50	2,32E-06
PIB	0,00	5,43E-05
vpib	-2,12	4,29E-03
D	-0,03	2,38E-01

Tabla 113 Retiro Livianos con remolque, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.2.3.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 42 Retiro Livianos con remolque, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,59	37379	39859	41598	7,24	-5,51
ARIMA	7,19	37254	41204	44027	4,11	0,01
Suavizamiento con tasa de crec.	5,73	39163	44073	49599	2,57	12,66
Media móvil	26,49	34637	34637	34637	19,39	-21,32
Steer Davies	-	38325	39894	41610	7,15	-5,48
Real	-	38381	42968	44024	-	-

Tabla 114 Retiro Livianos con remolque, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,942	2900	10708174	3272	10,67	19,39	-21,32
Suavizamiento con tasa de crec.	0,938	1330	3231872	1798	5,73	2,57	12,66
ARIMA	0,876	1745	6101495	2470	7,19	4,11	0,01
Regresión mejor R2	0,949	928	2720908	1650	3,59	7,24	-5,51

Tabla 115 Retiro Livianos con remolque, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	7,41	1,48E-07
PIB	0,00	7,21E-06
vpib	-2,31	3,11E-03
D	-0,02	4,76E-01

Tabla 116 Retiro Livianos con remolque, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.2.3.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 43 Retiro Livianos con remolque, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,98	3846907	4071876	4234384	-6,69	-6,43
ARIMA	6,10	3645217	4134570	4638772	-5,25	2,50
Suavizamiento con tasa de crec.	4,62	3903766	4317006	4784231	-1,07	5,72
Media móvil	19,51	3173104	3491017	3864472	-20,00	-14,61
Real	-	3859522	4363724	4525574	-	-
Steer Davies	-	3859510	4011360	4180345	8,07	7,63

Tabla 117 Retiro Livianos con remolque, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,903	552271	361592333537	601325	20,29	-14,61
Suavizamiento con tasa de crec.	0,965	119674	22882486824	151270	4,62	5,72
ARIMA	0,930	170479	48518513855	220269	6,10	2,50
Regresión mejor R2	0,948	118709	33582088627	183254	3,98	-6,43

Tabla 118 Retiro Livianos con remolque, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,32	3,33E-10
PIB	0,00	3,21E-06
vpib	-1,96	3,47E-02
D	0,00	9,70E-01

Tabla 119 Retiro Livianos con remolque, entrenamiento hasta 2016, estimadores del mejor modelo de regresión



A.1.2.4. Camiones de dos ejes

A.1.2.4.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 44 Retiro Camiones de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	2,68	350483	355883	362428	1,99	-6,04	-5,88
ARIMA	5,35	327136	327136	327136	-4,80	-13,63	-15,05
Suavizamiento con tasa de crec.	5,74	360798	377209	394366	4,99	-0,41	2,41
Media móvil	9,97	329564	329564	329564	-4,10	-12,99	-14,42
Real	-	343647	378779	385080	-	-	-
Steer Davies	-	343465	351726	359890	-0,05	-7,14	-6,54

Tabla 120 Retiro Camiones de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,011	34769	1707872002	41326	12,46	9,60	-14,42
Suavizamiento con tasa de crec.	0,649	17335	370579827	19250	5,74	1,72	2,41
ARIMA	0,476	14663	695220156	26367	5,35	10,42	-15,05

Regresión mejor R2	0,863	8254	145242702	12052	2,68	4,19	-5,88
--------------------	-------	------	-----------	-------	------	------	-------

Tabla 121 Retiro Camiones de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	11,56	3,67E-07
PIB	0,00	4,13E-03
D	-0,09	1,17E-01

Tabla 122 Retiro Camiones de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.2.4.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 45 Retiro Camiones de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	2,58	348065	353241	359512	6,74	-6,64
ARIMA	5,31	327136	343647	343647	9,28	-10,76
Suavizamiento con tasa de crec.	5,52	353651	368804	384606	2,63	-0,12
Media móvil	10,82	334785	334785	334785	11,61	-13,06
Real	-	343647	378779	385080	-	-
Steer Davies	-	343465	351726	359890	7,14	-6,54

Tabla 123 Retiro Camiones de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,639	14387	439466405	20963	4,87	11,61	-13,06
Suavizamiento con tasa de crec.	0,681	16719	342152062	18497	5,52	2,63	-0,12
ARIMA	0,546	14894	642394277	25345	5,31	9,28	-10,76
Regresión mejor R2	0,884	7944	130689190	11432	2,58	6,74	-6,64

Tabla 124 Retiro Camiones de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	11,59	6,26E-09
PIB	0,00	8,21E-04
D	-0,09	8,03E-02

Tabla 125 Retiro Camiones de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.2.4.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 46 Retiro Camiones de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017

Regresión mejor R2	3,07	354648	360461	367516	-4,84	-4,56
ARIMA	5,86	327136	343647	378779	-9,28	-1,64
Suavizamiento con tasa de crec.	5,07	356760	372494	389836	-1,66	1,24
Media móvil	10,82	329564	334785	349854	-11,61	-9,15
Real	-	343647	378779	385080	-	-
Steer Davies	-	343465	351726	359890	7,14	-6,54

Tabla 126 Retiro Camiones de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,334	32859	1494211832	38655	11,21	-9,15
Suavizamiento con tasa de crec.	0,785	15639	307219934	17528	5,07	1,24
ARIMA	0,641	17143	708156849	26611	5,86	-1,64
Regresión mejor R2	0,889	10010	167584345	12945	3,07	-4,56

Tabla 127 Retiro Camiones de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	11,49	3,85E-10
PIB	0,00	2,54E-04
D	-0,08	1,10E-01

Tabla 128 Retiro Camiones de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.2.5. Camiones de más de dos ejes

A.1.2.5.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 47 Retiro Camiones de más de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	2,15	1187878	1209283	1235304	3,06	-3,89	-2,97
ARIMA	6,94	1140737	1140737	1140737	-1,03	-9,34	-10,40
Suavizamiento con tasa de crec.	5,40	1217221	1277219	1340175	5,61	1,51	5,26
Media móvil	11,88	1107584	1107584	1107584	-3,91	-11,97	-13,01
Real	-	1152607	1258231	1273176	-	-	-
Steer Davies	-	1152670	1182180	1212530	0,01	-6,04	-4,76

Tabla 129 Retiro Camiones de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015- 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,918	137136	21494901253	146611	14,86	8,83	-13,01

Suavizamiento con tasa de crec.	0,80 5	52575	4480365607	66936	5,40	2,27	5,26
ARIMA	0,49 3	62254	9380507668	96853	6,94	5,67	-10,40
Regresión mejor R2	0,94 2	20563	901798022	30030	2,15	3,51	-2,97

Tabla 130 Retiro Camiones de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,58	7,99E-08
PIB	0,00	7,51E-04
D	-0,11	2,42E-02

Tabla 131 Retiro Camiones de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.2.5.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 48 Retiro Camiones de más de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	2,07	1175368	1195582	1220133	4,98	-4,17
ARIMA	6,20	1140737	1152607	1152607	8,39	-9,47
Suavizamiento con tasa de crec.	5,34	1189724	1242262	1297121	1,27	1,88

Media móvil	12,70	1137321	1137321	1137321	9,61	-10,67
Steer Davies	-	1152670	1182180	1212530	6,04	-4,76
Real	-	1152607	1258231	1273176	-	-

Tabla 132 Retiro Camiones de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,734	57833	5532216667	74379	6,01	9,61	-10,67
Suavizamiento con tasa de crec.	0,784	52811	4182923462	64676	5,34	1,27	1,88
ARIMA	0,580	55956	8225556322	90695	6,20	8,39	-9,47
Regresión mejor R2	0,945	20139	898301284	29972	2,07	4,98	-4,17

Tabla 133 Retiro Camiones de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,63	1,26E-09
PIB	0,00	1,37E-04
D	-0,11	1,47E-02

Tabla 134 Retiro Camiones de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.2.5.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 49 Retiro Camiones de más de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	2,51	1191592	1213415	1239953	-3,56	-2,61
ARIMA	6,53	1140737	1152607	1258231	-8,39	-1,17
Suavizamiento con tasa de crec.	4,73	1194770	1248270	1306672	-0,79	2,63
Media móvil	12,70	1107584	1137321	1183858	-9,61	-7,02
Real	-	1152607	1258231	1273176	-	-
Steer Davies	-	1152670	1182180	1212530	6,04	-4,76

