



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



industrials
valència

TRABAJO FIN DE MÁSTER

**MODELO CAUSAL DE PREVISIÓN DE DEMANDA Y METODOLOGÍA PARA
LA IDENTIFICACIÓN DE VARIABLES EXPLICATIVAS Y VALORES
EXTRAORDINARIOS. APLICACIÓN A UNA EMPRESA DEL SECTOR DE
SOLUCIONES DE LAVADO PARA LA AUTOMOCIÓN**

**Autora: Noelia García García
Tutor: Raúl Poler Escoto**

Curso: 2015-2018

Resumen

El objetivo del Trabajo Fin de Máster (TFM) es la propuesta de una metodología genérica para la previsión de la demanda con modelos causales que incorporan variables explicativas (tanto internas como exógenas) y para la identificación de valores extraordinarios. El TFM comenzará con un análisis del estado del arte sobre el proceso de previsión de la demanda y los diferentes tipos de modelos de previsión existentes (especialmente los causales). La aportación del TFM será la propuesta de un modelo de previsión de demanda causal, que incorporan el tratamiento de variables explicativas de diferentes características y la identificación automática de valores extraordinarios, que serán incluidos en el modelo matemático. El modelo y metodología propuestos se validarán mediante experimentos con datos reales de una empresa del sector de soluciones de lavado para la automoción.

Palabras clave: Previsión de demanda, Modelo causal, Valores extraordinarios, Valores atípicos, Modelo de Prevision.

Abstract

The objective of the project (TFM) is the proposal of a generic methodology for the forecasting of the demand with causal models that incorporate causal variables (both internal and exogenous) and for the identification of outliers. The TFM will start with an analysis of the state of the art on the demand forecasting process and the different types of existing methodologies (especially the causal ones). The contribution of the TFM will be the proposal of one or several forecasting causal models, which incorporate the treatment of explanatory variables of different characteristics and the automatic identification of outliers, which will be included in the mathematical model. The proposed model and methodology will be validated by experiments with real data from a company in the car wash and care solutions sector.

Key words: Demand Forecasting, Causal model, Outliers, Forecasting model

Índice de ilustraciones

Ilustración 2-1. Proceso del método Delphi. En “Método Delphi para Pronósticos de Ventas”, 2015, en www.gestiondeoperaciones.net	15
Ilustración 2-2. Ciclo de vida del producto vs Matriz BCG. Limas, S. (2012). Marketing empresarial: dirección como estrategia competitiva [Ilustración]. Recuperado de www.researchgate.net	16
Ilustración 2-3. Ajuste de tendencias mediante regresión lineal. En “Cómo utilizar una Regresión Lineal para realizar un Pronóstico de Demanda”, 2014. Recuperado de www.gestiondeoperaciones.net	17
Ilustración 3-1. Modelo de Programación Lineal con Variables Explicativas. Poler (2017).	31
Ilustración 3-2. Modelo causal Líneas de Puentes de Lavado Automático y Línea de Lavado Automático de Vehículos	35
Ilustración 3-3. Modelo causal para la Línea de Túneles de Lavado Automático	36
Ilustración 3-4. Modelo causal para la Línea de Centros de Lavado.....	37
Ilustración 0-1. Puente de lavado automático ISTOBAL. Recuperado de www.istobal.com	40
Ilustración 0-2. Puente de lavado ISTOBAL M’S TART. Recuperado de www.istobal.com	41
Ilustración 0-3. Túnel de lavado ISTOBAL 4TC. Recuperado de www.istobal.com	42
Ilustración 0-4. Puente de lavado para vehículos industriales ISTOBAL HW’ PROGRESS. Recuperado de www.istobal.com	43
Ilustración 0-5. Centro de lavado ISTOBAL. Recuperado de www.istobal.com	43
Ilustración 0-6. Datos de demanda por línea (2014- 2017)	45
Ilustración 0-7. Gráfico de los datos de demanda por línea (2014- 2017).....	46
Ilustración 0-8. M3-Comp. Series 200, la deflación del método Theta.....	47
Ilustración 0-9. PrevGIP. Datos.....	49
Ilustración 0-10. PrevGIP. Modelo de previsión.....	50
Ilustración 0-11. PrevGIP. Tabla de previsión	51
Ilustración 0-12. PrevGIP. Tabla de previsión - valores sin utilizar	52
Ilustración 0-13. Demanda real y previsión pasada calculada a través del método Theta para la línea de Puentes de Lavado Automático.....	54
Ilustración 0-14. Demanda real y previsión futura calculada a través del método Theta para la línea de Puentes de Lavado Automático.....	55
Ilustración 0-15. Demanda real y previsión pasada calculada a través del método Theta para la línea de túneles de lavado automático	57
Ilustración 0-16. Demanda real y previsión futura calculada a través del método Theta para la línea de túneles de lavado automático	59
Ilustración 0-17. Demanda real y previsión pasada calculada a través del método Theta para la línea de lavado de vehículos industriales.....	61
Ilustración 0-18. Demanda real y previsión futura calculada a través del método Theta para la línea de lavado de vehículos industriales.....	62
Ilustración 0-19. Demanda real y previsión pasada calculada a través del método Theta para la línea de Centros de Lavado	65
Ilustración 0-20. Demanda real y previsión futura calculada a través del método Theta para la línea de Centros de Lavado	66

Ilustración 0-21. Gráfico de la tendencia para la línea de puentes.....	71
Ilustración 0-22. Gráfico de la estacionalidad para la línea de puentes	72
Ilustración 0-23. Comparación Demanda y Previsión 2014-2016. Línea de puentes	75
Ilustración 0-24. Tendencia 2017. Línea de Puentes de Lavado Automático	76
Ilustración 0-25. Comparación Demanda y Previsión 2017. Línea de puentes.....	79
Ilustración 0-26. Comparación del Error Porcentual del Método Theta y el Modelo Causal para la línea de Puentes de Lavado Automático	80
Ilustración 0-27. Gráfico de la tendencia para la línea de Túneles de Lavado Automático	81
Ilustración 0-28. Gráfico de la estacionalidad para la línea de Túneles de Lavado Automático. 82	
Ilustración 0-29. Comparación Demanda y Previsión 2014-2016 para la línea de túneles de lavado automático	85
Ilustración 0-30. Tendencia 2017. Línea de Túneles de Lavado Automático.....	86
Ilustración 0-31. Comparación Demanda y Previsión 2017. Línea de túneles de lavado automático	88
Ilustración 0-32. Gráfico de la tendencia para la línea de Túneles de Lavado Automático. Segundo Cálculo	89
Ilustración 0-33. Gráfico de la estacionalidad para la línea de Túneles de Lavado Automático. Segundo Cálculo	90
Ilustración 0-34. Comparación Demanda y Previsión 2014-2016. Línea de túneles de lavado automático. Segundo Cálculo.....	93
Ilustración 0-35. Tendencia 2017. Línea de Túneles de Lavado Automático. Segundo Cálculo .	94
Ilustración 0-36. Comparación Demanda y Previsión 2017 para la línea de túneles de lavado automático. Segundo Cálculo.....	96
Ilustración 0-37. Comparación Demanda y Previsión 2014-2016. Línea de túneles de lavado automático. Tercer cálculo.....	99
Ilustración 0-38. Comparación del Error Porcentual del Método Theta y el Modelo Causal para la línea de Túneles de Lavado Automático	100
Ilustración 0-39. . Gráfico de la tendencia para la línea de Lavado de Vehículos Industriales. 103	
Ilustración 0-40. Gráfico de la estacionalidad para la línea de Lavado de Vehículos Industriales	104
Ilustración 0-41. Comparación Demanda y Previsión 2014-2016. Línea de Lavado de Vehículos Industriales.....	107
Ilustración 0-42. Tendencia 2017. Línea de Lavado de Vehículos Industriales.....	108
Ilustración 0-43. Comparación Demanda y Previsión 2017. Línea de Lavado de Vehículos Industriales.....	110
Ilustración 0-44. Comparación del Error Porcentual del Método Theta y el Modelo Causal para la línea de Lavado de Vehículos Industriales.....	111
Ilustración 0-45. Gráfico de la tendencia para la línea de Centros de Lavado.....	114
Ilustración 0-46. Gráfico de la estacionalidad para la línea de Centros de Lavado	115
Ilustración 0-47. Demanda y Previsión 2014-2016 para la línea de Centros de Lavado	118
Ilustración 0-48. Tendencia 2017. Línea de Lavado de Vehículos Industriales.....	119
Ilustración 0-49. Comparación Demanda y Previsión 2017. Línea de Centros de Lavado	122
Ilustración 0-50. Gráfico de la estacionalidad para la línea de Centros de Lavado. Segundo Cálculo	124

Ilustración 0-51. Demanda y Previsión 2014-2016 para la línea de Centros de Lavado. Segundo Cálculo	127
Ilustración 0-52. Tendencia 2017. Línea de Centros de Lavado. Segundo Cálculo	128
Ilustración 0-53. Comparación Demanda y Previsión 2017 para la línea de Centros de Lavado. Segundo cálculo	130
Ilustración 0-54. Comparación del Error Porcentual del Método Theta y el Modelo Causal para la línea de Centros de Lavado	131

Índice de tablas

Tabla 4-1. Demanda real y previsión pasada calculada a través del método Theta para la línea de Puentes de Lavado Automático	53
Tabla 4-2. Error de ajuste medio del método Theta para la Línea de Puentes de Lavado Automático.....	54
Tabla 4-3. Demanda real y previsión futura calculada a través del método Theta para la línea de Puentes de Lavado Automático	55
Tabla 4-4. Error de acierto medio del método Theta para de la línea de Puentes de Lavado Automático.....	56
Tabla 4-5. Demanda real y previsión pasada calculada a través del método Theta para la línea de túneles de lavado automático.....	57
Tabla 4-6. Error de ajuste medio del método Theta para la línea de túneles de lavado automático	58
Tabla 4-7. Demanda real y previsión futura calculada a través del método Theta para la línea de túneles de lavado automático.....	58
Tabla 4-8. Error de acierto medio del método Theta para la línea de túneles de lavado automático	59
Tabla 4-9. . Demanda real y previsión pasada calculada a través del método Theta para la línea de puentes de lavado de vehículos industriales	60
Tabla 4-10. Error de ajuste medio del método Theta para la línea de lavado de vehículos industriales.....	61
Tabla 4-11. Demanda real y previsión futura calculada a través del método Theta para la línea de lavado de vehículos industriales	62
Tabla 4-12. Error de acierto medio del método Theta para la línea de lavado de vehículos industriales.....	63
Tabla 4-13. Demanda real y previsión pasada calculada a través del método Theta para la línea de Centros de Lavado.....	64
Tabla 4-14. Error de ajuste medio del método Theta para la línea de Centros de Lavado	65
Tabla 4-15. Demanda real y previsión futura calculada a través del método Theta para la línea de Centros de Lavado.....	66
Tabla 4-16. Error de acierto medio del método Theta para la línea de Centros de Lavado	67
Tabla 4-17. Variable explicativa (número de días laborables)	68
Tabla 4-18. Variable explicativa (modelos por fase de su ciclo de vida).....	70
Tabla 4-19. Valor de la tendencia para la línea de puentes.....	70
Tabla 4-20. Valor de la estacionalidad para la línea de puentes.....	71
Tabla 4-21. Valor de la previsión por días laborables para la línea de puentes	72
Tabla 4-22. Variable explicativa: número de modelos en estado de introducción.....	73
Tabla 4-23. Variable explicativa: número de modelos en estado de introducción.....	73
Tabla 4-24. Demanda y Previsión 2014-2016 para la línea de puentes.....	74
Tabla 4-25. Error de ajuste del modelo causal para la línea de Puentes de Lavado Automático.....	75
Tabla 4-26. Tendencia 2017. Línea de Puentes de Lavado Automático	76
Tabla 4-27. Valores de estacionalidad para 2017	77
Tabla 4-28. Variable explicativa (número de días laborables) para 2017	77

Tabla 4-29. Variable explicativa (modelos por fase de su ciclo de vida).....	78
Tabla 4-30. Demanda y Previsión 2017 para la línea de puentes	78
Tabla 4-31. Error de acierto del modelo causal para la línea de puentes.....	79
Tabla 4-32. Valor de la tendencia para la línea de Túneles de Lavado Automático	81
Tabla 4-33. Valor de la estacionalidad para la línea de túneles de lavado automático.....	82
Tabla 4-34. Valor de la previsión por días laborables para la línea de túneles de lavado automático	83
Tabla 4-35. Demanda y Previsión 2014-2016 para la línea de túneles de lavado automático ...	84
Tabla 4-36. Error de ajuste del modelo causal para la línea de túneles de lavado automático .	85
Tabla 4-37. Cálculo tendencia 2017. Línea de túneles de lavado automático.....	86
Tabla 4-38. Valores de estacionalidad para 2017. Línea de túneles de lavado automático.....	86
Tabla 4-39. Variable explicativa (número de días laborables) para 2017	87
Tabla 4-40. Demanda y Previsión 2017 para la línea de túneles de lavado automático	87
Tabla 4-41. Error de acierto del modelo causal para la línea de túneles de lavado automático	88
Tabla 4-42. Valor de la tendencia para la línea de túneles de lavado automático. Segundo Cálculo.....	89
Tabla 4-43. Valor de la estacionalidad para la línea de túneles de lavado automático. Segundo Cálculo.....	90
Tabla 4-44. Valor de la previsión por días laborables para la línea de Túneles de Lavado Automático. Segundo Cálculo.	91
Tabla 4-45. Valor de la previsión de la variable causal añadida para la línea de centros.....	91
Tabla 4-46. Demanda y Previsión 2014-2016 para la línea de Túneles de Lavado Automático. Segundo Cálculo	92
Tabla 4-47. Error de ajuste del modelo causal para la línea de túneles de lavado automático. Segundo Cálculo	93
Tabla 4-48. Cálculo tendencia 2017. Línea de túneles de lavado automático. Segundo Cálculo	94
Tabla 4-49. Valores de estacionalidad para 2017. Línea de Túneles de Lavado Automático. Segundo Cálculo	95
Tabla 4-50. Variable explicativa (número de días laborables) para 2017	95
Tabla 4-51. Demanda y Previsión 2017 para la línea de túneles de lavado automático. Segundo Cálculo	96
Tabla 4-52. Error de acierto del modelo causal para la línea de túneles de lavado automático. Segundo Cálculo	96
Tabla 4-53 Valor de la previsión de la variable causal añadida para la línea de centros.....	97
Tabla 4-54. Demanda y Previsión 2014-2016 para la línea de Túneles de Lavado Automático. Tercer cálculo	98
Tabla 4-55. Error de ajuste del modelo causal para la línea de túneles de lavado automático. Tercer cálculo	99
Tabla 4-56. Variable explicativa (modelos por fase de su ciclo de vida). Línea de Lavado de Vehículos Industriales	101
Tabla 4-57. Valor de la tendencia para la línea de Lavado de Vehículos Industriales	102
Tabla 4-58. Valor de la estacionalidad para la línea de Lavado de Vehículos Industriales	103
Tabla 4-59. Valor de la previsión por días laborables para la línea de Lavado de Vehículos Industriales.....	104
Tabla 4-60. Variable explicativa: número de modelos en estado de introducción.....	105