Tabla 135 Retiro Camiones de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,787	119080	17104308842	130783	12,35	-7,02
Suavizamiento con tasa de crec.	0,845	47079	3679941946	60663	4,73	2,63
ARIMA	0,664	61474	8551208884	92473	6,53	-1,17
Regresión mejor R2	0,946	26020	1097649454	33131	2,51	-2,61

Tabla 136 Retiro Camiones de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,56	4,73E-11
PIB	0,00	3,12E-05

D	-0,11	1,75E-02
---	-------	----------

Tabla 137 Retiro Camiones de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.2.6. Buses de dos ejes

A.1.2.6.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 50 Retiro Buses de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	4,61	143272	134216	128085	9,78	13,52	23,66
ARIMA	4,76	117293	90988	64684	-10,13	-23,04	-37,55
Suavizamiento con tasa de crec.	7,45	125184	98438	77407	-4,08	-16,74	-25,27
Media móvil	15,73	178022	178022	178022	36,41	50,58	71,87
Real	-	130507	118227	103581	-	-	-
Steer Davies	-	130670	116754	105485	0,12	-1,25	1,84

Tabla 138 Retiro Buses de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,739	45075	2229251116	47215	19,66	30,14	71,87

Suavizamiento con tasa de crec.	0,879	15418	301088715	17352	7,45	8,12	-25,27
ARIMA	0,931	10092	182164116	13497	4,76	20,60	-37,55
Regresión mejor R2	0,935	9371	168781021	12992	4,61	10,41	23,66

Tabla 139 Retiro Buses de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	15,24	3,08E-05
PIB	0,00	4,16E-03
vpib	2,12	2,01E-01
D	-0,21	1,13E-01

Tabla 140 Retiro Buses de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.2.6.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 51 Retiro Buses de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	4,70	137806	128192	122023	8,43	17,80
ARIMA	5,22	119180	106090	81674	10,27	-21,15

Suavizamiento con tasa de crec.	6,88	125589	114140	103736	3,46	0,15
Media móvil	21,07	152239	152239	152239	28,77	46,98
Steer Davies	-	130670	116754	105485	0,12	-1,25
Real	-	130507	118227	103581	-	-

Tabla 141 Retiro Buses de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,902	25561	800266736	28289	12,32	28,77	46,98
Suavizamiento con tasa de crec.	0,917	13847	261816184	16181	6,88	3,46	0,15
ARIMA	0,946	9982	183949261	13563	5,22	10,27	-21,15
Regresión mejor R2	0,947	9136	171421787	13093	4,70	8,43	17,80

Tabla 142 Retiro Buses de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	15,42	1,01E-06
PIB	0,00	5,03E-04
vpib	2,52	1,08E-01
D	-0,23	7,13E-02

Tabla 143 Retiro Buses de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión



A.1.2.6.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 52 Retiro Buses de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	4,65	134432	124335	118183	5,17	14,10
ARIMA	5,59	120698	107608	95328	-8,98	-7,97
Suavizamiento con tasa de crec.	6,38	125855	114382	103619	-3,25	0,04
Media móvil	21,07	178022	152239	130777	28,77	26,26
Real	-	130507	118227	103581	-	-
Steer Davies	-	130670	116754	105485	0,12	-1,25

Tabla 144 Retiro Buses de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,898	43638	2055250806	45335	21,28	26,26

Suavizamiento con tasa de crec.	0,937	12522	231053380	15200	6,38	0,04
ARIMA	0,957	9884	182007571	13491	5,59	-7,97
Regresión mejor R2	0,954	9085	175922281	13264	4,65	14,10

Tabla 145 Retiro Buses de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	15,53	3,30E-08
PIB	0,00	5,65E-05
vpib	2,89	4,83E-02
D	-0,24	4,25E-02

Tabla 146 Retiro Buses de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.2.7. Buses de más de dos ejes

A.1.2.7.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 53 Retiro Buses de más de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017

Regresión mejor R2	8,13	269875	286147	299544	0,27	-5,93	-7,98
ARIMA	9,15	287021	319850	352680	6,64	5,15	8,34
Suavizamiento con tasa de crec.	19,19	314159	368057	431203	16,72	20,99	32,46
Media móvil	48,51	215998	215998	215998	-19,75	-28,99	-33,65
Real	-	269160	304193	325523	-	-	-
Steer Davies	-	269005	288042	302585	-0,06	-5,31	-7,05

Tabla 147 Retiro Buses de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,882	70817	5208735811	72172	60,64	32,72	-33,65
Suavizamiento con tasa de crec.	0,913	21028	663207849	25753	19,19	10,56	32,46
ARIMA	0,936	12966	304904283	17462	9,15	5,56	8,34
Regresión mejor R2	0,953	9993	222536154	14918	8,13	3,29	-7,98

Tabla 148 Retiro Buses de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-669446,7	3,05E-03
PIB	6,6	1,74E-03
vpib	-409958,3	2,23E-01
D	12279,6	5,73E-01

Tabla 149 Retiro Buses de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.2.7.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 54 Retiro Buses de más de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	7,15	269577	285795	299172	6,05	-8,09
ARIMA	8,54	284469	299438	329716	1,56	1,29
Suavizamiento con tasa de crec.	18,66	295290	317550	341488	4,39	4,90
Media móvil	53,43	248263	248263	248263	18,39	-23,73
Steer Davies	-	269005	288042	302585	5,31	-7,05
Real	-	269160	304193	325523	-	-

Tabla 150 Retiro Buses de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,959	31796	1144191951	33826	21,94	18,39	-23,73
Suavizamiento con tasa de crec.	0,922	22008	733230533	27078	18,66	4,39	4,90
ARIMA	0,946	13240	310919893	17633	8,54	1,56	1,29
Regresión mejor R2	0,966	8811	194623745	13951	7,15	6,05	-8,09

Tabla 151 Retiro Buses de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-668062,4	2,89E-04
PIB	6,597288	1,20E-04
vpib	-406920,4	1,38E-01
D	12165,12	5,05E-01

Tabla 152 Retiro Buses de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.2.7.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 55 Retiro Buses de más de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	6,70	275212	292741	306442	-3,76	-5,86
ARIMA	7,79	285064	300033	335066	-1,37	2,93
Suavizamiento con tasa de crec.	17,01	291454	312398	350538	2,70	7,68

Media móvil	53,43	215998	248263	275848	-18,39	-15,26
Real	-	269160	304193	325523	-	-
Steer Davies	-	269005	288042	302585	5,31	-7,05

Tabla 153 Retiro Buses de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,958	65393	4464878491	66820	48,28	-15,26
Suavizamiento con tasa de crec.	0,942	20622	654845015	25590	17,01	7,68
ARIMA	0,960	12297	276511115	16629	7,79	2,93
Regresión mejor R2	0,971	9618	202599729	14234	6,70	-5,86

Tabla 154 Retiro Buses de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-694512,3	4,17E-05
PIB	6,834399	1,20E-05
vpib	-491534,3	6,62E-02
D	15444,5	3,97E-01

Tabla 155 Retiro Buses de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.3. Laterales

A.1.3.1. Motos

A.1.3.1.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 56 Laterales Motos, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,69	60870	63750	65985	-0,61	-2,66	-0,91
ARIMA	7,74	63116	68455	73794	3,06	4,53	10,81
Suavizamiento con tasa de crec.	8,47	71638	83536	97409	16,97	27,56	46,28
Media móvil	28,56	51957	51957	51957	-15,16	-20,66	-21,98
Real	-	61243	65489	66593	-	-	-
Steer Davies	-	61320	64050	67525	0,13	-2,20	1,40

Tabla 156 Laterales Motos, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,886	12564	164964597	12844	35,70	21,96	-21,98
Suavizamiento con tasa de crec.	0,907	3134	17445871	4177	8,47	12,04	46,28
ARIMA	0,870	2846	18293714	4277	7,74	3,65	10,81

Regresión mejor R2	0,951	1364	7237559	2690	3,69	1,67	-0,91
--------------------	-------	------	---------	------	------	------	-------