Tabla 4-61. Variable explicativa: número de modelos en estado de madurez.....	105
Tabla 4-62. Demanda y Previsión 2014-2016 para la línea de Lavado de Vehículos Industriales	106
Tabla 4-63. Error de ajuste del modelo causal para la línea de Lavado de Vehículos Industriales	107
Tabla 4-64. Cálculo tendencia 2017. Línea de Lavado de Vehículos Industriales	108
Tabla 4-65. Valores de estacionalidad para 2017. Línea de Lavado de Vehículos Industriales	109
Tabla 4-66. Variable explicativa (número de días laborables) para 2017	109
Tabla 4-67. Variable explicativa (modelos por fase de su ciclo de vida).....	109
Tabla 4-68. Demanda y Previsión 2017 para la línea de Lavado de Vehículos Industriales.....	110
Tabla 4-69. Error de acierto del modelo causal para la línea de Lavado de Vehículos Industriales	111
Tabla 4-70. Variable explicativa (número de modelos por periodo). Línea de Centros de Lavado	112
Tabla 4-71. Variables causales Tenders. Línea de Centros de Lavado	113
Tabla 4-72. Valor de la tendencia para la línea de centros	114
Tabla 4-73. Valor de la estacionalidad para la línea de centros.....	114
Tabla 4-74. Valor de la previsión por días laborables para la línea de centros	115
Tabla 4-75. Valor de la previsión por número de modelos para la línea de centros	116
Tabla 4-76. Valor de la previsión por Tenders para la línea de Centros de Lavado	116
Tabla 4-77. Demanda y Previsión 2014-2016 para la línea de centros.....	117
Tabla 4-78. Error de ajuste del modelo causal para la línea de centros	118
Tabla 4-79. Cálculo tendencia 2017. Línea de Centros de Lavado.....	119
Tabla 4-80. Valores de estacionalidad para 2017. Línea de Centros de Lavado	120
Tabla 4-81. Variable explicativa (número de días laborables) para 2017	120
Tabla 4-82. Valor de la previsión por número de modelos para la línea de centros	121
Tabla 4-83. Demanda y Previsión 2017 para la línea de Centros de Lavado	121
Tabla 4-84. Error de acierto del modelo causal para la línea de centros.....	122
Tabla 4-85. Valor de la tendencia para la línea de Centros de Lavado. Segundo Cálculo	123
Tabla 4-86. Gráfico de la tendencia para la línea de Centros de Lavado. Segundo Cálculo	123
Tabla 4-87. Valor de la estacionalidad para la línea de Centros de Lavado. Segundo Cálculo .	124
Tabla 4-88. Valor de la previsión por días laborables para la línea de Centros de Lavado. Segundo Cálculo	125
Tabla 4-89. Valor de la previsión por número de modelos para la línea de Centros de Lavado	125
Tabla 4-90. Valor de la previsión de la variable causal añadida para la línea de centros.....	125
Tabla 4-91. Demanda y Previsión 2014-2016 para la línea de centros 2	126
Tabla 4-92. Error de ajuste del modelo causal para la línea de centros. Segundo Cálculo	127
Tabla 4-93. Cálculo tendencia 2017. Línea de Centros de Lavado. Segundo Cálculo	128
Tabla 4-94. . Valor de la estacionalidad para 2017 para la línea de Centros de Lavado. Segundo Cálculo	129
Tabla 4-95. Valor de la previsión por número de modelos para 2017 para la línea de Centros de Lavado. Segundo cálculo	129
Tabla 4-96. Demanda y Previsión 2017 para la línea de Centros de Lavado. Segundo cálculo	129
Tabla 4-97. Error de acierto del modelo causal para la línea de centros. Segundo cálculo	130

Contenido

Resumen.....	1
Abstract	2
Índice de ilustraciones.....	3
Índice de tablas	6
1 Objeto del proyecto	11
2 Introducción	12
2.1 Métodos de previsión de demanda	13
2.1.1 Métodos de previsión de demanda bajo un enfoque cualitativo	13
2.1.2 Métodos de previsión de demanda bajo un enfoque cuantitativo	16
2.2 Fiabilidad de los métodos de previsión.....	25
2.2.1 Corrección de series temporales. Identificación de valores atípicos.....	28
3 Modelo de programación matemática	30
3.1 Datos de entrada.....	30
3.2 Modelo matemático.....	30
3.2.1 Definición del modelo	31
3.2.2 Modelado matemático.....	34
3.2.3 Adaptación del modelo	34
3.3 Datos de salida. Cálculo de las previsiones futuras	37
4 Aplicación práctica a una empresa real	39
4.1 Introducción.....	39
4.1.1 La empresa	39
4.1.2 Líneas de producción.....	40
4.1.3 Datos proporcionados.....	44
4.2 Cálculo de las previsiones. Método Theta.	47
4.2.1 Línea de Puentes de Lavado Automático	52
4.2.2 Línea de Túneles de Lavado Automático.....	56
4.2.3 Línea de Lavado de Vehículos Industriales.....	59
4.2.4 Línea de Centros de Lavado	63
4.2.5 Conclusiones. Aplicación del método Theta.	67
4.3 Cálculo de las previsiones. Modelo Causal.	67
4.3.1 Línea de lavado automático de puentes	69

4.3.2	Línea de túneles de lavado automático	80
4.3.3	Línea de Lavado de Vehículos Industriales.....	100
4.3.4	Línea de Centros de Lavado	112
4.3.5	Conclusiones. Aplicación del Modelo Causal.	131
5	Conclusiones y futuras líneas de investigación	132
6	Referencias y bibliografía	133

1 Objeto del proyecto

El presente proyecto tiene como objetivo desarrollar una metodología para el cálculo de previsiones a través de un Modelo Causal, buscar nuevas variables explicativas, identificadas gracias a la aparición de valores extraordinarios en los cálculos de los errores de ajuste y mejorar progresivamente tanto el modelo como su fiabilidad gracias a la inclusión de dichas variables.

La metodología se ha aplicado a una empresa del sector de soluciones de lavado para la automoción. Con ello se pretende mejorar el sistema de cálculo y fiabilidad de las previsiones de la compañía, que actualmente es fundamental para la planificación del suministro de materias primas, piezas de proveedor y submontajes subcontratados.

El resto del documento se estructura de la siguiente forma. En primer lugar se hace un pequeño resumen de los métodos de pronóstico más utilizados actualmente y las formas más comunes de evaluar su fiabilidad. A continuación se presenta la forma general del modelo de previsión desarrollado en el proyecto así como los datos proporcionados por la empresa que servirán para la realización del análisis práctico. Seguidamente se realizan las previsiones de venta para estas cuatro líneas a través tanto del Método Theta y como del Modelo Causal desarrollado, comparando los resultados y exponiendo, finalmente, las conclusiones deducidas del estudio y futuras líneas de investigación.

2 Introducción

Para la mayoría de las empresas conseguir una cadena de suministro eficiente que optimice costes y mejore el servicio al cliente es algo primordial y que consume una gran cantidad de recursos. Sin embargo, la consecución de este objetivo está determinado, en su mayoría, por las decisiones que los responsables de cada uno de sus departamentos va tomando. ¿Y cómo puede la organización asegurarse de que éstos toman las decisiones acertadas? Una buena base para ello es disponer de una correcta previsión de la demanda. Ello permitirá que cada parte de la organización disponga de información adecuada y fiable que le permita anticiparse a las situaciones venideras y poder estar preparada cuando se presenten.

Por lo tanto puede definirse la previsión de la demanda como el conjunto de actividades destinadas a realizar las estimaciones, cuantitativas o cualitativas, de las ventas futuras de la compañía con el objetivo de proporcionar información útil que pueda ser utilizada en la toma de decisiones. Por ejemplo, puede ser primordial para definir aspectos como:

- Políticas de compra, búsqueda de acuerdos con proveedores.
- Tamaños de lote para la fabricación.
- Nivel de existencias óptimo del almacén.
- Pautas de comportamiento ante promociones, periodos estacionales o cualquier otra tipología de evento...
- Necesidades de transporte.
- Compra de maquinaria.
- Contratación de personal.
- Asignación de tareas
- ...

La toma de este tipo de decisiones y, sobre todo, su puesta en marcha lleva un tiempo del que normalmente no se dispone. Por lo tanto, obtener unas buenas previsiones ayudará a la empresa a anticiparse, colaborando en la toma de unas decisiones más acertadas. Además se obtendrán múltiples ventajas y mejoras, como por ejemplo:

- Disminución de los niveles de inventario.
- Disminución del inmovilizado del capital en forma de productos y materia prima almacenada.
- Generación de menos obsoletos dentro del almacén.
- Menos roturas de stock.
- Mejora de la relación con proveedores.
- Aumento de las ventas.
- Aumento de la calidad del servicio.
- Aumento de la satisfacción del cliente.
- Mejora del rendimiento de los recursos productivos.

También es necesario destacar que la previsión de la demanda puede tener un carácter informativo sobre, por ejemplo, la eficiencia de las campañas publicitarias, eventos de

merchandising, promociones... o cualquier hecho que la empresa (o incluso el entorno) pueda provocar. Este enfoque puede proporcionar una alerta de que alguna de estas actuaciones no está teniendo el impacto esperado por lo que se podrá detectar y corregir más rápidamente.

Con ello la empresa podría pasar de simplemente calcular las previsiones en base a históricos a influir en ellas de forma directa dando la herramienta para provocar el aumento o disminución de la demanda según su interés y de reaccionar ante resultados no deseados.

Existen multitud de métodos y herramientas para realizar pronósticos de demanda, desde los más básicos a los más complejos. Los más destacados se exponen a continuación.

2.1 Métodos de previsión de demanda

La previsión de la demanda es una de las mayores fuentes de incertidumbre que existen dentro de una organización. De hecho, históricamente, no ha tenido una gran participación dentro de ellas ya que muchas, ni siquiera las calculan y otras, lo hacen con métodos muy básicos. Sin embargo, a lo largo del tiempo se han ido desarrollando multitud de técnicas para poder calcular unas previsiones lo más acertadas posibles.

En primer lugar, las previsiones pueden tener dos enfoques muy diferentes:

- Enfoque cualitativo: se basan en la intuición, experiencia y opinión de expertos, tomadores de decisiones, concededores del mercado...
- Enfoque cuantitativo: se basan en modelos matemáticos utilizando datos objetivos.

La utilización de un enfoque u otro vendrá determinada por la naturaleza, tanto del producto para el que se desea estimar la previsión, como del mercado en que se encuentre. En este sentido, se utilizan las técnicas cualitativas en mercados nuevos, con aplicación de nuevas tecnologías, en lanzamientos de nuevos productos... donde no se dispone de datos históricos sobre los cuales basar la previsión. Por tanto, el enfoque cuantitativo se empleará cuando sí se tenga información sobre las ventas pasadas, el entorno sea más estable y se trate de productos que ya lleven un cierto tiempo en el mercado.

A continuación se exponen algunos de los métodos más utilizados de ambos enfoques.

2.1.1 Métodos de previsión de demanda bajo un enfoque cualitativo

Estas técnicas se basan en interpretaciones, observaciones u opiniones de los sujetos encargados de realizar las previsiones. Con ellas se puede obtener un orden de magnitud aproximado de la demanda que se podría esperar. Se utilizan cuando no se dispone de datos históricos, cuando se desea obtener un valor aproximado de forma rápida o cuando,

simplemente, no se dispone de recursos para invertir en la aplicación otras técnicas. A continuación se exponen algunas de las más utilizadas.

Jurado de opinión ejecutiva

Se basa en realizar una estimación de la demanda basada en la opinión, experiencia y conocimientos técnicos de los altos mandos. En González (2011) se presenta como una técnica de fácil aplicación y bajo coste ya que consiste en la celebración de una reunión en la que el grupo expone, discute y toma decisiones de forma rápida. Sin embargo, también se señala una desventaja, lo que se conoce como “pensamiento en grupo”, el cual puede provocar la toma de decisiones irracionales a causa de la influencia desigual de las opiniones de los miembros del equipo.

Método DELPHI

Es una técnica de obtención de pronósticos basada en la discusión de expertos a través de un proceso iterativo. En González (2011) se señala su ventaja principal, a saber, se intenta sacar provecho del conocimiento de expertos minimizando el inconveniente del “pensamiento en grupo”, que tenía el método del jurado de opinión ejecutiva. Además, el autor lo describe como un método donde existen tres tipos de roles: los encargados de tomar decisiones, el personal de plantilla y los expertos, que responderán a los cuestionarios. Para llevarlo a cabo, una vez definidos los objetivos y seleccionado a los expertos, el personal de plantilla plantea una serie de preguntas, de interés para los tomadores de decisiones, que los expertos participantes deben responder de manera anónima. Una vez hecho esto, los encargados de tomar decisiones evalúan las respuestas y se realiza un segundo cuestionario, con las mismas preguntas o incluyendo alguna nueva. En este segundo cuestionario se informa a los expertos sobre la opinión media del equipo en la primera vuelta pidiendo que, en caso de tener una opinión que diste mucho de la general, justifiquen su respuesta del cuestionario anterior o, si lo prefieren, cambien su contestación, también de forma justificada. De este modo, las respuestas se van depurando progresivamente permitiendo obtener una información lo más objetiva posible.

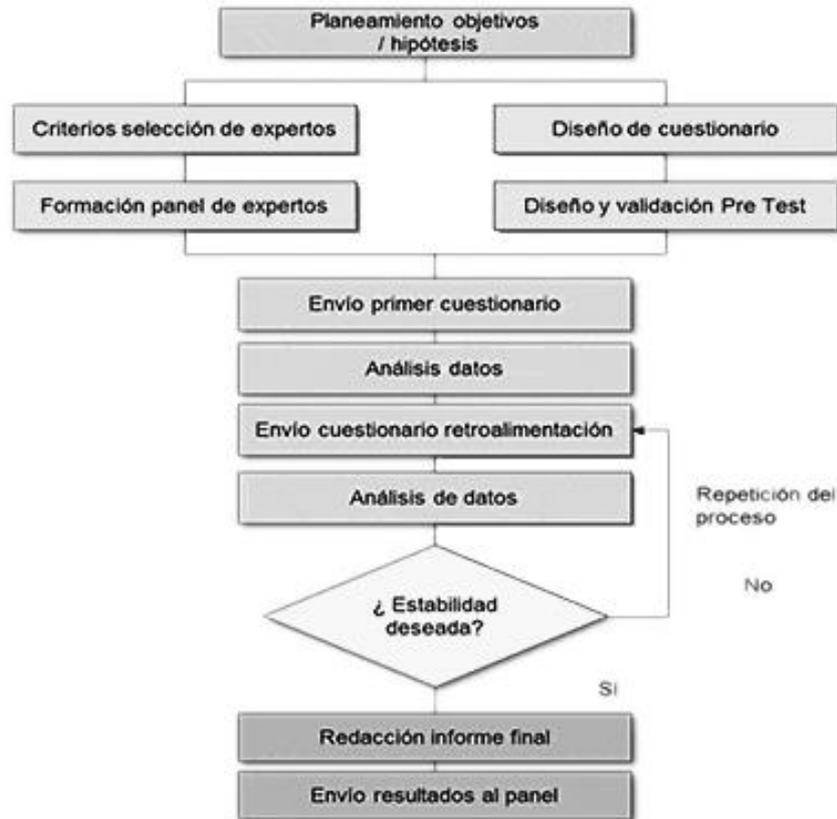


Ilustración 2-1. Proceso del método Delphi. En “Método Delphi para Pronósticos de Ventas”, 2015, en www.gestiondeoperaciones.net

Propuesta del personal de ventas

Es una estimación realizada por los vendedores o comerciales, los cuales tienen conocimientos tanto del mercado en sí como de las necesidades y comportamientos de los consumidores. En González (2011) se describe como un método que permite poder realizar un pronóstico bastante certero aunque normalmente tiende a ser optimista.

Estudio de mercado

Se basa en el estudio de las opiniones, percepciones o respuestas ante el producto de una muestra representativa del público objetivo. En González (2011) se define este método como costoso de realizar ya que se necesita diseñar con precisión el cuestionario, de lo contrario se pueden obtener datos inadecuados para conseguir unas buenas previsiones, ya sea porque las preguntas no eran las adecuadas, porque induzcan a confusión a quienes han de responderlas, no sigan el orden adecuado...

Método del Ciclo de Vida del Producto

Se trata de estimar la demanda futura de un producto dependiendo de la fase de su ciclo de vida en la que se encuentre: introducción, crecimiento, madurez o declive.

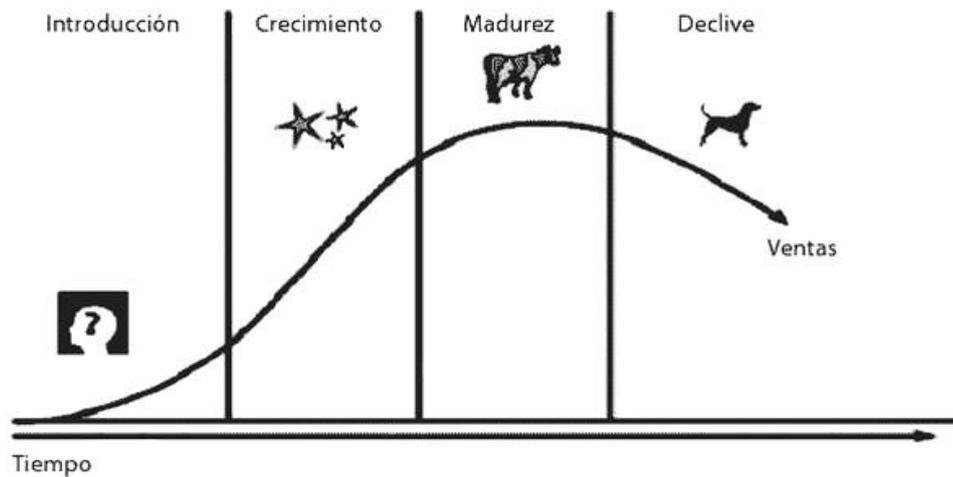


Ilustración 2-2. Ciclo de vida del producto vs Matriz BCG. Limas, S. (2012). Marketing empresarial: dirección como estrategia competitiva [Ilustración]. Recuperado de www.researchgate.net

La fase de introducción es la primera por la que pasa un producto, una vez es lanzado al mercado. En él las ventas son bajas y, conforme va siendo más conocido por el consumidor se espera que su demanda empiece a aumentar. En la fase de crecimiento el producto ya ha sido aceptado en el mercado y las ventas suben rápidamente hasta alcanzar el nivel de madurez. Una vez en este punto la demanda se estabiliza, los esfuerzos se centran en disminuir costes en lugar de lograr cuota de mercado y se obtienen beneficios hasta que comienza la fase de declive. En ella, el producto comienza a ser menos demandado, suelen bajar los precios hasta que las ventas se extinguen o se hace un relanzamiento, haciendo modificaciones, rediseños, etc.

La clasificación de los productos según la fase del ciclo de vida en la que se encuentren puede ayudar a realizar unas previsiones coherentes con el comportamiento del mercado.

2.1.2 Métodos de previsión de demanda bajo un enfoque cuantitativo

En Poler (2017) se hace una revisión de los métodos más destacados bajo un enfoque cuantitativo, basados en extrapolación del comportamiento pasado hacia el futuro. Para aplicarlos es necesario disponer de suficientes datos históricos que demuestren la existencia de patrones de comportamiento de la demanda. El autor señala dos tipologías, los basados en el análisis estadístico de series temporales y los basados en el establecimiento de variables causales.

2.1.2.1 Métodos de previsión basados en series temporales

El primer grupo, se basa en la extrapolación del comportamiento pasado hacia el futuro y son métodos considerados reactivos. Existen tres tipos:

2.1.2.1.1 Métodos de proyección de tendencias

Ajuste de tendencias

En Poler (2017) se describe el Ajuste de Tendencias como un método basado en el análisis de series temporales y el cálculo de sus proyecciones hacia el futuro a través de cálculos de regresión, minimización de los errores cuadráticos, etc. De este modo se obtienen modelos de tendencias lineales, exponenciales, logarítmicas, potenciales, etc.

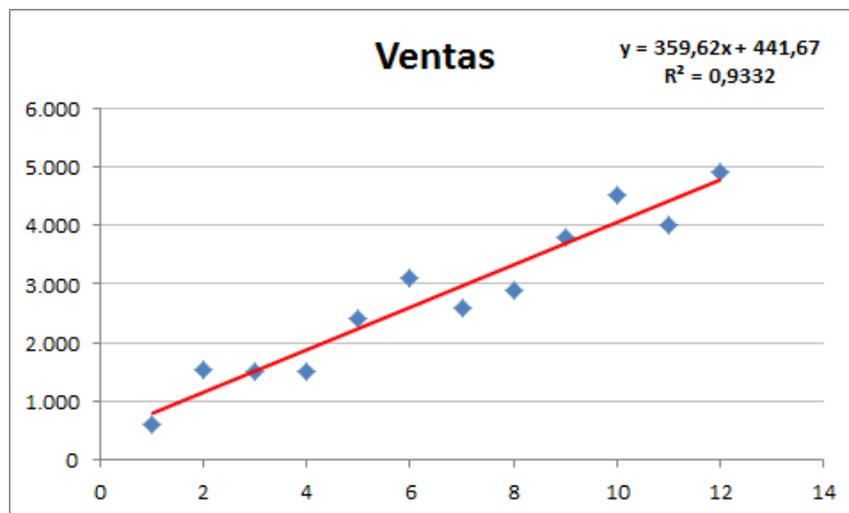


Ilustración 2-3. Ajuste de tendencias mediante regresión lineal. En “Cómo utilizar una Regresión Lineal para realizar un Pronóstico de Demanda”, 2014. Recuperado de www.gestiondeoperaciones.net

2.1.2.1.2 Métodos de suavizado

Suavizado por medias móviles

Poler (2017) se identifica como un método adecuado cuando la demanda no presenta una tendencia marcada y no existe estacionalidad. Su formulación matemática es la siguiente:

$$Y_{t+1} = \frac{1}{N} \sum_{i=t-N+1}^t X_i$$

Donde la demanda pronosticada para el periodo t+1 (Y_{t+1}) es la media de las demandas reales de los N periodos anteriores.

Suavizado exponencial

Es utilizado para pronosticar patrones de demanda aleatorios (sin tendencia ni estacionalidad) permitiendo dar pesos distintos a las demandas de diferentes periodos (Poler, 2017).

$$Y_{t+1} = (1-\alpha)Y_t + \alpha X_t$$

Donde,

Y_{t+1} es el valor del pronóstico para el siguiente periodo t .

α es conocido como factor de alisamiento y toma valores entre 0 y 1.

Y_t es el valor del pronóstico para el anterior periodo t .

X_t es valor de la demanda para el periodo t .

Este método es relativamente fácil de utilizar y no se necesita una gran cantidad de datos para aplicarse pero es necesario elegir un valor de α adecuado.

Método de Holt

El método de Holt suaviza la tendencia obteniendo la diferencia entre el valor de la demanda para dos periodos consecutivos. Es adecuado cuando la demanda está dotada de tendencia y continua siendo no estacional (Poler, 2017). Este método permite obtener el número de datos pronosticados que se desee no tan solo el valor de $t + 1$.

$$Y_{t+1} = L_t + T_t$$

$$L_t = \alpha X_t + (1-\alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1}$$

$$Y_{N+k} = L_n + kT_n$$

Donde,

Y_{t+1} es el valor del pronóstico para el siguiente periodo t .

T_t es la tendencia

L_t es el nivel, T_t la tendencia.

α es el factor de alisamiento del nivel.

β es el factor de alisamiento de la tendencia.

X_t es valor de la demanda para el periodo t .

Y los valores iniciales son:

$$T_o = \frac{X_N - X_1}{N-1} \quad \gamma \quad L_o = X_1 - \frac{T_o}{2}$$

Método de Holt-Winters

El método de Holt-Winters es similar al anterior pero permite calcular previsiones cuando se dispone de una serie temporal que, además de tendencia, tiene estacionalidad (Poler, 2017). Para ello incluye un tercer factor de alisamiento γ .

$$Y_{t+1} = (L_t + T_t)S_{t+1-c}$$

$$L_t = \alpha \frac{X_t}{S_{t-c}} + (1-\alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \beta(L_t + L_{t-1}) + (1-\beta)T_{t-1}$$

$$S_t = \gamma \frac{X_t}{L_t} + (1-\gamma)S_{t-c}$$

$$Y_{N+k} = (L_n + kT_N)S_{N+k-c}$$

Donde,

Y_{t+1} es el valor del pronóstico para el siguiente periodo t .

T_t es la tendencia

L_t es el nivel, T_t la tendencia.

S_t es la estacionalidad ($S_{1..c}$ se obtiene por descomposición).

α es el factor de alisamiento del nivel.

β es el factor de alisamiento de la tendencia.

γ es el factor de alisamiento de la estacionalidad.

X_t es valor de la demanda para el periodo t .

Los valores iniciales son:

$$T_o = \frac{m_p - m_1}{(p-1)c} \quad \gamma \quad L_o = m_1 - \frac{c}{2}T_o$$

2.1.2.1.3 Métodos de descomposición de series temporales

Estos métodos se basan en la observación de una variable a lo largo del tiempo, analizar su comportamiento y crear un modelo que lo describa y que pueda ser utilizado para extrapolar dicha variable hacia el futuro. Este tipo de modelos son especialmente útiles cuando no se dispone de mucha información. Existen varios métodos:

Descomposición Aditiva

Presuponen que la previsión de un periodo puede considerarse como la agregación de cuatro componentes: tendencia, ciclicidad y estacionalidad (Poler, 2017). Se expresa de la siguiente forma:

$$Y_t = T_t + E_t + C_t$$

Donde,

Y_t es el valor del pronóstico para el siguiente periodo t .

T_t es la componente de la tendencia, considerada como el movimiento general de la serie a largo plazo.

E_t representa la estacionalidad, es decir, oscilaciones periódicas que se repite cada año.

C_t es la ciclicidad, fluctuaciones que se repiten a periodos más largos.

Descomposición multiplicativa

Expresa la previsión como la multiplicación de las variables de tendencia, estacionalidad y ciclicidad (Poler, 2017).

$$Y_t = T_t \cdot E_t \cdot C_t$$

Donde,

Y_t es el valor del pronóstico para el siguiente periodo t .

T_t es la componente de la tendencia, considerada como el movimiento general de la serie a largo plazo;

E_t representa la estacionalidad, es decir, oscilaciones periódicas que se repite cada año;

C_t es la ciclicidad, fluctuaciones que se repiten a periodos más largos.

Método Theta

Determina que el valor de la previsión es el resultado de la suma de varias curvas, denominadas líneas theta. Para el caso más sencillo, descomponiendo la previsión en dos únicas líneas, éstas se corresponden con la regresión lineal de los puntos desestacionalizados y con el lisaje de la parte no explicada por la primera (Poler, 2014 en PrevGIP, vers. 2014 A). Se expresa de la siguiente forma:

$$Y_t = \frac{LR_t + LE_t}{2} E_t$$

$$D_t = \frac{X_t}{E_t}$$

$$L_t = 2D_t - LR_t$$

$$LE_{t+1} = LE_t + \alpha (D_t - LE_t)$$

Donde,

Y_t es el valor del pronóstico para el periodo t .

X_t es el valor de la demanda observada para el periodo t .

α es el factor de alisamiento.

E_t es el factor estacional.

D_t es la serie desestacionalizada.

LR_t es la regresión lineal sobre los puntos de la serie desestacionalizada.

L_t es la diferencia entre el doble de la serie desestacionalizada y la línea LR_t .

LE_t es el lisaje exponencial simple de la línea L_t .

2.1.2.2 Métodos causales

Los métodos causales están basados en la identificación de variables explicativas que influyan en el comportamiento del consumidor o del comportamiento de la cadena de suministro en general. Al contrario, que los basados en series temporales, son considerados proactivos ya que, en lugar de reaccionar ante lo que ocurrió en el pasado, son capaces de anticiparse a los eventos futuros, incluyendo en los cálculos de las previsiones la influencia esperada de las variables causales que afectarán al horizonte de estudio.

Los modelos causales asumen, por tanto, que las variables causales y sus relaciones son conocidas y pueden ser expresadas matemáticamente, pero en muchos casos esto no es posible. De este modo, las series temporales suelen estar sujetas a eventos incontrolados o inesperados. Si estos eventos son conocidos, el planificador de demanda será capaz de tener en cuenta sus efectos e intervenciones dentro de la serie temporal. Sin embargo, si estos eventos son desconocidos serán necesarios otros modos de identificarlos y ajustarlos.

En este sentido, en Hoyos y Poler (2013) se propone una metodología para la previsión de la demanda con modelos causales. Se plantean dos métodos para identificar la existencia variables que afectan a la demanda en ausencia de información. Uno de ellos basado en la exploración y análisis de la interdependencia de las variables a través de la estructura de los datos y otro basado en un análisis estadístico a través de valores anómalos del error de pronóstico al aplicar el método de previsión.

En Allen and Fildes (2001) se demuestra que los métodos de previsión basados en modelos causales, cuando se dispone de buena información, ofrecen resultados más exactos que otras metodologías (Amstrong, 2006). Esto es debido, en parte, a que son capaces de incluir en los cálculos información referente a decisiones gubernamentales, fluctuaciones de los precios de compra y venta, promociones, climatología... que no son consideradas por otras metodologías. Esta cualidad se hace significativa, tal como se señala en Amstrong (2006), cuando se tiene información de calidad y existe una fuerte relación entre la variable dependiente y la variable causal. Por tanto, el rendimiento de los modelos causales depende, en gran medida, de la disponibilidad y fiabilidad de las variables, y requiere una inversión elevada de recursos en la recopilación de los datos.