Tabla 157 Laterales Moto, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-9,75E+04	5,87E-04
PIB	1,12E+00	2,13E-04
vpib	-8,18E+04	3,50E-02
D	-2,00E+02	9,10E-01

Tabla 158 Laterales Moto, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.3.1.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 57 Laterales Motos, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,25	61026	63933	66179	2,38	-0,62
ARIMA	7,12	62848	66314	71386	1,26	7,20
Suavizamiento con tasa de crec.	8,78	65912	71812	78240	9,65	17,49
Media móvil	32,14	57399	57399	57399	12,35	-13,81
Steer Davies	-	61320	64050	67525	2,20	1,40
Real	-	61243	65489	66593	-	-

Tabla 159 Laterales Motos, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,937	5339	35264685	5938	12,87	12,35	-13,81
Suavizamiento con tasa de crec.	0,906	3331	21567649	4644	8,78	9,65	17,49
ARIMA	0,902	2691	16741951	4092	7,12	1,26	7,20
Regresión mejor R2	0,965	1213	6366723	2523	3,25	2,38	-0,62

Tabla 160 Laterales Motos, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercepto)	-9,83E+04	3,16E-05
PIB	1,12E+00	7,27E-06
vpib	-8,34E+04	1,07E-02
D	-1,40E+02	9,25E-01

Tabla 161 Laterales Motos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.3.1.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 58 Laterales Motos, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017

Regresión mejor R2	3,13	61502	64521	66794	-1,48	0,30
ARIMA	6,44	62745	66211	70457	1,10	5,80
Suavizamiento con tasa de crec.	8,59	64121	68968	73895	5,31	10,97
Media móvil	32,14	51957	57399	61503	-12,35	-7,64
Real	-	61243	65489	66593	-	-
Steer Davies	-	61320	64050	67525	2,20	1,40

Tabla 162 Laterales Motos, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,961	11272	135256047	11630	29,13	-7,64
Suavizamiento con tasa de crec.	0,921	3296	21486089	4635	8,59	10,97
ARIMA	0,926	2461	15071058	3882	6,44	5,80
Regresión mejor R2	0,972	1252	6006922	2451	3,13	0,30

Tabla 163 Laterales Motos, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercepto)	-1,01E+05	2,87E-06
PIB	1,14E+00	3,95E-07
vpib	-9,05E+04	3,68E-03
D	1,37E+02	9,26E-01

Tabla 164 Laterales Motos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.3.2. Livianos

A.1.3.2.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 59 Laterales Livianos, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	2,53	9664144	9979649	10214817	-4,41	-9,49	-11,75
ARIMA	4,33	9885132	10467323	11049513	-2,23	-5,07	-4,54
Suavizamiento con tasa de crec.	5,09	10576026	11590842	12703035	4,61	5,12	9,75
Media móvil	15,36	8701681	8701681	8701681	-13,93	-21,08	-24,82
Real	-	10110248	11025985	11574460	-	-	-
Steer Davies	-	10110135	10588014	11137245	0,00	-3,97	-3,78

Tabla 165 Laterales Livianos, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015- 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,878	1337333	1887211356170	1373758	19,20	21,45	-24,82
Suavizamiento con tasa de crec.	0,899	353782	219031216730	468008	5,09	3,09	9,75

ARIMA	0,838	307880	261940643400	511801	4,33	3,81	-4,54
Regresión mejor R2	0,940	176454	101083327083	317936	2,53	7,55	-11,75

Tabla 166 Laterales Livianos, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-7130157,7	0,0051
PIB	118,5	0,0006
vpib	-9628381,2	0,0660
D	-79944,6	0,7676

Tabla 167 Laterales Livianos, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.3.2.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 60 Laterales Livianos, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	2,86	9850115	10199189	10446611	7,50	-9,74
ARIMA	4,08	9917292	10724598	11338948	2,73	-2,03
Suavizamiento con tasa de crec.	4,84	10348525	11254494	12239776	2,07	5,75

Media móvil	18,60	9404700	9404700	9404700	14,70	-18,75
Steer Davies	-	10110135	10588014	11137245	3,97	-3,78
Real	-	10110248	11025985	11574460	-	-

Tabla 168 Laterales Livianos, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,946	606126	451336269234	671816	7,75	14,70	-18,75
Suavizamiento con tasa de crec.	0,933	343440	204480359421	452195	4,84	2,07	5,75
ARIMA	0,894	299127	230001489342	479585	4,08	2,73	-2,03
Regresión mejor R2	0,953	219949	106013212169	325597	2,86	7,50	-9,74

Tabla 169 Laterales Livianos, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	13,67	6,9234E-11
PIB	0,00	2,537E-06
vpib	-1,64	0,02999541
D	0,01	0,9184865

Tabla 170 Laterales Livianos, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.3.2.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 61 Laterales Livianos, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,07	10103387	10511360	10773334	-4,67	-6,92
ARIMA	3,95	9954965	10762271	11678008	-2,39	0,89
Suavizamiento con tasa de crec.	4,28	10274371	11137068	12093255	1,01	4,48
Media móvil	18,60	8701681	9404700	10146392	-14,70	-12,34
Real	-	10110248	11025985	11574460	-	-
Steer Davies	-	10110135	10588014	11137245	3,97	-3,78

Tabla 171 Laterales Livianos, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,937	1396531	2026912068073	1423697	18,37	-12,34

Suavizamiento con tasa de crec.	0,954	304185	181976090753	426587	4,28	4,48
ARIMA	0,929	299374	208459716918	456574	3,95	0,89
Regresión mejor R2	0,949	257071	151774034962	389582	3,07	-6,92

Tabla 172 Laterales Livianos, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-9183096	0,00119338
PIB	136,8184	4,9963E-05
vpib	-15327550	0,04141694
D	138875,4	0,7686029

Tabla 173 Laterales Livianos, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.3.3. Livianos con remolque

A.1.3.3.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 62 Laterales Livianos con remolque, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017

Regresión mejor R2	3,14	24213	25790	26857	-7,48	-12,52	-16,14
ARIMA	5,77	24859	26665	28470	-5,00	-9,55	-11,10
Suavizamiento con tasa de crec.	5,11	26163	29608	33507	-0,02	0,43	4,63
Media móvil	20,26	20301	20301	20301	-22,42	-31,14	-36,61
Real	-	26169	29481	32024	-	-	-
Steer Davies	-	26280	27450	28835	0,42	-6,89	-9,96

Tabla 174 Laterales Livianos con remolque, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,895	3935	16159918	4020	25,33	37,06	-36,61
Suavizamiento con tasa de crec.	0,941	740	947363	973	5,11	0,15	4,63
ARIMA	0,896	961	1566445	1252	5,77	7,92	-11,10
Regresión mejor R2	0,949	489	752623	868	3,14	11,20	-16,14

Tabla 175 Laterales Livianos con remolque, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	7,111014	2,59732E-05
PIB	2,11656E-05	0,000526547
vpib	-2,370145	0,02556121
D	0,02810927	0,5480408

Tabla 176 Laterales Livianos con remolque, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.3.3.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 63 Laterales Livianos con remolque, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	3,73	25010	26795	27963	9,11	-12,68
ARIMA	5,62	25046	28161	30154	4,48	-5,84
Suavizamiento con tasa de crec.	4,38	26166	29622	33535	0,48	4,72
Media móvil	26,04	23217	23217	23217	21,25	-27,50
Steer Davies	-	26280	27450	28835	6,89	-9,96
Real	-	26169	29481	32024	-	-

Tabla 177 Laterales Livianos con remolque, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,981	1982	4757022	2181	10,81	21,25	-27,50
Suavizamiento con tasa de crec.	0,967	635	812028	901	4,38	0,48	4,72
ARIMA	0,942	981	1481257	1217	5,62	4,48	-5,84

Regresión mejor R2	0,958	672	937080	968	3,73	9,11	-12,68
--------------------	-------	-----	--------	-----	------	------	--------

Tabla 178 Laterales Livianos con remolque, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	6,960	2,35201E-06
PIB	0,000	8,21444E-05
vpib	-2,700	0,01655674
D	0,041	0,4751803

Tabla 179 Laterales Livianos con remolque, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.3.3.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 64 Laterales Livianos con remolque, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	4,07	25752	27779	29039	-5,77	-9,32
ARIMA	5,02	25957	28929	32650	-1,87	1,95

Suavizamiento con tasa de crec.	3,88	26119	29564	33445	0,28	4,44
Media móvil	26,04	20301	23217	26235	-21,25	-18,08
Real	-	26169	29481	32024	-	-
Steer Davies	-	26280	27450	28835	6,89	-9,96

Tabla 180 Laterales Livianos con remolque, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,976	4645	23051799	4801	26,20	-18,08
Suavizamiento con tasa de crec.	0,981	569	711987	844	3,88	4,44
ARIMA	0,966	836	1395461	1181	5,02	1,95
Regresión mejor R2	0,961	807	1277779	1130	4,07	-9,32

Tabla 181 Laterales Livianos con remolque, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	6,823143	3,26292E-07
PIB	2,37242E-05	1,61403E-05
vpib	-3,139831	0,009751636
D	0,05758078	0,392483

Tabla 182 Laterales Livianos con remolque, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.3.4. Camiones de dos ejes

A.1.3.4.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 65 Laterales Camiones de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,70	467332	471762	477025	2,05	-3,52	-4,77
ARIMA	3,31	448176	448176	448176	-2,13	-8,34	-10,53
Suavizamiento con tasa de crec.	3,12	478182	494338	511040	4,42	1,10	2,02
Media móvil	5,50	446605	446605	446605	-2,48	-8,66	-10,84
Real	-	457951	488966	500925	-	-	-
Steer Davies	-	458075	467748	477055	0,03	-4,34	-4,77

Tabla 183 Laterales Camiones de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,333	26330	1127516643	33579	6,60	6,013	-10,84
Suavizamiento con tasa de crec.	0,737	12960	253797742	15931	3,12	1,772	2,02
ARIMA	0,578	12757	560685707	23679	3,31	5,641	-10,53

Regresión mejor R2	0,917	7158	85136418	9227	1,70	2,827	-4,77
--------------------	-------	------	----------	------	------	-------	-------

Tabla 184 Laterales Camiones de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	4,148	3,54E-02
lnpib	0,750	1,76E-03
D	-0,066	1,07E-01

Tabla 185 Laterales Camiones de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.3.4.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Tabla 186 Laterales Camiones de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,63	464271	468486	473491	4,19	-5,48
ARIMA	3,18	448176	457951	457951	6,34	-8,58
Suavizamiento con tasa de crec.	3,24	470796	485614	500898	0,69	0,00
Media móvil	5,92	451416	451416	451416	7,68	-9,88
Steer Davies	-	458075	467748	477055	4,34	-4,77
Real	-	457951	488966	500925	-	-

Tabla 187 Laterales Camiones de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,770	12131	303440823	17420	2,95	7,68	-9,88
Suavizamiento con tasa de crec.	0,761	13547	254554674	15955	3,24	0,69	-5,48
ARIMA	0,641	12425	509004031	22561	3,18	6,34	-8,58
Regresión mejor R2	0,927	6869	79728903	8929	1,63	4,19	-5,48

Tabla 188 Laterales Camiones de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	4,517	9,32E-03
lnpib	0,718	4,11E-04
D	-0,066	8,33E-02

Tabla 189 Laterales Camiones de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.3.4.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 66 Laterales Camiones de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,94	469298	473879	479321	-3,09	-4,31
ARIMA	3,54	448176	457951	488966	-6,34	-2,39
Suavizamiento con tasa de crec.	2,93	471746	486713	502692	-0,46	0,35
Media móvil	5,92	446605	451416	465031	-7,68	-7,17
Real	-	457951	488966	500925	-	-
Steer Davies	-	458075	467748	477055	4,34	-4,77

Tabla 190 Laterales Camiones de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,552	25792	1025189285	32019	6,27	-7,17
Suavizamiento con tasa de crec.	0,834	12329	227110178	15070	2,93	0,35
ARIMA	0,699	14284	554296650	23544	3,54	-2,39
Regresión mejor R2	0,925	8477	105867052	10289	1,94	-4,31

Tabla 191 Laterales Camiones de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	3,891	1,09E-02
lnpib	0,772	9,02E-05
D	-0,066	8,42E-02

Tabla 192 Laterales Camiones de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.3.5. Camiones de más de dos ejes

A.1.3.5.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 67 Laterales Camiones de más de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAP E(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,16	454637	447698	455678	2,76	-3,50	-4,74
ARIMA	6,42	446786	442433	463948	0,98	-4,64	-3,01
Suavizamiento con tasa de crec.	6,43	461227	450069	439181	4,25	-2,99	-8,19
Media móvil	5,55	450064	450064	450064	1,72	-2,99	-5,91
Real	-	442433	463948	478342	-	-	-

Tabla 193 Laterales Camiones de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,048	29975	1335491659	36544	7,40	2,39	-5,91
Suavizamiento con tasa de crec.	0,728	25436	968780391	31125	6,43	2,39	-8,19
ARIMA	0,607	24371	992297923	31501	6,42	2,92	-3,01

Regresión mejor R2	0,977	5202	55449185	7446	1,16	3,16	-4,74
--------------------	-------	------	----------	------	------	------	-------

Tabla 194 Laterales Camiones de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,165	2,82E-04
PIB	0,000	7,58E-02
vpib	2,459	5,47E-02
D	-0,115	1,31E-01

Tabla 195 Laterales Camiones de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.3.5.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 68 Laterales Camiones de más de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,44	449058	441081	448508	4,93	-6,24
ARIMA	5,63	446786	442433	442433	4,64	-7,51
Suavizamiento con tasa de crec.	5,91	456782	452182	447629	2,54	-6,42
Media móvil	5,98	449289	449289	449289	3,16	-6,07

Steer Davies	-	442380	452010	460995	2,57	-3,63
Real	-	442433	463948	478342	-	-

Tabla 196 Laterales Camiones de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,116	18565	678404965	26046	4,53	3,16	-6,07
Suavizamiento con tasa de crec.	0,700	23472	852240459	29193	5,91	2,54	-6,42
ARIMA	0,674	21635	923564131	30390	5,63	4,64	-7,51
Regresión mejor R2	0,964	6417	67047282	8188	1,44	4,93	-6,24

Tabla 197 Laterales Camiones de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,235	4,31E-06
PIB	0,000	2,46E-02
vpib	2,601	1,35E-02
D	-0,122	5,49E-02

Tabla 198 Laterales Camiones de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.3.5.3. Entrenamiento hasta 2016, rendimiento 2017




Tabla 199 Laterales Camiones de más de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,52	456471	450268	458404	-2,95	-4,17
ARIMA	5,36	446786	442433	463948	-4,64	-3,01
Suavizamiento con tasa de crec.	5,42	458995	454344	475738	-2,07	-0,54
Media móvil	5,98	450064	449289	451056	-3,16	-5,70
Real	-	442433	463948	478342	-	-
Steer Davies	-	442380	452010	460995	2,57	-3,63

Tabla 200 Laterales Camiones de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,039	22443	855920638	29256	5,43	-5,70
Suavizamiento con tasa de crec.	0,697	21846	746637314	27325	5,42	-0,54
ARIMA	0,711	21361	796711524	28226	5,36	-3,01
Regresión mejor R2	0,952	6836	80326071	8962	1,52	-4,17

Tabla 201 Laterales Camiones de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	12,138	1,35E-07
PIB	0,000	6,55E-03
vpib	2,338	9,63E-03
D	-0,108	6,29E-02

Tabla 202 Laterales Camiones de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.3.6. Buses de dos ejes

A.1.3.6.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 69 Buses de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE (%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,12	661939	652463	647225	4,17	2,27	5,39
ARIMA	4,41	661064	635453	637978	4,03	-0,40	3,89
Suavizamiento con tasa de crec.	3,29	655512	640432	625699	3,16	0,38	1,89
Media móvil	1,90	687847	687847	687847	8,25	7,82	12,01
Real	-	635453	637978	614106	-	-	-
Steer Davies	-	635465	637206	635465	0,00	-0,12	3,48