En los siguientes apartados se hace una recopilación sobre los más utilizados.

2.1.2.2.1 Métodos de regresión

Se basan en suponer una relación de dependencia entre la variable previsión y una variable independiente o variable explicativa.

Regresión simple

Es el caso más simple para un método de regresión lineal, en el que una variable dependiente se relaciona directamente con una variable explicativa a través de una recta.

Regresión múltiple

En este caso, la variable dependiente se relacionará con más de una variable explicativa de modo que se buscará determinar la correlación lineal de cada una de ellas con la variable dependiente con el objetivo de obtener los valores de pronóstico buscados.

2.1.2.2.2 Métodos ARIMA

Los modelos ARIMA definen la previsión como una función lineal de los valores pasados y errores de pronóstico. Están basados en modelos matemáticos potentes que, bien diseñados, proporcionan una gran exactitud pero implican un alto coste en cuanto a software y personal cualificados. En Gaynor & Kirkpatrick (1994) se definen como métodos iterativos autorregresivos que integran medias móviles, se ajustan por factores estacionales y de tendencias, ajustan los pesos de cada parámetro, testean el modelo y repiten el proceso en caso de proceder. En este sentido, en Box and Jenkins (1970), donde se desarrollaron, se proponía el seguimiento de estos pasos:

- a) Identificación, donde se examinan las características y datos estadísticos de la serie temporal intentando relacionarlos con modelos específicos.
- b) Estimación, donde se estiman los parámetros provisionales que definen el modelo, considerando los datos disponibles.
- c) Chequeo del diagnóstico, donde se examina el modelo de estimación y su ajuste para comprobar si el modelo es consecuente con las conjeturas que se han tomado.

En Newbold & Granger (1974) se señala la importancia de disponer tanto de los recursos oportunos como de la experiencia necesaria para poder obtener unos buenos resultados aplicando modelos ARIMA.

Por otro lado, los modelos ARIMA no son únicos, sino que constituyen familia, entre los cuales en Box & Jenkins (1970) se proporciona al analista una guía para elegir el más apropiado en cada caso (Pankratz, 2009). En este sentido, existen diferentes versiones de estos modelos, de los cuales los más utilizados se señalan a continuación.

Modelos auto-regresivos (AR)

Los modelos que tan solo consideran la parte autorregresiva se denominan AR(p), siendo p el orden del modelo. . En De Arce & Mahía (2003) se definen como modelos en los que la variable tiempo es explicada por una combinación lineal de sus valores pasados añadiendo un término de error. La expresión genérica de un método autorregresivo de orden p es la siguiente:

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + a_t$$

Donde,

Y_t es el valor del pronóstico para el periodo t.

a_t es el término del error.

$\varphi_0, \dots, \varphi_p$ son los parámetros pertenecientes a la parte autorregresiva.

Modelos de medias móviles (MA)

Un modelo de medias móviles, MA(q), explica el valor de la variable dependiente en función de un término independiente y una sucesión de errores correspondientes a períodos precedentes ponderados convenientemente (De Arce & Mahía, 2003). Un modelo MA de orden q puede expresarse como:

$$Y_t = \theta_0 + a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q}$$

Donde,

Y_t es el valor del pronóstico para el periodo t.

a_t es el término del error.

$\theta_0, \dots, \theta_p$ son los parámetros pertenecientes a la parte de medias móviles.

Modelos auto-regresivos de medias móviles (ARMA)

La combinación de los modelos AR con MA da lugar a los modelos de medias móviles autorregresivos. Se representan como:

$$Y_t = \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

Donde,

Y_t es el valor del pronóstico para el periodo t.

a_t es el término del error.

$\varphi_0, \dots, \varphi_p$ son los parámetros pertenecientes a la parte autorregresiva.

$\theta_0, \dots, \theta_p$ son los parámetros pertenecientes a la parte de medias móviles.

Modelos ARIMA

Cuando se aplica un modelo ARMA (p,q) a una serie integrada de orden d, se obtiene un modelo ARIMA (p,d,q) o modelo autorregresivo integrado de media móvil.

$$Z_t = \varphi_0 + \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q}$$

Modelos estacionales SARIMA

Los modelos ARIMA estacionales se representan por las siglas SARIMA (seasonal autoregressive integrated moving average)

Modelos ARIMA con variables explicativas (ARIMAX)

Estos modelos consideran además el impacto de determinadas variables que afectan la demanda como días laborables, festivos, factores económicos o de negocios, etc.

2.1.2.2.3 Métodos de espacios de estado

Modelos de filtro de Kalman

El filtro de Kalman es un algoritmo desarrollado por R.E. Kalman en 1960. Su objetivo es calcular el estimador óptimo del vector de estados en un instante determinado, basándose para ello en la información disponible por las observaciones realizadas hasta ese momento (Quesada, 2002). El filtro de Kalman permite además obtener estimaciones de los distintos componentes inobservables que conforman una serie temporal (Ruíz, 1997).

Modelos de componentes inobservables

Los componentes que habitualmente suelen dominar la evolución de las series económicas son el componente tendencial, el estacional, el cíclico y el componente irregular. Dichos componentes se han modelizado tradicionalmente de forma determinista. Sin embargo, cuando las series temporales son suficientemente largas, parece razonable suponer que los componentes pueden evolucionar aleatoriamente en el tiempo (Ruíz, 1997).

En este sentido, se define un componente inobservable como aquel que necesita ser extraído de la serie temporal para poder ser observado. Por tanto, los modelos de componentes inobservables son aquellos basados en la descomposición de una serie temporal en sus diferentes componentes inobservables. Para ello pueden ser utilizados programas econométricos como TRAMO-SEATS y X11 y X12-ARIMA, que permiten tratar simultáneamente gran número de series temporales.

2.1.2.2.4 Métodos de inteligencia artificial

Modelos de redes neuronales artificiales

Los modelos de redes neuronales artificiales están basados en los sistemas biológicos del cerebro humano, estos sistemas son capaces de aprender y generalizar a través de la experiencia (Zhang et al, 1998).

Su mayor ventaja es que son capaces de realizar previsiones sobre un modelo no lineal. Es más, el modelo se forma adaptándose al comportamiento que presentan de los datos a lo largo del tiempo (Zhang, 2001). Por otro lado su formulación es bastante complicada ya que pueden existir muchos modelos no-lineales posibles y podrían no ser capaces de englobar todas las características necesarias (Zhang et al, 1998).

2.2 Fiabilidad de los métodos de previsión

En la aplicación, a una determinada serie temporal, de cualquiera de los anteriores mencionados métodos de previsión, aparecerá siempre un cierto grado de error. Es decir, los modelos tratarán de ajustarse lo máximo posible a los valores de demanda alcanzados en los históricos, y prever los de los periodos futuros, pero nunca llegarán a acertarlos completamente. Por tanto, el objetivo principal de cualquier cálculo de previsiones habrá de ser, precisamente, la minimización de dicho error. Ello permitirá comparar los diferentes métodos, elegir el más adecuado en cada caso y cuantificar la fiabilidad de las previsiones que se realizan.

En este sentido, el error de las previsiones no es más que la diferencia entre el valor pronosticado y el valor real. Existen dos tipologías de errores cuando se analiza un método de previsión de demanda:

- Error de ajuste o error in-sample, que indica cómo prevé el método los valores de demanda pasados.
- Error de acierto o out-of-sample, que indica como prevé el modelo los valores de demanda futuros.

Para evaluarlos se dispone de diferentes indicadores. En Shcherbakov et al. (2013) se hace una clasificación de los más importantes:

Medidas de errores de pronóstico absolutas

Se basan en el cálculo de un valor absoluto del error entendido como la diferencia entre el valor real y el previsto, $e_t = (X_t - Y_t)$. Los más utilizados son:

- MAE (Mean Absolute Error) / MAD (Mean Absolute Deviation), error medio absoluto:

$$MAD = \frac{1}{n} \sum_{t=1}^n |e_t|$$

- MdRAE (Median Relative Absolute Error), error relativo medio absoluto:

$$MdRAE = \text{Mediana}|e_t|$$

- MSE (Mean Square Error), error cuadrático medio:

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

- RMSE (Root Mean Square Error), raíz del error cuadrático medio:

$$RMSE = \sqrt{MSE}$$

Estas mediciones del error son los más populares en muchos campos, sin embargo, tienen varios inconvenientes:

- Su valor es dependiente del orden de magnitud de los datos. Además no se podría aplicar si se tuvieran datos en diferentes escalas o dimensiones.
- Son muy influenciados por los outliers.
- El RMSE y MSE tienen una baja fiabilidad ya que los resultados pueden variar dependiendo de los datos tomados.

Medidas de errores de pronóstico porcentuales

Se basan en la obtención de un porcentaje, que represente el error cometido en las previsiones, es decir, $p_t(\%) = |e_t|/X_t$. Los más comunes son:

- MAPE (Mean Absolute Percentage Error), error medio absoluto porcentual:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|e_t|}{X_t} 100$$

- MdAPE (Median Absolute Percentage Error), mediana del error absoluto porcentual:

$$MdAPE = \text{Mediana} \left(100 \cdot \frac{|e_t|}{X_t} \right)$$

- RMSPE (Root Mean Square Percentage Error), raíz del error cuadrático medio porcentual:

$$RMSPE = \sqrt{\text{Mean} \left(100 \frac{|e_t|}{X_t} \right)^2}$$

- RMdSPE (Median Percentage Error of the Quadratic), mediana del error cuadrático porcentual:

$$RMdSPE = \sqrt{\text{Median}\left(100 \frac{|e_t|}{X_t}\right)^2}$$

Las mediciones del error basadas en porcentaje son las más utilizadas dentro del campo de las previsiones. Sin embargo, también tienen algunas desventajas, como por ejemplo:

- Tienen un valor indeterminado cuando el valor de la demanda real es igual a cero.
- No son simétricos, es decir, el valor del error varía cuando se produce por encima o por debajo del valor real.
- Son muy sensibles a la influencia de los outliers.
- Las mediciones del error son parciales lo que puede conllevar a una incorrecta evaluación del rendimiento del modelo.

Medidas del Error de pronóstico simétricas

El cálculo de errores de esta clase se basa en el cálculo del valor $s_t(\%) = \frac{|e_t|}{(X_t + Y_t)}$

- sMAPE (Symmetric Mean Absolute Percentage Error), error medio absoluto porcentual simétrico:

$$sMAPE = \frac{1}{n} 2 \sum_{t=1}^n \frac{|e_t|}{|X_t + Y_t|} 100$$

- sMdAPE (median mean absolute percentage error), mediana del error absoluto porcentual simétrico:

$$sMdAPE = \text{median}\left(200 \frac{|e_t|}{|X_t + Y_t|}\right)$$

Además existe una versión modificada del sMAPE, el msMAPE, que pretende evitar el problema asociado al cálculo del error cuando la demanda real es igual a cero.

Estas medidas se caracterizan por:

- A pesar de su nombre, son también no-simétricas.
- Dan como resultado un error cuando el valor de la previsión es igual al de la demanda real pero de signo contrario.
- Son igualmente sensibles a la presencia de outliers.
- Al utilizar un método de previsión complejo, su interpretación se complica por lo que su cálculo puede no resultar ágil.

Además de estos tres grupos, existen medidas para el error basadas el cálculo del error relativo, errores escalados e incluso relaciones entre diferentes errores que sirven para evaluar el rendimiento de los modelos de previsión.

2.2.1 Corrección de series temporales. Identificación de valores atípicos

Para obtener unos buenos resultados en los pronósticos y unos menores grados de error es recomendable realizar un análisis previo de la serie temporal en búsqueda de valores atípicos o anómalos. Estos fueron definidos en Grubbs (1969) como observaciones que parecen desviarse marcadamente de los otros valores de la muestra a la que pertenecen. Los outliers introducen en la muestra valores muy alejados de la normalidad y que el método de previsión no es capaz de pronosticar. Por ello, pueden tener un impacto sustancial en los resultados del cálculo de los pronósticos.

Un outlier puede aparecer debido a fallos en la maquinaria, cambios en el comportamiento del sistema, comportamientos fraudulentos, errores humanos, errores de instrumentación o simplemente variaciones naturales en la población (Hodge & Austin, 2004).

En este sentido, en Liu & Hydak (1992) se señalan algunas de las razones por las que resulta importante identificarlos:

- Se obtiene un mejor conocimiento de la serie temporal estudiada. Por ejemplo, La detección de los valores atípicos puede destapar factores externos que afectan a la serie temporal e indicar en qué grado lo hacen.
- Se obtienen un mejor modelo de previsión. Los factores externos desconocidos pueden alterar la estructura de las estadísticas, y con ello la del modelo desarrollado para el cálculo de los pronósticos. Identificar los outliers puede simplificar la estructura del modelo haciéndolo más adecuado para la serie temporal. Además, incluso contando con el modelo adecuado, los outliers pueden provocar la elección de parámetros incorrectos.
- Mejora el análisis de los datos. Los outliers contaminan la muestra de los datos y pueden provocar que se escoja un modelo erróneo debido, por ejemplo, una varianza inflada.
- Mejores resultados de pronóstico. La identificación de estos valores y la realización de las correcciones anteriores provocan una mejora del rendimiento del modelo con lo que se obtendrán unas mejores previsiones.

Para identificarlos se suelen aplicar condiciones matemáticas como por ejemplo:

$$\text{Abs}(X_t - \text{mean}(X)) > n \cdot \sigma(X)$$

Donde,

X_t es el valor de la demanda en el periodo t ;

n es un valor numérico que se decidirá en cada caso. A mayor valor de n menos puntos se considerarán outliers.

$\text{mean}(X)$ es el valor de la media de X ;

$\sigma(X)$ es el valor de la desviación típica de X .

Los valores de la serie que la cumplen y por lo tanto se identifican como outliers suelen ser eliminados de la muestra y su valor considerarse como erróneo, vacío o no disponible. Posteriormente se suelen rellenar los valores de estos periodos, por ejemplo, mediante la interpolación de los valores de periodos cercanos.

Otra opción utilizada por muchos autores es la de la acercar su valor al de la media en lugar de eliminarlos por completo. De este modo se reduce el ruido que introducen en la serie temporal pero se sigue disponiendo del dato de la existencia de una subida o bajada importante en ese período.

3 Modelo de programación matemática

Para el desarrollo de un método para el cálculo de previsiones basado en un modelo causal con identificación y ajuste de outliers se ha creado un modelo matemático en MPL. MPL (Mathematical Programming Language) es un sistema avanzado de modelado que permite formular complejos modelos de optimización utilizando ecuaciones algebraicas.

De esta forma se ha formulado un modelo que calculará las previsiones, buscando la minimización del error, e identificará los outliers. Posteriormente se transformarán estos puntos atípicos en nuevas variables causales y se recalcularán los valores de los pronósticos repitiendo este proceso hasta quedar su influencia totalmente absorbida.

3.1 Datos de entrada

Los datos de entrada al modelo, que han sido facilitados por la organización, son la demanda histórica de los últimos cuatro años, para cada una de las líneas de producción y determinada por periodos. Además se ha recogido información relevante sobre cambios importantes en las líneas durante esos periodos como, por ejemplo, la entrada o anulación de alguno de sus modelos.

La importación de datos al modelo de programación matemática se ha hecho a través de una base de datos en Microsoft Access. Además, ésta contendrá la exportación de las variables de decisión.

3.2 Modelo matemático

Para el cálculo de las previsiones, se ha desarrollado un modelo matemático para cada una de las líneas de producción. Ello es debido a que cada una tiene sus propias particularidades, que provocan que sea necesario definir unas variables algo diferentes.

Los cuatro han sido enfocados como modelos de optimización deterministas y lineales, basados en el Modelo de Programación Lineal con Variables Explicativas expuesto en Poler (2017).

```

TITLE
  PMC;
OPTIONS
  DatabaseType=Access
  DatabaseAccess="PMC.mdb"
  ModelType=Linear;
INDEX
  t := DATABASE("DATA", "ti");           !índice de los valores observados (meses)
  ma := DATABASE("MesAnoT", "MesAno");   !índice de los meses del año (de 1 a 12)
  a := DATABASE("AnoT", "Ano");          !índice de los años (comenzando por 1)
  par := DATABASE("PARAM", "Id");        !índice de los parámetros (un único índice con valor 1)
DATA
  V[t] := DATABASE("DATA", "V");         !Ventas observadas en el mes t
  MesAno[t] := DATABASE("DATA", "MesAno"); !Mes del año en el mes t
  Ano[t] := DATABASE("DATA", "Ano");     !Año (comenzando por 1) en el mes t
  E_1[t] := DATABASE("DATA", "E_1");     !Toma valor 1 si en el mes t ha aparecido el evento E1
DECISION VARIABLES
  Err[t] -> ERR_ !Error
  ErrA[t] -> ERA_ !Error absoluto
  MAC[ma] -> MAC_ EXPORT TO DATABASE("MesAnoT", "MesAnoC"); !Valor de previsión asociado al mes del año
  Ac[a] -> Ac_ EXPORT TO DATABASE("AnoT", "AnoC"); !Valor de previsión asociado al año
  P[t] -> P_ EXPORT TO DATABASE("DATA", "P"); !Valor total de la previsión para el mes t
  E1[par] -> AF1_ EXPORT TO DATABASE("PARAM", "E1"); !Valor de previsión asociado a la aparición del evento E1
MACROS
  Errt:=SUM(t: ErrA/last(t)); !Media de errores absolutos
MODEL
  MIN z = Errt; !Función objetivo: minimizar la media de errores absolutos
SUBJECT TO
  !Restricción para el cálculo de la Previsión:
  RCalculoP[t] -> RCP: P[t] = Ac[a:=Ano[t]] + MAC[ma:=MesAno[t]] + E_1[t] * E1[par:=1];
  !Suma el valor asociado al Año
  !Suma el valor asociado al Mes del año
  !Suma el valor asociado a la aparición del evento E1
  !Restricciones para el cálculo del error:
  RCalculoError[t] -> RCE: Err[t] = P[t]-V[t];
  RCalculoErrorA1[t] -> RA1: Err[t] <= ErrA[t];
  RCalculoErrorA2[t] -> RA2: -Err[t] <= ErrA[t];
FREE
  Err[t]; !Para que pueda tomar valores negativos
  E1[par]; !Para que pueda tomar valores negativos
END

```

Ilustración 3-1. Modelo de Programación Lineal con Variables Explicativas. Poler (2017).

Éste ha sido adaptado a las características propias del caso de estudio del proyecto, y posteriormente a las de cada una de las líneas de producción a las que ha sido aplicado. La definición general del modelo se detalla en los siguientes apartados.

3.2.1 Definición del modelo

Los elementos que definen el modelo, es decir, índices, conjuntos, parámetros y variables de decisión se exponen a continuación. Sin embargo, se ha de tener en cuenta que no todas ellas no son consideradas en todos los modelos, sino que en función de las características propias de cada una de las líneas se incluirán las más adecuadas.

3.2.1.1 Índices

Los siguientes índices son generales para el cálculo de las previsiones de todas las líneas:

- t** Índice que representa el periodo.
- a** Índice que representa el año del periodo.
- m** Índice que representa el mes del periodo.

I Índice que representa el número de días laborables de un periodo.

Además de ellos, dependiendo de la línea analizada, se han utilizado:

ms2 Índice que representa la cantidad de modelos nuevos en el periodo.

ms3 Índice que representa la cantidad de modelos antiguos en el periodo.

nm Índice que representa el número de modelos en el periodo.

vcT Índice que representa al Tender que afecta al periodo.

3.2.1.2 Conjuntos

Los siguientes conjuntos son generales para el cálculo de las previsiones de todas las líneas:

T Conjunto de los T periodos de tiempo del histórico siendo $t \in \{1, \dots, T\}$.

A Conjunto de los A años del histórico siendo $a \in \{1, \dots, A\}$.

M Conjunto de los M meses del año $m \in \{1, \dots, M\}$ y $M = 12$.

L Conjunto de los L días laborables de un periodo $dl \in \{1, \dots, L\}$.

Además de ellos, dependiendo de la línea analizada, se han utilizado:

S2 Conjunto de los $S2$ modelos en estado de introducción de una línea de producción siendo $ms2 \in \{1, \dots, S2\}$.

S3 Conjunto de los $S3$ modelos en estado de madurez de una línea de producción siendo $ms3 \in \{1, \dots, S3\}$.

N Conjunto de los N modelos que coexisten a la vez en una línea de producción $nm \in \{1, \dots, N\}$.

TN Conjunto de los TN Tenders que han afectado en algún momento la Línea de Centros de Lavado $vcT \in \{1, \dots, TN\}$ y $TN = 4$.

3.2.1.3 Parámetros

Los siguientes parámetros son generales para el cálculo de las previsiones de todas las líneas:

D_t Demanda real del periodo t .

a_t Año del periodo t .

m_t Mes del periodo t.

Además de ellos, dependiendo de la línea analizada, se han utilizado:

$EvS2_t$ Número de modelos nuevos de la línea en el periodo t.

$EvS3_t$ Número de modelos antiguos de la línea en el periodo t.

$EvDL_t$ Número de días laborables del periodo t.

$EvNM_t$ Número de modelos fabricados en la línea en el periodo t.

$EvTN_t$ Tender que afecta al periodo t.

3.2.1.4 Variables de decisión

Las siguientes variables son generales para el cálculo de las previsiones de todas las líneas:

P_a Valor de la previsión para el año a.

P_m Valor de la previsión para el mes m.

$Prev_t$ Valor total de la previsión para el periodo t.

Err_t Valor del error de ajuste en el periodo t.

$ErrA_t$ Valor absoluto del error de ajuste en periodo t.

$ErrPorA_t$ Valor porcentual absoluto del error de ajuste en periodo t.

Además de ellos, dependiendo de la línea analizada, se han utilizado:

$PrevDL_l$ Valor de la previsión por número de días laborables del periodo.

$PrevS2_{ms2}$ Valor de la previsión por número de modelos nuevos de la línea.

$PrevS2_{ms3}$ Valor de la previsión por número de modelos antiguos de la línea.

$PrevNM_{nm}$ Valor de la previsión por número de modelos de la línea.

$PrevTN_{vcT}$ Valor de la previsión por número de modelos de la línea.

3.2.2 Modelado matemático

En este apartado quedan definidas tanto la función objetivo del problema de optimización como las restricciones que la solución debe cumplir.

3.2.2.1 Función objetivo

La función objetivo del modelo busca minimizar el error absoluto medio de ajuste.

$$Z = \sum_{t=1}^T \frac{ErrA_t}{T}$$

3.2.2.2 Restricciones

$$Prev_t = P_{a=a_t} + P_{m=m_t} + PrevDL_l + PrevS2_{ms2} + PrevS3_{ms3} + PrevNM_{nm} + PrevTN_{vct}$$

Calcula el valor total de la previsión para el periodo t sumando las previsiones debidas a todas las variables consideradas.

$$Err_t = Prev_t - D_t$$

Calcula el error de cada periodo t.

$$Err_t \leq ErrA_t$$

$$-Err_t \leq ErrA_t$$

Calcula el error absoluto de cada periodo t.

$$ErrPorA_t = ErrA_t / D_t$$

Calcula el error porcentual de cada periodo t.

3.2.3 Adaptación del modelo

El modelo matemático presentado en el apartado anterior es adaptado a cada una de las líneas de producción. En este sentido, para las líneas de Puentes de Lavado Automático y Lavado automático de Vehículos Industriales, la previsión se ha calculado considerando las variables $P_a + P_m + PrevDL_l + PrevS2_{ms2} + PrevS3_{ms3}$. El modelo queda, por tanto, de la siguiente manera.

```

TITLE
    TFHPrevisiones

OPTIONS
    DatabaseType=ACCESS;
    DatabaseACCESS="PuentesLavadoAutomatico.mdb"
    ModelType=Linear;

INDEX
    t      :=DATABASE("DATA","Per");           !Indice de periodos
    a      :=DATABASE("PreuAn","A");           !Indice anual
    m      :=DATABASE("PreuMes","M");         !Indice del mes (del 1 al 12)
    l      :=DATABASE("PreuDL","Id");         !Indice numero de días laborables

    ns2    :=DATABASE("PreuModS2","Id");      !Numero de modelos en estado de introduccion
    ns3    :=DATABASE("PreuModS3","Id");      !Numero de modelos en estado de madurez

DATA
    D[t]    :=DATABASE("DATA","Dt");          !demanda observada en el periodo t
    at[t]   :=DATABASE("DATA","An");         !año del periodo t
    mt[t]   :=DATABASE("DATA","Ms");         !mes del periodo t
    EuDL[t] :=DATABASE("DATA","DiasLab");    !numero de días laborables en el periodo t

    EuS2[t] :=DATABASE("DATA","ModS2");      !Numero de modelos en estado de introduccion
    EuS3[t] :=DATABASE("DATA","ModS3");      !Numero de modelos en estado de madurez

VARIABLES
    Pa[a]   -> Pa_EXPORT TO DATABASE("PreuAn","PreuA");           !valor de la previsión para el año a
    Pm[m]   -> Pm_EXPORT TO DATABASE("PreuMes","PreuM");         !valor de la previsión para el mes m
    PreuDL[l] -> PreuDL_EXPORT TO DATABASE("PreuDL","PreuDiasLab"); !previsión asociada al número de días laborales del periodo

    Err[t]   -> Err_EXPORT TO DATABASE("DATA","Err");           !error de ajuste en el periodo t
    ErrA[t]  -> ErrA_EXPORT TO DATABASE("DATA","ErrA");         !valor absoluto del error de ajuste en el periodo t
    ErrPorA[t] -> ErrPorA_EXPORT TO DATABASE("DATA","ErrPorA"); !error porcentual de ajuste en el periodo t

    PreuS2[ns2] -> PreuS2_EXPORT TO DATABASE("PreuModS2","PreuS2"); !previsión asociada al número de modelos en estado de introduccion
    PreuS3[ns3] -> PreuS3_EXPORT TO DATABASE("PreuModS3","PreuS3"); !previsión asociada al número de modelos en estado de madurez

    Preu[t]   -> Pa_EXPORT TO DATABASE("DATA","Preu");           !valor total de la previsión para el periodo t
    z;

MACROS
    Errt :=SUM(t:ErrA/last(t) if (t<73));           !media de errores absolutos

MODEL
    MIN Z = Errt; !el modelo busca minimizar la media de los errores absolutos

SUBJECT TO
    RCalculoP[t]-> RCP:    Preu[t] =          Pa[a:=at[t]]
                          + Pm[m:=mt[t]]
                          + PreuDL[l:=EuDL[t]]
                          + PreuS2[ns2:=EuS2[t]]
                          + PreuS3[ns3:=EuS3[t]];

    RCalculoError[t]-> RCE:    Err[t] = Preu[t] - D[t];
    RCalculoErrorA1[t]-> RA1:  Err[t] <= ErrA[t];
    RCalculoErrorA2[t]-> RA2:  -Err[t] <= ErrA[t];
    RCalculoErrorA3[t]-> RA3:  ErrPorA[t] = ErrA[t] / D[t];

BOUNDS
FREE
    Err[t];           !para que pueda tomar valores negativos
    PreuDL[l];

END

```

Ilustración 3-2. Modelo causal Líneas de Puentes de Lavado Automático y Línea de Lavado Automático de Vehículos

Por otro lado, para la línea de Túneles de Lavado Automático, tan solo se han considerado $P_{a=a_t} + P_{m=m_t} + \text{PreuDL}_l + \text{PreuNM}_{nm}$, quedando el modelo como se expone a continuación.

```

TITLE
TFMPrevisiones

OPTIONS
DatabaseType=ACCESS;
DatabaseACCESS="TunelesLavadoAutomatico.mdb"
ModelType=Linear;

INDEX
t      :=DATABASE("DATA","Per");           !Indice de periodos
a      :=DATABASE("PrevAn","A");           !Indice anual
n      :=DATABASE("PrevMes","M");         !Indice del mes (del 1 al 12)
l      :=DATABASE("PrevDL","Id");         !Indice numero de dias laborables

nn     :=DATABASE("PrevNM","Id");         !Numero de modelos
vcT    :=DATABASE("PrevUCTen","Id");      !Indice Tenders

DATA
D[t]   :=DATABASE("DATA","Dt");           !demanda observada en el periodo t
at[t]  :=DATABASE("DATA","An");           !año del periodo t
nt[t]  :=DATABASE("DATA","Ms");           !mes del periodo t
EvDL[t]:=DATABASE("DATA","DiasLab");      !numero de dias laborables en el periodo t

EuNM[t]:=DATABASE("DATA","NM");          !Numero de modelos
PrevTN[t]:=DATABASE("PrevUCTen","TN");    !Unidades vendidas por Tenders

VARIABLES
Pa[a]  -> Pa_EXPORT TO DATABASE("PrevAn","PrevA");           !valor de la prevision para el año a
Pn[n]  -> Pn_EXPORT TO DATABASE("PrevMes","PrevM");          !valor de la prevision para el mes n
PrevDL[l] -> PrevDL_EXPORT TO DATABASE("PrevDL","PrevDiasLab"); !prevision asociada al numero de dias laborales

Err[t]  -> Err_EXPORT TO DATABASE("DATA","Err");             !error de ajuste en el periodo t
ErrA[t] -> ErrA_EXPORT TO DATABASE("DATA","ErrA");            !valor absoluto del error de ajuste en el periodo t
ErrPorA[t] -> ErrPorA_EXPORT TO DATABASE("DATA","ErrPorA");  !error porcentual de ajuste en el periodo t

PrevNM[nn] -> PrevNM_EXPORT TO DATABASE("PrevNM","PrevNM"); !prevision asociada al número de modelos

Prev[t] -> Prev_EXPORT TO DATABASE("DATA","Prev");           !valor total de la prevision para el periodo t
z;

MACROS
Errt :=SUM(t:ErrA/last(t) if (t<73));           !media de errores absolutos

MODEL
MIN Z = Errt; !el modelo busca minimizar la media de los errores absolutos

SUBJECT TO
RCalculoP[t]-> RCP: Prev[t] = Pa[a:=at[t]]
                + Pn[n:=nt[t]]
                + PrevDL[l:=EvDL[t]]
                + PrevNM[nn:=EuNM[t]]
                + PrevTN[t];
RCalculoError[t]-> RCE: Err[t] = Prev[t] - D[t];
RCalculoErrorA1[t]-> RA1: Err[t] <= ErrA[t];
RCalculoErrorA2[t]-> RA2: -Err[t] <= ErrA[t];
RCalculoErrorA3[t]-> RA3: ErrPorA[t] = ErrA[t] / D[t];

BOUNDS
FREE !para que pueda tomar valores negativos
Err[t];
PrevDL[l];
PrevNM[nn];

END