Tabla 203 Buses de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE (%)	MAPE (%)	Error (%)
Media móvil	0,200	17783	602173715	24539	2,54	7,43	12,01
Suavizamiento con tasa de crec.	0,007	23787	1378849338	37133	3,29	1,15	1,89
ARIMA	0,020	31167	1720643139	41481	4,41	2,14	3,89

Regresión mejor R2	0,848	7955	146239578	12093	1,12	3,11	5,39
--------------------	-------	------	-----------	-------	------	------	------

Tabla 204 Buses de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	21,157	0,006015583
lnpib	-0,647	0,042503964
lnvpibc	0,023	0,157220709
D	-0,143	0,031028941

Tabla 205 Buses de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.3.6.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Tabla 206 Buses de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015	2016	2017	diff real 2015	diff real 2016	diff real 2017
Proyección con regresión mejor R2	0,791207	649606,25 5	637685,13 5	631480,321 7	2,23 %	- 0,05 %	2,83%
ARIMA(0,1,0) with drift	4,4557775 5	697879,8	697879,8	697879,8	9,82 %	9,39 %	13,64 %
Suavizamiento con tasa de crec.	25,862330 4	649947,18 7	616644,16 4	585047,573 3	2,28 %	- 3,34 %	-4,73%

Steer Davies	-	635465	637206	635465	0,00 %	- 0,12 %	3,48%
Real	0	635453	637978	614106	0,00 %	0,00 %	0,00%

Tabla 207 Buses de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,40	649606	637685	631480	0,05	2,83
ARIMA	4,73	661064	635453	635453	0,40	3,48
Suavizamiento con tasa de crec.	2,93	644403	627011	610088	1,72	-0,65
Media móvil	3,81	664428	664428	664428	4,15	8,19
Steer Davies	-	635465	637206	635465	0,12	3,48
Real	-	635453	637978	614106	-	-

Tabla 208 Buses de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	22,965	0,001
PIB	-0,799	0,013
vpib	0,031	0,093
D	-0,158	0,017

Tabla 209 Buses de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.3.6.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 70 Buses de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	1,22	649704	637807	631610	-0,03	2,85
ARIMA	3,97	661064	635453	637978	-0,40	3,89
Suavizamiento con tasa de crec.	2,75	648194	631453	615433	-1,02	0,22
Media móvil	3,81	687847	664428	644832	4,15	5,00
Real	-	635453	637978	614106	-	-
Steer Davies	-	635465	637206	635465	0,12	3,48

Tabla 210 Buses de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,335	26439	1050254435	32408	3,84	5,00
Suavizamiento con tasa de crec.	0,353	19572	1019868317	31935	2,75	0,22
ARIMA	0,298	27837	1403281804	37460	3,97	3,89
Regresión mejor R2	0,867	8520	184040232	13566	1,22	2,85

Tabla 211 Buses de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Parámetros modelo mejor adj-R2		
Clase	Parámetro	Pr(> t)
(Intercept)	22,949	0,000
lnpib	-0,797	0,002
lnvpibc	0,031	0,036
D	-0,158	0,004

Tabla 212 Buses de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.1.3.7. Buses de más de dos ejes

A.1.3.7.1. Entrenamiento hasta 2014, validación 2015-2016, rendimiento 2017




Gráfico 71 Buses de más de dos ejes, entrenamiento hasta 2014, proyecciones

Resultados Tráfico Anual Validación cruzada							
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2015	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	7,61	112997	120315	129529	4,27	-1,90	-2,65
ARIMA	7,97	115258	129463	143667	6,35	5,56	7,97
Suavizamiento con tasa de crec.	22,65	117975	140357	166986	8,86	14,44	25,50
Media móvil	26,55	86053	86053	86053	-20,60	-29,84	-35,33
Real	-	108374	122647	133061	-	-	-
Steer Davies	-	108405	108702	108405	0,03	-11,37	-18,53

Tabla 213 Buses de más de dos ejes, entrenamiento hasta 2014, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2014						Validación 2015-2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE (%)	Error (%)
Media móvil	0,976	22094	492051452	22182	35,40	34,23	-35,33
Suavizamiento con tasa de crec.	0,852	10208	160042327	12651	22,65	6,92	25,50

ARIMA	0,910	5625	55854068	7474	7,97	5,62	7,97
Regresión mejor R2	0,918	4717	47242065	6873	7,61	3,01	-2,65

Tabla 214 Buses de más de dos ejes, entrenamiento hasta 2014, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-47,606	0,016
lnpib	4,989	0,009
D	0,113	0,569

Tabla 215 Buses de más de dos ejes, entrenamiento hasta 2014, estimadores del mejor modelo de regresión

A.1.3.7.2. Entrenamiento hasta 2015, validación 2016, rendimiento 2017




Gráfico 72 Buses de más de dos ejes, entrenamiento hasta 2015, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	MAPE(%) 2016	Diff real(%) 2017
Regresión mejor R2	6,99	111365	118448	127355	3,42	-4,29
ARIMA	8,10	114111	121432	134489	0,99	1,07
Suavizamiento con tasa de crec.	19,98	114535	124436	135192	1,46	1,60
Media móvil	33,04	97930	97930	97930	20,15	-26,40
Steer Davies	-	108405	108702	108405	11,37	-18,53

Real	-	108374	122647	133061	-	-
------	---	--------	--------	--------	---	---

Tabla 216 Buses de más de dos ejes, entrenamiento hasta 2015, resultados tráfico en niveles

Modelos de proyección TA							
Entrenamiento hasta 2015						Validación 2016	Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	MAPE(%)	Error (%)
Media móvil	0,894	12684	190460155	13801	18,91	20,15	-26,40
Suavizamiento con tasa de crec.	0,904	9564	143200053	11967	19,98	1,46	1,60
ARIMA	0,934	5805	53466042	7312	8,10	0,99	1,07
Regresión mejor R2	0,943	4483	40351370	6352	6,99	3,42	-4,29

Tabla 217 Buses de más de dos ejes, entrenamiento hasta 2015, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-46,587	0,003
lnpib	4,902	0,001
D	0,111	0,513

Tabla 218 Buses de más de dos ejes, entrenamiento hasta 2015, estimadores del mejor modelo de regresión

A.1.3.7.3. Entrenamiento hasta 2016, rendimiento 2017




Gráfico 73 Buses de más de dos ejes, entrenamiento hasta 2016, proyecciones

Resultados Tráfico Anual Validación cruzada						
Modelos	MAPE(%)	2015 [unidades]	2016 [unidades]	2017 [unidades]	Diff real(%) 2016	Diff real(%) 2017
Regresión mejor R2	6,49	112404	119642	128751	-2,45	-3,24
ARIMA	7,14	114284	121605	135878	-0,85	2,12
Suavizamiento con tasa de crec.	17,35	114036	123844	139447	0,98	4,80
Media móvil	33,04	86053	97930	110691	-20,15	-16,81
Real	-	108374	122647	133061	-	-
Steer Davies	-	108405	108702	108405	11,37	-18,53

Tabla 219 Buses de más de dos ejes, entrenamiento hasta 2016, resultados tráfico en niveles

Modelos de proyección TA						
Entrenamiento hasta 2016						Desempeño 2017
Modelos	R2	MAD	MSE	RMSE	MAPE(%)	Error (%)
Media móvil	0,993	22664	517068569	22739	31,48	-16,81
Suavizamiento con tasa de crec.	0,929	8400	123048683	11093	17,35	4,80
ARIMA	0,951	5210	46947725	6852	7,14	2,12
Regresión mejor R2	0,956	4418	38089482	6172	6,49	-3,24

Tabla 220 Buses de más de dos ejes, entrenamiento hasta 2016, resultados medidas de error y desempeño

Mejor modelo para proyectar		
Clase	Parámetro	Pr(> t)
(Intercept)	-47,280	0,001
lnpib	4,961	0,000
D	0,113	0,453

Tabla 221 Buses de más de dos ejes, entrenamiento hasta 2016, estimadores del mejor modelo de regresión

A.2. Dótimas Importantes en el análisis de los modelos de proyección y ajuste estacional

A.2.1. Retiro

A.2.1.1. Motos

Tests considerados importantes para la proyección			
Dótimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,2803	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dótimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,2582	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,5809	$x > 0,05$ Se acepta