```

Ilustración 3-3. Modelo causal para la Línea de Túneles de Lavado Automático

Por último para la Línea de Centros de Lavado las variables tenidas en cuenta para el cálculo de las previsiones son las siguientes $P_{a=at} + P_{m=mt} + PrevDL_l + PrevNM_{nm} + PrevTN_{vcT}$.

```

TITLE
    TFMPrevisiones

OPTIONS
    DatabaseType=ACCESS;
    DatabaseACCESS="CentrosLavado.mdb"
    ModelType=Linear;

INDEX
    t      :=DATABASE("DATA","Per");           !Indice de periodos
    a      :=DATABASE("PrevAn","A");           !Indice anual
    m      :=DATABASE("PrevMes","M");         !Indice del mes (del 1 al 12)
    l      :=DATABASE("PrevDL","Id");          !Indice numero de días laborables

    nm     :=DATABASE("PrevNM","Id");          !Numero de modelos
    ucT    :=DATABASE("PrevUCTen","Id");       !Indice Tenders

DATA
    D[t]    :=DATABASE("DATA","Dt");           !demanda observada en el periodo t
    at[t]   :=DATABASE("DATA","An");           !año del periodo t
    mt[t]   :=DATABASE("DATA","Ms");           !mes del periodo t
    EvDL[t] :=DATABASE("DATA","DiasLab");      !numero de días laborables en el periodo t

    EvNM[t] :=DATABASE("DATA","NM");           !Numero de modelos
    PrevTN[t] :=DATABASE("PrevUCTen","TN");    !Unidades vendidas por Tenders

VARIABLES
    Pa[a]   -> Pa_EXPORT TO DATABASE("PrevAn","PrevA");           !valor de la previsión para el año a
    Pm[m]   -> Pm_EXPORT TO DATABASE("PrevMes","PrevM");           !valor de la previsión para el mes m
    PrevDL[l] -> PrevDL_EXPORT TO DATABASE("PrevDL","PrevDiasLab"); !previsión asociada al numero de días laborales

    Err[t]   -> Err_EXPORT TO DATABASE("DATA","Err");             !error de ajuste en el periodo t
    ErrA[t]  -> ErrA_EXPORT TO DATABASE("DATA","ErrA");           !valor absoluto del error de ajuste en el periodo t
    ErrPorA[t] -> ErrPorA_EXPORT TO DATABASE("DATA","ErrPorA");   !error porcentual de ajuste en el periodo t

    PrevNM[nm] -> PrevNM_EXPORT TO DATABASE("PrevNM","PrevNM"); !previsión asociada al número de modelos

    Prev[t]  -> Prev_EXPORT TO DATABASE("DATA","Prev");           !valor total de la previsión para el periodo t
    z;

MACROS
    Errt :=SUM(t:ErrA/last(t) if (t<73));           !media de errores absolutos

MODEL
    MIN Z = Errt;   !el modelo busca minimizar la media de los errores absolutos

SUBJECT TO
    RCalculoP[t]-> RCP:   Prev[t] =      Pa[a:=at[t]]
                                + Pm[m:=mt[t]]
                                + PrevDL[l:=EvDL[t]]
                                + PrevNM[nm:=EvNM[t]]
                                + PrevTN[t];

    RCalculoError[t]-> RCE:   Err[t] = Prev[t] - D[t];
    RCalculoErrorA1[t]-> RA1:   Err[t] <= ErrA[t];
    RCalculoErrorA2[t]-> RA2:  -Err[t] <= ErrA[t];
    RCalculoErrorA3[t]-> RA3:   ErrPorA[t] = ErrA[t] / D[t];

BOUNDS
FREE
    !para que pueda tomar valores negativos
    Err[t];
    PrevDL[l];
    PrevNM[nm];

END
    
```

Ilustración 3-4. Modelo causal para la Línea de Centros de Lavado

Con estos modelos se calcularán el valor para cada una de las variables implicadas en cada caso, proporcionando los datos de salida del modelo que serán utilizados en el posterior cálculo de las previsiones futuras.

3.3 Datos de salida. Cálculo de las previsiones futuras

Una vez ejecutado el modelo de programación matemática con MPL se obtendrán los valores calculados para las variables de decisión consideradas en cada una de las líneas. Estos se exportarán a una base de datos de Microsoft Access para posteriormente utilizarse en el cálculo de las previsiones para el próximo año.

Para ello, se procederá del siguiente modo:

- Los valores aportados por la variable P_a (valor de la previsión para el año a) representan la tendencia de la serie temporal. Como el modelo calculará los valores para los años pasados pero no para los futuros, se aplicará el método de Holt a esta variable, aplicable a series temporales con tendencia, para calcular su valor para los próximos años.
- Los valores aportados por la variable P_m (valor de la previsión para el mes m) representan la estacionalidad de la serie temporal. Como estas fluctuaciones se repetirán año tras año, los valores calculados para los años con histórico, que serán introducidos en el modelo, serán los supuestos para calcular las previsiones de los años futuros.
- Además de estos dos factores, se habrá de estimar los valores para las variables causales que sean consideradas en cada caso y que se obtendrán de la información disponible.

4 Aplicación práctica a una empresa real

4.1 Introducción.

Para la validación de este modelo para el cálculo de previsiones se han calculado los pronósticos del año actual a través de dos metodologías: el método Theta y el modelo causal desarrollado en el presente proyecto. Una vez calculadas se compararán los resultados con el objetivo de comprobar si la incorporación de variables explicativas y el ajuste de outliers mejoran el resultado de las previsiones.

En primer lugar se calcularán las previsiones para el 2017 a través de ambos métodos. Para ello se supondrán desconocidos los valores reales de demanda para los últimos 10 periodos (desde enero a octubre de 2017). De este modo se podrá calcular tanto el error de ajuste como de acierto para ambas técnicas.

En segundo lugar, se identificarán, a través de un método estándar y sencillo, los outliers de cada uno de los pronósticos. Una vez encontrados se realizará una pequeña investigación con el objetivo de encontrar variables causales que los expliquen. Para el resto, se supondrá que existe una y que resulta, por el momento, desconocida. De este modo todos los outliers serán transformados en variables explicativas, que se introducirán como dato de entrada al modelo y se recalcularán las previsiones. Este bucle se realizará tantas veces como sea necesario hasta que las variables supuestas hayan absorbido la influencia de los outliers.

Por último se calcularán las previsiones para el 2018 con el método desarrollado.

4.1.1 La empresa

El modelo de previsión de demanda ha sido validado en ISTOBAL, una empresa española líder en el diseño, fabricación y comercialización de soluciones de lavado y cuidado para la automoción. Fue fundada en 1950 por Ismael Tomás Alacreu y hoy en día la compañía mantiene su esencia de empresa familiar, siendo ya la tercera generación la que dirige.

ISTOBAL está presente en más de 75 países gracias a su firme estrategia de internacionalización, que le ha permitido posicionarse como uno de los líderes del sector a nivel europeo. Su apuesta por la innovación y su compromiso por ofrecer soluciones globales eficientes la convierten en un referente internacional. Actualmente, el 80% de su facturación, que en el último ejercicio consolidado alcanzó los 124 millones de euros, corresponde a ventas internacionales.

Además, cuenta con 10 filiales y tres plantas de fabricación y ensamblaje en Europa y América, más de 800 trabajadores en plantilla y una amplia red de distribuidores por todo el mundo, la cual consolida su presencia internacional.

4.1.2 Líneas de producción

ISTOBAL ofrece a sus clientes un gran abanico de opcionales para cada una de sus líneas y modelos. Ello permite que cada cliente pueda configurar su máquina ajustada a sus necesidades e intereses concretos. En este sentido, sus productos se dividen en cuatro grandes líneas: lavado automático de puentes, lavado de vehículos industriales, lavado automático de Túneles de Lavado Automático y Centros de Lavado.



Ilustración 4-1. Puente de lavado automático ISTOBAL. Recuperado de www.istobal.com

Puentes de Lavado Automático

La línea de producción de puentes es la principal de ISTOBAL. La característica principal de estos modelos es que se componen por un puente que se desplaza sobre sus railes quedando el vehículo en posición fija. De este modo los módulos de lavado van recorriendo el vehículo siguiendo el programa.



Ilustración 4-2. Puente de lavado ISTOBAL M'START. Recuperado de www.istobal.com

Túneles de lavado automático

La constituyen los denominados túneles de lavado, una solución rápida para conseguir un lavado eficaz. En estos modelos es el vehículo el que se desplaza por los raíles atravesando el túnel que tiene fijados los opcionales de lavado en diferentes puntos de su recorrido.



Ilustración 4-3. Túnel de lavado ISTOBAL 4TC. Recuperado de www.istobal.com

Lavado de vehículos industriales

Se trata de la línea que se dedica a la fabricación de soluciones de lavado para vehículos de grandes dimensiones como camiones, furgonetas, autobuses, tráileres, tranvías, vehículos especiales, etc.. Se trata de modelos de diseño robusto y compacto, con una mecánica fiable que garantice el lavado eficiente de las flotas.



Ilustración 4-4. Puente de lavado para vehículos industriales ISTOBAL HW'PROGRESS. Recuperado de www.istobal.com

Centros de Lavado

En esta línea se fabrican los Centros de Lavado en los que el vehículo se limpia con una pistola la cual maneja en cliente. Además en esta línea se producen todos los complementos y periféricos, como aspiradores, terminales de pago, limpia-alfombrillas, etc.



Ilustración 4-5. Centro de lavado ISTOBAL. Recuperado de www.istobal.com

4.1.3 Datos proporcionados

Estas cuatro líneas de producción se gestionan de forma totalmente independiente por lo que la validación del modelo se hará para cada una ellas. En primer lugar y como punto de partida, se dispone de los datos de fabricación facilitados por la empresa desde el año 2014 hasta 2017. Con ello se obtiene de una serie temporal por línea bastante amplia y de un nivel de agregación suficiente para poder aplicar el modelo.

Los datos son los siguientes:

Año	Mes	Puentes de Lavado Automático	Túneles de lavado automático	Lavado de vehículos industriales	Centros de Lavado
2014	Enero	71	3	12	21
2014	Febrero	89	3	19	23
2014	Marzo	87	3	15	17
2014	Abril	75	5	19	39
2014	Mayo	94	4	22	54
2014	Junio	104	2	17	59
2014	Julio	95	8	46	39
2014	Agosto	24	2	5	12
2014	Septiembre	84	5	23	27
2014	Octubre	95	8	26	35
2014	Noviembre	101	3	16	29
2014	Diciembre	60	6	8	19
2015	Enero	67	8	13	14
2015	Febrero	91	7	19	21
2015	Marzo	96	5	13	23
2015	Abril	94	6	18	27
2015	Mayo	110	4	23	24
2015	Junio	128	4	19	38
2015	Julio	146	9	25	43
2015	Agosto	27	2	7	6
2015	Septiembre	117	6	18	36
2015	Octubre	116	8	14	33
2015	Noviembre	116	8	21	33
2015	Diciembre	86	5	11	20
2016	Enero	59	5	8	21
2016	Febrero	111	4	15	28
2016	Marzo	101	10	16	28
2016	Abril	123	5	21	35
2016	Mayo	132	8	20	37
2016	Junio	136	9	13	45
2016	Julio	129	9	29	54

2016	Agosto	40	0	8	16
2016	Septiembre	107	5	23	32
2016	Octubre	107	8	14	32
2016	Noviembre	120	9	19	55
2016	Diciembre	73	5	12	29
2017	Enero	86	4	20	22
2017	Febrero	94	7	29	36
2017	Marzo	142	8	28	44
2017	Abril	104	7	13	27
2017	Mayo	140	16	28	48
2017	Junio	125	9	25	66
2017	Julio	156	4	20	67
2017	Agosto	50	1	11	21
2017	Septiembre	108	4	23	43
2017	Octubre	126	6	19	47
2017	Noviembre	127	3	12	44
2017	Diciembre	81	3	4	35

Ilustración 4-6. Datos de demanda por línea (2014- 2017)

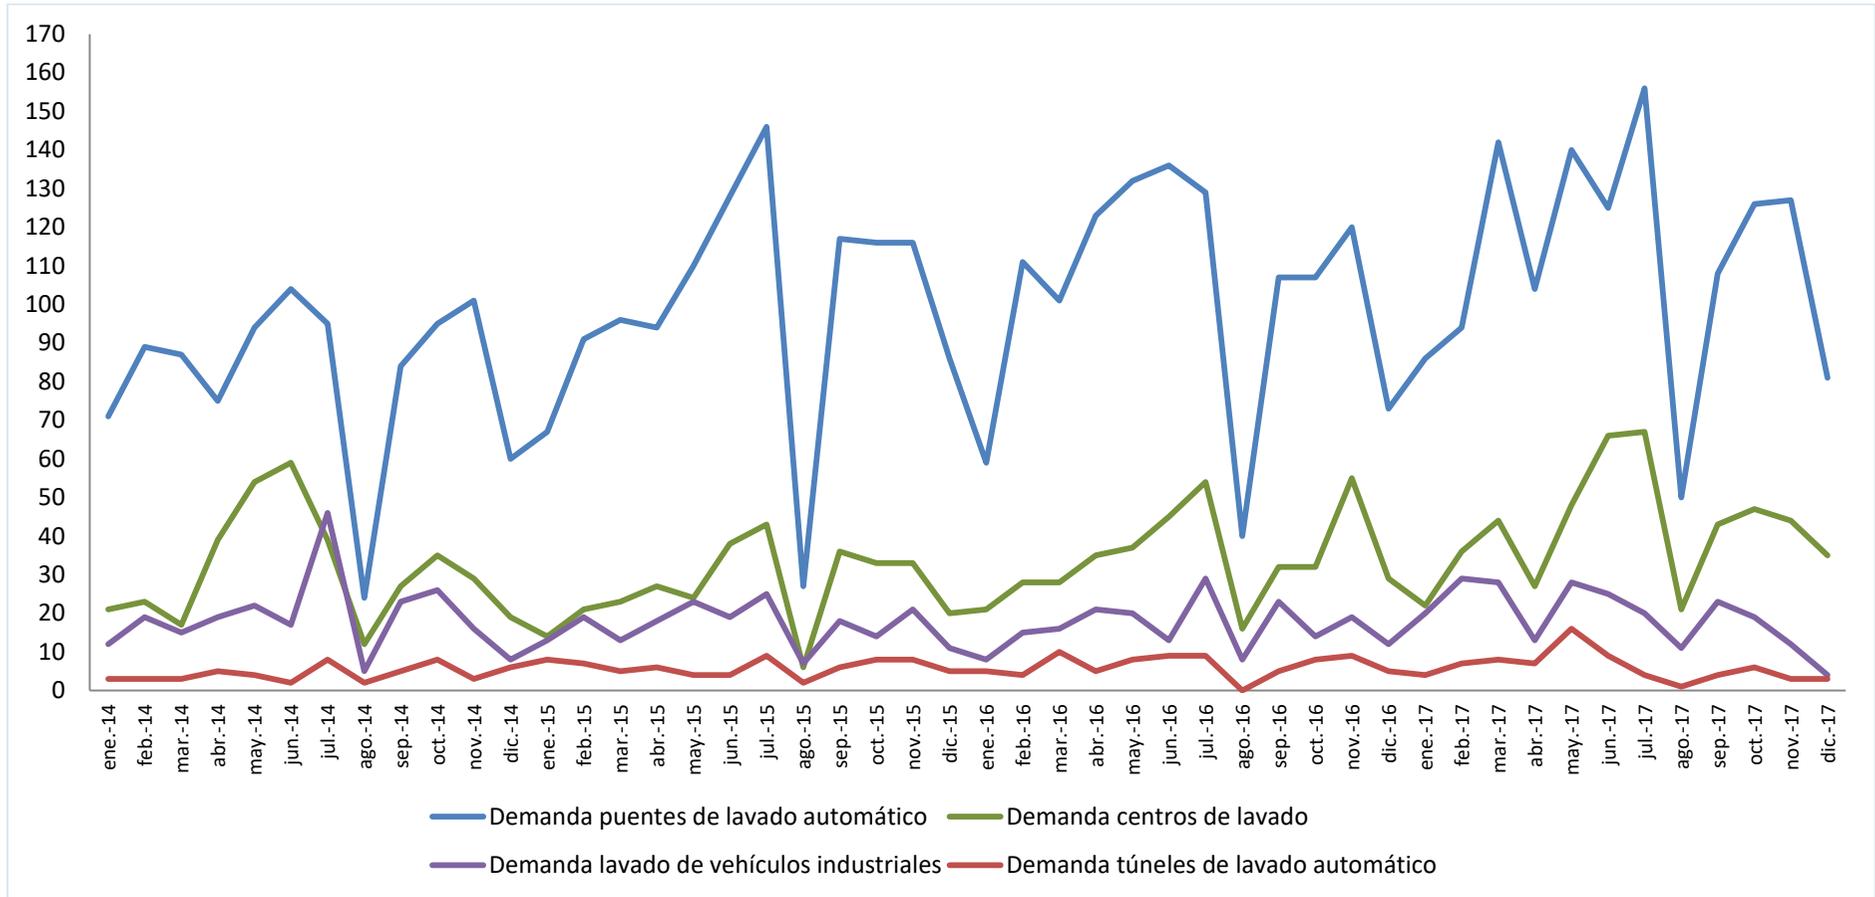


Ilustración 4-7. Gráfico de los datos de demanda por línea (2014- 2017)

Como se puede observar la línea de puentes es la que más participación tiene dentro de la compañía ya que supone aproximadamente el 60% de la producción. Seguidamente se sitúa la línea de centros con un 25%. Y por último las de buses y Túneles de Lavado Automático con un 10% y 5% respectivamente. Existe, por tanto, una gran diferencia en cuanto al volumen de producción de cada una de las líneas que podría afectar al grado de acierto del modelo de previsión en cada una de ellas.

4.2 Cálculo de las previsiones. Método Theta.

En este apartado se calcularán las previsiones para el 2017 a través del método Theta. El método theta es una técnica para el cálculo de previsiones desarrollada en Assimakopoulos & Nikolopoulos (2000). Se trata de una variante del alisado exponencial basado en la modificación de la curva de la serie temporal a través de un coeficiente theta. El resultado es una serie de nuevas curvas, denominadas líneas theta, cuyo sumatorio equivale al pronóstico y que mantienen la media y la pendiente de la original pero no su curvatura. Con ello se mejora el comportamiento a largo plazo o las características a corto plazo, en función del valor de dicho coeficiente. Es decir, cuanto mayor sea el valor de theta menor será el grado de deflación y más se asemejará la línea theta a la serie temporal original. Por el contrario, cuanto menor sea el valor de theta, la deflación será mayor y la línea theta se alisará. En el caso extremo de theta=0 la línea se transforma en una regresión lineal.

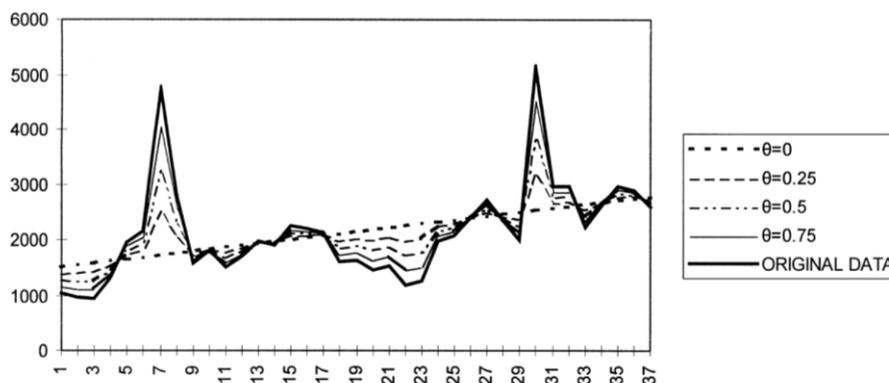


Ilustración 4-8. M3-Comp. Series 200, la deflación del método Theta.
Fuente: Assimakopoulos & Nikolopoulos (2000).

En su versión más sencilla se calculan dos líneas Theta, una correspondiente a la regresión lineal de los puntos desestacionados y otra al lisaje de la parte no explicada por la primera. Su formulación es la que sigue:

$$Y_t = \frac{LR_t + LE_t}{2} E_t$$

$$D_t = \frac{X_t}{E_t}$$

$$L_t = 2D_t - LR_t$$

$$LE_{t+1} = LE_t + \alpha (D_t - LE_t)$$

Donde,

Y_t es el valor del pronóstico para el periodo t .

X_t es el valor de la demanda observada para el periodo t .

α es el factor de alisamiento.

E_t es el factor estacional.

D_t es la serie desestacionalizada.

LR_t es la regresión lineal sobre los puntos de la serie desestacionalizada.

L_t es la diferencia entre el doble de la serie desestacionalizada y la línea LR_t .

LE_t es el lisaje exponencial simple de la línea L_t .

Para calcular los valores pronosticados por el método theta se ha utilizado PrevGIP, un software para la previsión de series temporales mensuales desarrollado por el Centro de Investigación de Gestión e Ingeniería de Producción de la Universidad Politécnica de Valencia.

Se trata de una herramienta que implementa doce modelos de previsión diferentes, de modo que es capaz de abordar una amplia variedad de históricos. PrevGIP permite además crear una representación gráfica tanto de los históricos como de las previsiones, modificar puntos del histórico, hacer comparativas de las previsiones obtenidas a través de diferentes metodologías crear una simulación ex-ante y calcular los errores tanto de ajuste como de acierto.

El procedimiento para el cálculo de los pronósticos para las cuatro líneas de producción de ISTOBAL se expone a continuación.

El primer paso es la introducción de los datos de las demandas reales observadas desde el 2014 al 2017 de la línea en la pestaña DATOS. Para ello se indicará por columnas, el año, mes y demanda observada tal como aparece en la siguiente imagen.

Datos	Modelo	Tabla Previsión	Tabla C.E.	Gráfico Previsión	Gráfico Prev. acum.	Gráfico Prev. comp.	Gráfico C.E.	Errores ajuste	Errores acierto
2014	1	71							
2014	2	89							
2014	3	87							
2014	4	75							
2014	5	94							
2014	6	104							
2014	7	95							
2014	8	24							
2014	9	84							
2014	10	95							
2014	11	101							
2014	12	60							
2015	1	67							
2015	2	91							
2015	3	96							
2015	4	94							
2015	5	110							
2015	6	128							
2015	7	146							
2015	8	27							
2015	9	117							
2015	10	116							
2015	11	116							
2015	12	86							
2016	1	59							

Ilustración 4-9. PrevGIP. Datos

Posteriormente se selecciona el modelo de pronóstico elegido, en este caso el método THETA con factor de alisamiento $\alpha=0,2$. Además, se le indica al programa que realice los pronósticos para el 2017, es decir, obviaré la información de estos últimos 12 periodos, que no se utilizarán en los cálculos que generarán las líneas theta.

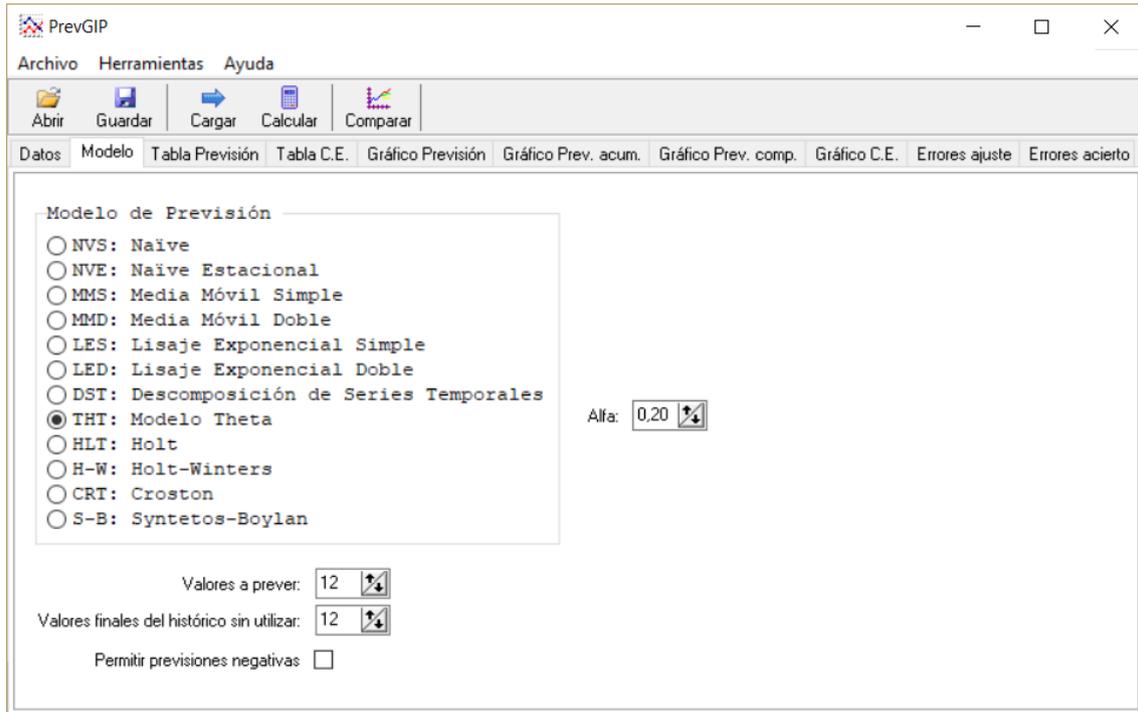


Ilustración 4-10. PrevGIP. Modelo de previsión

De este modo, se obtendrán los valores, tanto para el error de ajuste (correspondiente a los periodos entre el 2011 y el 2016) como para el error de acierto (para los periodos del 2017).

Por último se ha pulsar el botón “Cargar” que creará la tabla de previsión y posteriormente “Calcular”, que hará los cálculos correspondientes a los pronósticos.

t	Año	Mes	Datos	MM12	MM12C	E*I	D	LR	L	P
1	2014	1	71				108,38	81,22	135,55	71,00
2	2014	2	89				86,86	82,05	135,55	111,48
3	2014	3	87				87,41	82,88	126,78	104,34
4	2014	4	75				69,34	83,72	119,81	110,06
5	2014	5	94				78,28	84,55	106,84	114,92
6	2014	6	104				79,76	85,38	99,87	120,77
7	2014	7	95	81,58	81,42	1,17	72,11	86,22	94,73	119,19
8	2014	8	24	81,25	81,33	0,30	84,95	87,05	87,38	24,64
9	2014	9	84	81,42	81,79	1,03	76,88	87,88	86,48	95,25
10	2014	10	95	82,17	82,96	1,15	83,43	88,72	82,36	97,40
11	2014	11	101	83,75	84,42	1,20	87,62	89,55	81,52	98,59
12	2014	12	60	85,08	86,08	0,70	79,49	90,38	82,35	65,19
13	2015	1	67	87,08	89,21	0,75	102,28	91,21	79,60	55,95
14	2015	2	91	91,33	91,46	0,99	88,82	92,05	86,35	91,39
15	2015	3	96	91,58	92,96	1,03	96,45	92,88	86,19	89,12
16	2015	4	94	94,33	95,21	0,99	86,91	93,71	88,96	98,79
17	2015	5	110	96,08	96,71	1,14	91,60	94,55	87,19	109,12
18	2015	6	128	97,33	98,42	1,30	98,17	95,38	87,48	119,21
19	2015	7	146	99,50	99,17	1,47	110,82	96,21	90,18	122,78

Ilustración 4-11. PrevGIP. Tabla de previsión

A continuación el programa rellena la tabla de previsión en la que aparecen las medias móviles centradas, el cociente de la estacionalidad por la componente irregular, la demanda desestacionalizada, la línea de regresión, la línea del lisaje y el pronóstico para cada periodo.

En la parte inferior aparecen los 12 periodos que no han sido utilizados en el cálculo de las líneas Theta y sus previsiones, con lo que se evaluará el error de acierto del modelo.

t	Año	Mes	Datos	MM12	MM12C	E ¹	D	LR	L	P
30	2016	6	136	104,25	103,71	1,31	104,31	105,38	108,83	139,65
31	2016	7	129	103,17				97,92	106,21	140,91
32	2016	8	40					141,58	107,04	104,09
33	2016	9	107					97,93	107,88	118,50
34	2016	10	107					93,97	108,71	112,39
35	2016	11	120					104,10	109,54	105,76
36	2016	12	73					96,71	110,38	104,34
37	2017	1	86						111,21	104,34
38	2017	2	94						112,04	104,34
39	2017	3	142						112,88	104,34
40	2017	4	104						113,71	104,34
41	2017	5	140						114,54	104,34
42	2017	6	125						115,38	104,34
43	2017	7	156						116,21	104,34
44	2017	8	50						117,04	104,34
45	2017	9	108						117,88	104,34
46	2017	10	126						118,71	104,34
47	2017	11	127						119,54	104,34
48	2017	12	81						120,38	104,34

Ilustración 4-12. PrevGIP. Tabla de previsión - valores sin utilizar

En el resto de pestañas se ofrece información útil como la tabla de coeficientes estacionales, varios gráficos de previsión o los errores de ajuste y acierto del modelo.