Tabla 222 Retiro Motos Dótimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA	0,956
Media móvil (3) ajust. Estacional	0,986
Media móvil (3) sin Est.	0,684
Suavizamiento sin Est.	0,624
Suavizamiento ajust.Estacional	0,952
Proyección TMDA ajustado Est.	0,973

Tabla 223 Retiro Motos R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	3281,6	1,983

febrero	3316,2	2,004
marzo	2441	1,475
abril	1259,6	0,761
mayo	823,4	0,498
junio	495,2	0,299
julio	493,4	0,298
agosto	599	0,362
septiembre	1243	0,751
octubre	1634	0,987
noviembre	2031,8	1,228
diciembre	2240,6	1,354
PROMEDIO	1654,9	1

Tabla 224 Retiro Motos Índices estacionales mensuales




Gráfico 74 Retiro Motos Índice estacional mensual por año

A.2.1.2. Livianos

Tests considerados importantes para la proyección			
Dótimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,0898	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta

Dócinas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,5012	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,5792	$x > 0,05$ Se acepta

Tabla 225 Retiro Livianos Dócinas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA	0,956
Media móvil (3) ajust. Estacional	0,980
Media móvil (3) sin Est.	0,485
Suavizamiento sin Est.	0,235
Suavizamiento ajust.Estacional	0,942
Proyección TMDA ajustado Est.	0,953

Tabla 226 Retiro Livianos R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	448779	1,391
febrero	560235,8	1,736
marzo	309466,6	0,959
abril	272361	0,844
mayo	261047,2	0,809
junio	232850,4	0,722
julio	319532,8	0,990
agosto	249628,4	0,774
septiembre	319539,2	0,990
octubre	287775,4	0,892
noviembre	273271	0,847
diciembre	337982,8	1,047
PROMEDIO	322705,8	1

Tabla 227 Retiro Livianos Índices estacionales mensuales




Gráfico 75 Retiro Livianos Índice estacional mensual por año

A.2.1.3. Livianos con remolque

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,01438	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,01	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,5862	$x > 0,05$ Se acepta

Tabla 228 Retiro Livianos con remolque Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA	0,984
Media móvil (3) ajust. Estacional	0,985
Media móvil (3) sin Est.	0,432

Suavizamiento sin Est.	0,259
Suavizamiento ajust.Estacional	0,961
Proyección TMDA ajustado Est.	0,981

Tabla 229 Retiro Livianos con remolque R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	6138,2	1,929
febrero	7743,6	2,434
marzo	2900,8	0,912
abril	2327,6	0,732
mayo	2146,8	0,675
junio	1746,4	0,549
julio	2482,8	0,780
agosto	1925,6	0,605
septiembre	2544,4	0,800
octubre	2476,8	0,778
noviembre	2535,8	0,797
diciembre	3211,6	1,009
PROMEDIO	3181,7	1

Tabla 230 Retiro Livianos con remolque Índices estacionales mensuales




Gráfico 76 Retiro Livianos con remolque Índice estacional mensual por año

A.2.1.4. Camiones de dos ejes

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,3938	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,2456	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,5724	$x > 0,05$ Se acepta

Tabla 231 Retiro Camiones de dos ejes Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA	0,954
Media móvil (3) ajust. Estacional	0,973
Media móvil (3) sin Est.	0,729
Suavizamiento sin Est.	0,563
Suavizamiento ajust.Estacional	0,913
Proyección TMDA ajustado Est.	0,889

Tabla 232 Retiro Camiones de dos ejes R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	35119,4	1,192
febrero	30792,6	1,045
marzo	31821,2	1,080
abril	29544,8	1,003
mayo	27168,6	0,922
junio	25071,4	0,851
julio	25475,4	0,864
agosto	26091,2	0,885

septiembre	25224,6	0,856
octubre	29166,6	0,990
noviembre	31319,4	1,063
diciembre	36847,8	1,250
PROMEDIO	29470,25	1

Tabla 233 Retiro Camiones de dos ejes Índices estacionales mensuales




Gráfico 77 Retiro Camiones de dos ejes Índice estacional mensual por año

A.2.1.5. Camiones de más de dos ejes

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,3871	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	NA	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,02456	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,7231	$x > 0,05$ Se acepta

Tabla 234 Retiro Camiones de más de dos ejes Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(0,1,1)(1,0,0)[12]	0,647
Media móvil (3) ajust. Estacional	0,883
Media móvil (3) sin Est.	0,685
Suavizamiento sin Est.	0,341
Suavizamiento ajust.Estacional	0,708
Proyección TMDA ajustado Est.	0,745

Tabla 235 Retiro Camiones de más de dos ejes R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	104258,4	1,053
febrero	100606,2	1,016
marzo	110791	1,118
abril	104052,2	1,050
mayo	102079,4	1,031
junio	93153,4	0,940
julio	95144	0,961
agosto	96765	0,977
septiembre	88402,8	0,892
octubre	93421,2	0,943
noviembre	96535	0,975
diciembre	103465,6	1,045
PROMEDIO	99056,18333	1

Tabla 236 Retiro Camiones de más de dos ejes Índices estacionales mensuales




Gráfico 78 Retiro Camiones de más de dos ejes Índice estacional mensual por año

A.2.1.6. Buses de dos ejes

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,6232	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,5922	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,1	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,7161	$x > 0,05$ Se acepta

Tabla 237 Retiro Buses de dos ejes Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

TMD		
	Gran promedio	Estacionalidad
enero	14810	1,310
febrero	15141,8	1,339
marzo	11544,4	1,021

abril	10323	0,913
mayo	10057,4	0,889
junio	9173,8	0,811
julio	10905,2	0,964
agosto	9617	0,850
septiembre	9888	0,874
octubre	11484,8	1,016
noviembre	11477,6	1,015
diciembre	11281,8	0,998
PROMEDIO	11308,73333	1

Tabla 238 Retiro Buses de dos ejes R2 ajuste estacional aplicado a modelos anuales

Modelos de ajuste TM	
Modelos	R2
ARIMA(0,1,0)(1,0,1)[12]	0,954
Media móvil (3) ajust. Estacional	0,967
Media móvil (3) sin Est.	0,800
Suavizamiento sin Est.	0,733
Suavizamiento ajust.Estacional	0,948
Proyección TMDA ajustado Est.	0,933

Tabla 239 Retiro Buses de dos ejes Índices estacionales mensuales




Gráfico 79 Retiro Buses de dos ejes Índice estacional mensual por año

A.2.1.7. Buses de más de dos ejes

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,3673	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,99	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,601	$x > 0,05$ Se acepta

Tabla 240 Retiro Buses de más de dos ejes Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(1,0,0)(0,1,0)[12]	0,972
Media móvil (3) ajust. Estacional	0,973
Media móvil (3) sin Est.	0,877
Suavizamiento sin Est.	0,770
Suavizamiento ajust.Estacional	0,954
Proyección TMDA ajustado Est.	0,928

Tabla 241 Retiro Buses de más de dos ejes R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	24287,2	1,060
febrero	25011,8	1,092
marzo	22882,2	0,999
abril	21527,2	0,940
mayo	21912,2	0,957
junio	20969,2	0,915
julio	24097	1,052
agosto	22269,2	0,972
septiembre	22325	0,975
octubre	22860,8	0,998

noviembre	22555,2	0,985
diciembre	24204	1,057
PROMEDIO	22908,41667	1

Tabla 242 Retiro Buses de más de dos ejes Índices estacionales mensuales




Gráfico 80 Retiro Buses de más de dos ejes Índice estacional mensual por año

A.2.2. Rio Claro

A.2.2.1. Motos

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,09241	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,5775	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,6387	$x > 0,05$ Se acepta

Tabla 243 Rio Claro Motos Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(1,0,0)(1,1,0)[12] with drift	0,961
Media móvil (3) ajust. Estacional	0,985
Media móvil (3) sin Est.	0,717
Suavizamiento sin Est.	0,660
Suavizamiento ajust.Estacional	0,957
Proyección TMDA ajustado Est.	0,969

Tabla 244 Rio Claro Motos R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	4119	1,781
febrero	4104,6	1,775
marzo	3501,6	1,514
abril	1821,2	0,788
mayo	1220,2	0,528
junio	788	0,341
julio	783,2	0,339
agosto	1032,8	0,447
septiembre	1829,2	0,791
octubre	2389,4	1,033
noviembre	2980,4	1,289
diciembre	3181	1,376
PROMEDIO	2312,55	1

Tabla 245 Tabla 230 Rio Claro Motos Índices estacionales mensuales




Gráfico 81 Rio Claro Motos Índice estacional mensual por año

A.2.2.2. Livianos

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,2138	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,9755	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,6708	$x > 0,05$ Se acepta

Tabla 246 Rio Claro Livianos Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(1,0,0)(0,1,1)[12] with drift	0,955
Media móvil (3) ajust. Estacional	0,977
Media móvil (3) sin Est.	0,554
Suavizamiento sin Est.	0,295
Suavizamiento ajust.Estacional	0,936

Proyección TMDA ajustado Est.	0,936
-------------------------------	-------

Tabla 247 Rio Claro Livianos R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	577148,6	1,292
febrero	685522,8	1,534
marzo	432206,4	0,967
abril	393488,2	0,881
mayo	380674,6	0,852
junio	344614,6	0,771
julio	442804,2	0,991
agosto	368352,6	0,824
septiembre	450911,8	1,009
octubre	415893,4	0,931
noviembre	396638,4	0,888
diciembre	472851,8	1,058
PROMEDIO	446758,95	1

Tabla 248 Rio Claro Livianos Índices estacionales mensuales




Gráfico 82 Rio Claro Livianos Índice estacional mensual por año

A.2.2.3. Livianos con remolque

Tests considerados importantes para la proyección			
Dósimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,01	x > 0,05 Se acepta

Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey–Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,9125	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,6228	$x > 0,05$ Se acepta

Tabla 249 Rio Claro Livianos con remolque Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(0,0,0)(0,1,1)[12] with drift	0,985
Media móvil (3) ajust. Estacional	0,986
Media móvil (3) sin Est.	0,442
Suavizamiento sin Est.	0,274
Suavizamiento ajust.Estacional	0,965
Proyección TMDA ajustado Est.	0,982

Tabla 250 Rio Claro Livianos con remolque R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	6699,8	1,820
febrero	8376,4	2,275
marzo	3453	0,938
abril	2716,2	0,738
mayo	2537,6	0,689
junio	2132	0,579
julio	2985,6	0,811
agosto	2398	0,651
septiembre	3046,2	0,828
octubre	3003,8	0,816
noviembre	2996,4	0,814
diciembre	3829,2	1,040
PROMEDIO	3681,183333	1

Tabla 251 Rio Claro Livianos con remolque Índices estacionales mensuales




Gráfico 83 Rio Claro Livianos con remolque Índice estacional mensual por año

A.2.2.4. Camiones de dos ejes

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,4011	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,3501	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,5306	$x > 0,05$ Se acepta

Tabla 252 Rio Claro Camiones de dos ejes Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(0,1,2)(0,1,0)[12]	0,930
Media móvil (3) ajust. Estacional	0,948
Media móvil (3) sin Est.	0,690
Suavizamiento sin Est.	0,419
Suavizamiento ajust.Estacional	0,856
Proyección TMDA ajustado Est.	0,884

Tabla 253 Rio Claro Camiones de dos ejes R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	44441,2	1,080
febrero	41175,2	1,001
marzo	44715,4	1,087
abril	42027,2	1,022
mayo	39344	0,956
junio	36237,4	0,881
julio	37022,4	0,900
agosto	38263,6	0,930
septiembre	36779,6	0,894
octubre	41853,4	1,017
noviembre	43584,4	1,060
diciembre	48185,2	1,171
PROMEDIO	41135,75	1

Tabla 254 Rio Claro Camiones de dos ejes Índices estacionales mensuales




Gráfico 84 Rio Claro Camiones de dos ejes Índice estacional mensual por año

A.2.2.5. Camiones de más de dos ejes

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,2101	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,2027	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,4606	$x > 0,05$ Se acepta

Tabla 255 Rio Claro Camiones de más de dos ejes Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(0,0,3)(1,0,0)[12] with non-zero mean	0,828
Media móvil (3) ajust. Estacional	0,917
Media móvil (3) sin Est.	0,616
Suavizamiento sin Est.	0,398
Suavizamiento ajust.Estacional	0,783
Proyección TMDA ajustado Est.	0,831

Tabla 256 Rio Claro Camiones de más de dos ejes R2 ajuste estacional aplicado a modelos anuales

TMD		
Mes	Gran promedio	Estacionalidad
enero	113830,8	1,011
febrero	115739,4	1,028
marzo	133264,8	1,183
abril	128099,4	1,138
mayo	117034	1,039
junio	104687,6	0,930

julio	104746,6	0,930
agosto	105796	0,939
septiembre	98805	0,877
octubre	106004,6	0,941
noviembre	109242,2	0,970
diciembre	114066	1,013
PROMEDIO	112609,7	1

Tabla 257 Rio Claro Camiones de más de dos ejes Índices estacionales mensuales




Gráfico 85 Rio Claro Camiones de más de dos ejes Índice estacional mensual por año

A.2.2.6. Buses de dos ejes

Tests considerados importantes para la proyección			
Dótimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,9229	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dótimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,99	$x > 0,05$ Se acepta

Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,6946	$x > 0,05$ Se acepta

Tabla 258 Rio Claro Buses de dos ejes Décimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(0,1,2)(1,0,0)[12]	0,951
Media móvil (3) ajust. Estacional	0,965
Media móvil (3) sin Est.	0,831
Suavizamiento sin Est.	0,751
Suavizamiento ajust.Estacional	0,941
Proyección TMDA ajustado Est.	0,930

Tabla 259 Rio Claro Buses de dos ejes Décimas y test de hipótesis aplicados al modelo de proyección más robusto

TMD		
	Gran promedio	Estacionalidad
enero	19517,4	1,175
febrero	19311,8	1,163
marzo	16727	1,007
abril	15967,8	0,962
mayo	15593,4	0,939
junio	14204	0,855
julio	15821,2	0,953
agosto	15215,6	0,916
septiembre	15278,6	0,920
octubre	17566	1,058
noviembre	17465,8	1,052
diciembre	16612,8	1,000
PROMEDIO	16606,78333	1

Tabla 260 Rio Claro Buses de dos ejes Índices estacionales mensuales




Tabla 261 Rio Claro Buses de dos ejes Índice estacional mensual por año

A.2.2.7. Buses de más de dos ejes

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,3826	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,99	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,606	$x > 0,05$ Se acepta

Tabla 262 Rio Claro Buses de más de dos ejes Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(1,0,0)(1,1,0)[12] with drift	0,961
Media móvil (3) ajust. Estacional	0,969
Media móvil (3) sin Est.	0,882
Suavizamiento sin Est.	0,772
Suavizamiento ajust.Estacional	0,948
Proyección TMDA ajustado Est.	0,926

Tabla 263 Rio Claro Buses de más de dos ejes R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	28425,4	1,063
febrero	28575,6	1,069
marzo	26681,4	0,998
abril	25087,8	0,938
mayo	25509,6	0,954
junio	24477,8	0,915
julio	27974,8	1,046
agosto	26018	0,973
septiembre	26155	0,978
octubre	27016	1,010
noviembre	26502,6	0,991
diciembre	28463	1,064
PROMEDIO	26740,58333	1

Tabla 264 Rio Claro Buses de más de dos ejes Índices estacionales mensuales




Gráfico 86 Rio Claro Buses de más de dos ejes Índice estacional mensual por año

A.2.3. Laterales

A.2.3.1. Motos

Tests considerados importantes para la proyección			
Docimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,1465	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Docimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,99	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,5846	$x > 0,05$ Se acepta

Tabla 265 Laterales Motos Dótimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(0,0,0)(1,1,0)[12] with drift	0,896
Media móvil (3) ajust. Estacional	0,961
Media móvil (3) sin Est.	0,721
Suavizamiento sin Est.	0,618
Suavizamiento ajust.Estacional	0,899
Proyección TMDA ajustado Est.	0,938

Tabla 266 Laterales Motos R2 ajuste estacional aplicado a modelos anuales

TMD		
Mes	Gran promedio	Estacionalidad
enero	7399,2	1,459
febrero	6855,4	1,352
marzo	6693,4	1,320
abril	4589,8	0,905
mayo	3847,2	0,759

junio	2540,2	0,501
julio	2543,4	0,502
agosto	3176,8	0,626
septiembre	4399,8	0,868
octubre	5313,4	1,048
noviembre	6305	1,243
diciembre	7192,2	1,418
PROMEDIO	5071,316667	1

Tabla 267 Laterales Motos Índices estacionales mensuales




Gráfico 87 Laterales Motos Índice estacional mensual por año

A.2.3.2. Livianos

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,3459	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,9224	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,02667	$x < 0,05$ Se acepta

Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,7231	$x > 0,05$ Se acepta
---	---	--------	-------------------------

Tabla 268 Laterales Livianos Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(1,0,0)(0,1,1)[12] with drift	0,921
Media móvil (3) ajust. Estacional	0,937
Media móvil (3) sin Est.	0,654
Suavizamiento sin Est.	0,341
Suavizamiento ajust. Estacional	0,927
Proyección TMDA ajustado Est.	0,899

Tabla 269 Laterales Livianos R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	897360,2	1,060
febrero	868572	1,026
marzo	856977,8	1,012
abril	808472,6	0,955
mayo	820793	0,969
junio	770633,4	0,910
julio	829823,2	0,980
agosto	821031,2	0,969
septiembre	829553,6	0,980
octubre	866007,8	1,023
noviembre	854859	1,009
diciembre	938825,2	1,109
PROMEDIO	846909,0833	1

Tabla 270 Laterales Livianos Índices estacionales mensuales




Gráfico 88 Laterales Livianos Índice estacional mensual por año

A.2.3.3. Livianos con remolque

Tests considerados importantes para la proyección			
Dótimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,01	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dótimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,92	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,64	$x > 0,05$ Se acepta

Tabla 271 Laterales Livianos con remolque Dótimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(0,0,0)(0,1,1)[12] with drift	0,973
Media móvil (3) ajust. Estacional	0,961
Media móvil (3) sin Est.	0,517
Suavizamiento sin Est.	0,238
Suavizamiento ajust.Estacional	0,974
Proyección TMDA ajustado Est.	0,977

Tabla 272 Laterales Livianos con remolque R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	2716	1,242
febrero	2837,4	1,298
marzo	2300,2	1,052
abril	2033,6	0,930
mayo	1947	0,891
junio	1578,8	0,722
julio	1742,2	0,797
agosto	1739,2	0,796
septiembre	2073,6	0,949
octubre	2304	1,054
noviembre	2339,4	1,070
diciembre	2619,8	1,198
PROMEDIO	2185,933333	1

Tabla 273 Laterales Livianos con remolque Índices estacionales mensuales




Gráfico 89 Laterales Livianos con remolque Índice estacional mensual por año

A.2.3.4. Camiones de dos ejes

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,4011	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,3501	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,5306	$x > 0,05$ Se acepta

Tabla 274 Laterales Camiones de dos ejes Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(0,0,0)(1,1,0)[12] with drift	0,930
Media móvil (3) ajust. Estacional	0,948
Media móvil (3) sin Est.	0,690
Suavizamiento sin Est.	0,419
Suavizamiento ajust.Estacional	0,856
Proyección TMDA ajustado Est.	0,884

Tabla 275 Laterales Camiones de dos ejes R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	44441,2	1,080
febrero	41175,2	1,001
marzo	44715,4	1,087
abril	42027,2	1,022
mayo	39344	0,956
junio	36237,4	0,881

julio	37022,4	0,900
agosto	38263,6	0,930
septiembre	36779,6	0,894
octubre	41853,4	1,017
noviembre	43584,4	1,060
diciembre	48185,2	1,171
PROMEDIO	41135,75	1

Tabla 276 Laterales Camiones de dos ejes Índices estacionales mensuales




Gráfico 90 Laterales Camiones de dos ejes Índice estacional mensual por año

A.2.3.5. Camiones de más de dos ejes

Tests considerados importantes para la proyección			
Dótimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,01663	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,04259	$x < 0,05$ Se acepta
Dótimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,9529	$x > 0,05$ Se acepta

Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,04062	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,1728	$x > 0,05$ Se acepta

Tabla 277 Laterales Camiones de más de dos ejes Dósimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(0,0,3)(1,0,0)[12] with non-zero mean	0,611
Media móvil (3) ajust. Estacional	0,801
Media móvil (3) sin Est.	0,553
Suavizamiento sin Est.	0,289
Suavizamiento ajust.Estacional	0,588
Proyección TMDA ajustado Est.	0,621

Tabla 278 Laterales Camiones de más de dos ejes R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	39558,6	1,036
febrero	38144,6	0,999
marzo	42029,4	1,101
abril	44112,6	1,156
mayo	41447,4	1,086
junio	36518,8	0,957
julio	35850,4	0,939
agosto	34886,2	0,914
septiembre	32243,8	0,845
octubre	35766	0,937
noviembre	37764,2	0,989
diciembre	39709,2	1,040
PROMEDIO	38169,26667	1

Tabla 279 Laterales Camiones de más de dos ejes Índices estacionales mensuales




Gráfico 91 Lateral de Camiones de más de dos ejes Índice estacional mensual por año

A.2.3.6. Buses de dos ejes

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,3826	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,99	$x > 0,05$ Se acepta
Kwiatkowski–Phillips–Schmidt–Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,606	$x > 0,05$ Se acepta

Tabla 280 Lateral de Buses de dos ejes Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(1,0,0)(1,1,0)[12] with drift	0,961
Media móvil (3) ajust. Estacional	0,969
Media móvil (3) sin Est.	0,882

Suavizamiento sin Est.	0,772
Suavizamiento ajust.Estacional	0,948
Proyección TMDA ajustado Est.	0,926

Tabla 281 Laterales Buses de dos ejes R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	28425,4	1,063
febrero	28575,6	1,069
marzo	26681,4	0,998
abril	25087,8	0,938
mayo	25509,6	0,954
junio	24477,8	0,915
julio	27974,8	1,046
agosto	26018	0,973
septiembre	26155	0,978
octubre	27016	1,010
noviembre	26502,6	0,991
diciembre	28463	1,064
PROMEDIO	26740,58333	1

Tabla 282 Laterales Buses de dos ejes Índices estacionales mensuales




Gráfico 92 Laterales Buses de dos ejes Índice estacional mensual por año

A.2.3.7. Buses de más de dos ejes

Tests considerados importantes para la proyección			
Dóctimas TM	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,2101	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Dóctimas TA	Hipótesis alternativa	P-value	Criterio
Augmented Dickey-Fuller	Estacionariedad en rezagos, autocorrelación en que rezagos	0,2027	$x > 0,05$ Se acepta
Kwiatkowski-Phillips-Schmidt-Shin	Estacionariedad en la tendencia (para poder proyectar)	0,01	$x < 0,05$ Se acepta
Jarque Bera, Curtosis y Asimetría	Normalidad del error (modelo proyección)	0,4606	$x > 0,05$ Se acepta

Tabla 283 Laterales Buses de más de dos ejes Dóctimas y test de hipótesis aplicados al modelo de proyección más robusto

Modelos de ajuste TM	
Modelos	R2
ARIMA(4,0,0)(0,1,1)[12] with drift	0,828
Media móvil (3) ajust. Estacional	0,917
Media móvil (3) sin Est.	0,616
Suavizamiento sin Est.	0,398
Suavizamiento ajust.Estacional	0,783
Proyección TMDA ajustado Est.	0,831

Tabla 284 Laterales Buses de más de dos ejes R2 ajuste estacional aplicado a modelos anuales

TMD		
	Gran promedio	Estacionalidad
enero	113830,8	1,011
febrero	115739,4	1,028
marzo	133264,8	1,183
abril	128099,4	1,138
mayo	117034	1,039

junio	104687,6	0,930
julio	104746,6	0,930
agosto	105796	0,939
septiembre	98805	0,877
octubre	106004,6	0,941
noviembre	109242,2	0,970
diciembre	114066	1,013
PROMEDIO	112609,7	1

Tabla 285 Laterales Buses de más de dos ejes Índices estacionales mensuales




Gráfico 93 Laterales Buses de más de dos ejes Índice estacional mensual por año