A continuación se ha realizado este proceso con cada una de las líneas para comprobar el grado de acierto del modelo Theta a sus series temporales de demanda concretas.

4.2.1 Línea de Puentes de Lavado Automático

La línea de Puentes de Lavado Automático es la más representativa de ISTOBAL ya que supone el 60% de la producción. En esta línea se fabrican actualmente once modelos diferentes cada uno de los cuales cuenta con una gran variedad de opcionales que hace que cada máquina que se vende sea una combinación casi única.

A pesar de la gran variabilidad de opcionales la demanda total de la línea se mantiene dentro de una cierta estabilidad que, unida a su amplio volumen, hace de esperar que sea la línea con los Errores de Pronóstico más bajos.

Una vez realizados los cálculos, se han obtenido los siguientes resultados:

Año	Mes	Previsión	Demanda real	Error de pronóstico absoluto	Error de pronóstico porcentual
2014	1	71	71	0	0,00%
2014	2	111	89	22	24,72%
2014	3	104	87	17	19,54%
2014	4	110	75	35	46,67%
2014	5	115	94	21	22,34%
2014	6	121	104	17	16,35%
2014	7	119	95	24	25,26%
2014	8	25	24	1	4,17%
2014	9	95	84	11	13,10%
2014	10	97	95	2	2,11%
2014	11	99	101	2	1,98%
2014	12	65	60	5	8,33%
2015	1	56	67	11	16,42%
2015	2	91	91	0	0,00%
2015	3	89	96	7	7,29%
2015	4	99	94	5	5,32%
2015	5	109	110	1	0,91%
2015	6	119	128	9	7,03%
2015	7	123	146	23	15,75%
2015	8	27	27	0	0,00%
2015	9	106	117	11	9,40%
2015	10	113	116	3	2,59%
2015	11	116	116	0	0,00%
2015	12	76	86	10	11,63%
2016	1	68	59	9	15,25%
2016	2	104	111	7	6,31%
2016	3	103	101	2	1,98%
2016	4	112	123	11	8,94%
2016	5	127	132	5	3,79%
2016	6	140	136	4	2,94%
2016	7	141	129	12	9,30%
2016	8	30	40	10	25,00%
2016	9	124	107	17	15,89%
2016	10	126	107	19	17,76%
2016	11	124	120	4	3,33%
2016	12	81	73	8	10,96%

Tabla 4-1. Demanda real y previsión pasada calculada a través del método Theta para la línea de Puentes de Lavado Automático

En el siguiente gráfico aparecen representados los históricos de demanda y previsión para los periodos utilizados en el cálculo del error de ajuste del modelo:

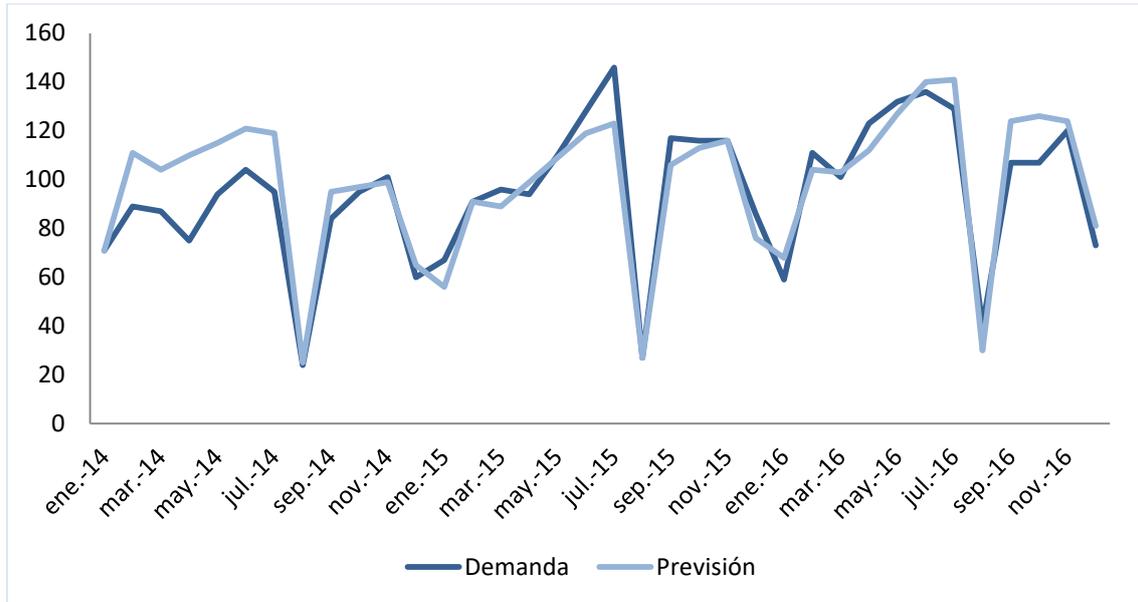


Ilustración 4-13. Demanda real y previsión pasada calculada a través del método Theta para la línea de Puentes de Lavado Automático

Gráficamente puede observarse que la curva de previsión sigue bastante cercanamente a la de demanda real, exceptuando algunos periodos concretos, como julio de 2015 en el que la demanda fue excepcionalmente elevada, septiembre y octubre de 2016 en los que las previsiones erran por debajo y los primeros siete meses del histórico cuyo pronóstico queda muy debajo del histórico.

Con estos valores, se ha calculado el error de ajuste medio, el cual se muestra en la siguiente tabla:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
THT (0,2) T-12	160,14	12,65	9,58	10,62%	29,82%

Tabla 4-2. Error de ajuste medio del método Theta para la Línea de Puentes de Lavado Automático

Se trata de una tasa de error bastante aceptable en cuanto a ajuste. A continuación se busca el cálculo de la de acierto para comprobar si es igual de adecuada.

Las previsiones calculadas por el software tras seleccionar la opción de no utilizar los 12 últimos meses del histórico, y que se corresponden con las que se habrían hecho con la información disponible a final de diciembre de 2016, son las siguientes:

Año	Mes	Previsión	Demanda real	Error de pronóstico absoluto	Error de pronóstico porcentual
2017	1	71	86	15	17,44%
2017	2	111	94	17	18,09%
2017	3	108	142	34	23,94%
2017	4	118	104	14	13,46%
2017	5	131	140	9	6,43%
2017	6	143	125	18	14,40%
2017	7	145	156	11	7,05%
2017	8	31	50	19	38,00%
2017	9	121	108	13	12,04%
2017	10	127	126	1	0,79%
2017	11	129	127	2	1,57%
2017	12	85	81	4	4,94%

Tabla 4-3. Demanda real y previsión futura calculada a través del método Theta para la línea de Puentes de Lavado Automático

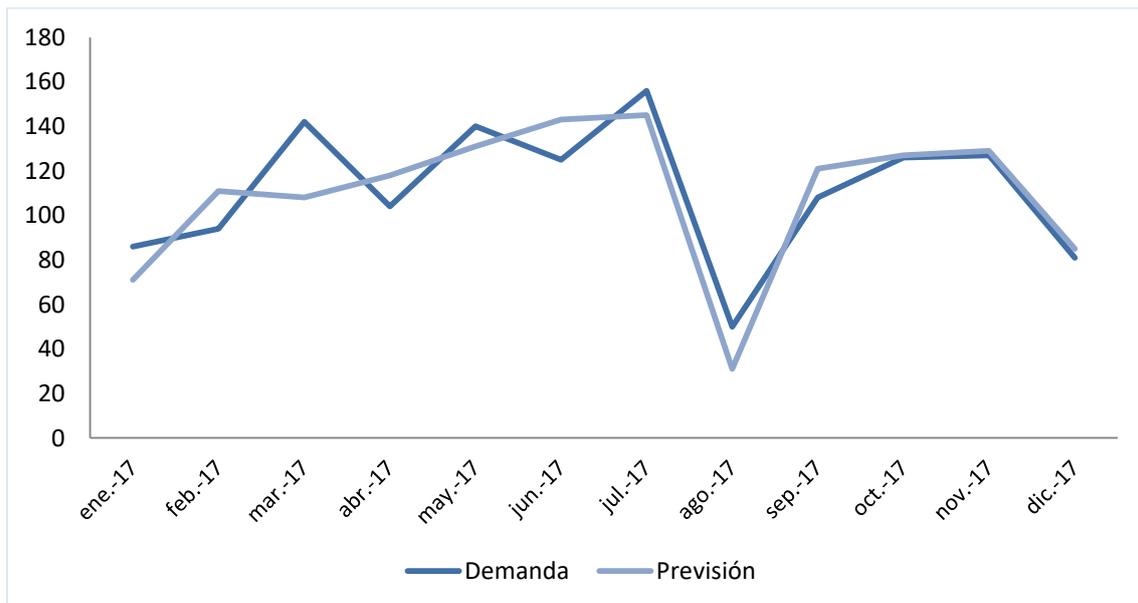


Ilustración 4-14. Demanda real y previsión futura calculada a través del método Theta para la línea de Puentes de Lavado Automático

En cuanto a las previsiones de estos 12 periodos, se observa que el modelo se ajusta bastante a la curva de demanda sobretudo la segundo mitad del año, mientras que visiblemente comete más error en la primera mitad. Los errores de acierto medios se muestra en la siguiente tabla:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
THT (0,2) T-12	245,25	15,66	13,08	13,18%	13,96%

Tabla 4-4. Error de acierto medio del método Theta para de la línea de Puentes de Lavado Automático

Se trata de un grado de acierto considerable por lo que se puede concluir que el modelo Theta ofrece unas previsiones bastante acertadas para la línea de Puentes de Lavado Automático.

4.2.2 Línea de Túneles de Lavado Automático

En segundo lugar, se ha realizado el mismo cálculo con los datos de demanda real observada en la línea de túneles de lavado automático. Los resultados son los siguientes:

Año	Mes	Previsión	Demanda real	Error de pronóstico absoluto	Error de pronóstico porcentual
2014	1	3	3	0	0,00%
2014	2	3	3	0	0,00%
2014	3	4	3	1	33,33%
2014	4	3	5	2	40,00%
2014	5	3	4	1	25,00%
2014	6	4	2	2	100,00%
2014	7	5	8	3	37,50%
2014	8	1	2	1	50,00%
2014	9	4	5	1	20,00%
2014	10	6	8	2	25,00%
2014	11	4	3	1	33,33%
2014	12	4	6	2	33,33%
2015	1	5	8	3	37,50%
2015	2	5	7	2	28,57%
2015	3	7	5	2	40,00%
2015	4	5	6	1	16,67%
2015	5	6	4	2	50,00%
2015	6	6	4	2	50,00%
2015	7	8	9	1	11,11%
2015	8	2	2	0	0,00%
2015	9	5	6	1	16,67%
2015	10	8	8	0	0,00%
2015	11	5	8	3	37,50%
2015	12	6	5	1	20,00%
2016	1	7	5	2	40,00%
2016	2	5	4	1	25,00%
2016	3	7	10	3	30,00%

2016	4	6	5	1	20,00%
2016	5	6	8	2	25,00%
2016	6	7	9	2	22,22%
2016	7	11	9	2	22,22%
2016	8	3	0	3	-
2016	9	5	5	0	0,00%
2016	10	8	8	0	0,00%
2016	11	5	9	4	44,44%
2016	12	6	5	1	20,00%

Tabla 4-5. Demanda real y previsión pasada calculada a través del método Theta para la línea de túneles de lavado automático

Gráficamente los valores de demanda y previsión por periodo se expresan a continuación:

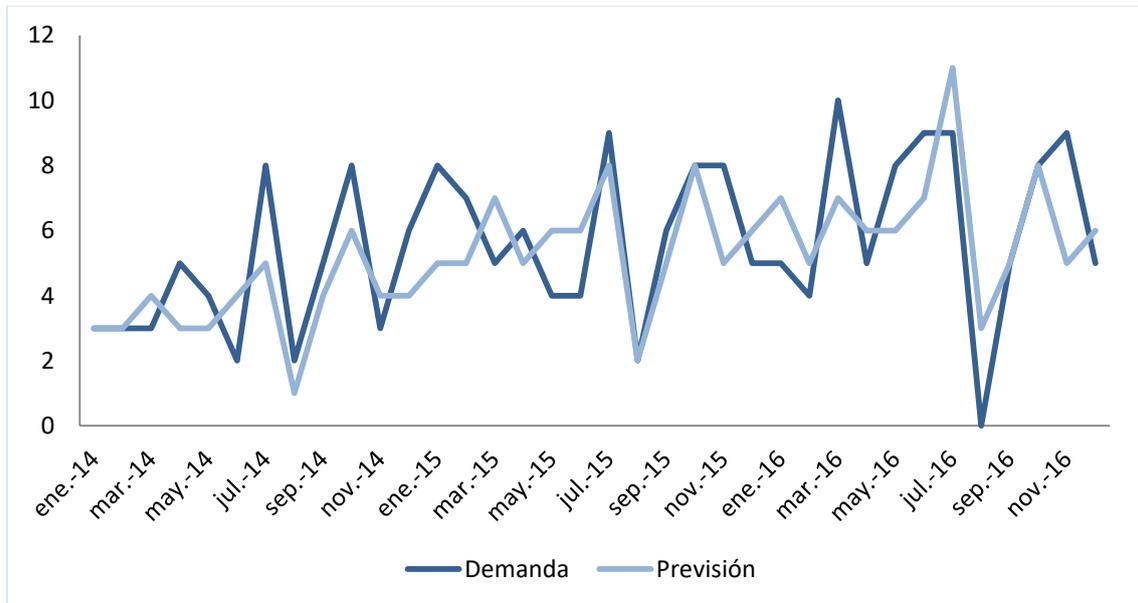


Ilustración 4-15. Demanda real y previsión pasada calculada a través del método Theta para la línea de túneles de lavado automático

Para la línea de túneles de lavado automático puede observarse que el ajuste de las previsiones a la demanda real es considerablemente peor que para la línea de puentes. Esto podría ser en parte debido a la gran diferencia entre los niveles de producción de ambas secciones. En este sentido, la curva de los pronósticos sigue en líneas generales la forma de la de la demanda, aunque comete errores bastante marcados en varios periodos como en julio de 2014, enero de 2015, noviembre de 2015, marzo de 2016 o noviembre de 2016.

Los errores de ajuste medios son los siguientes:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
THT (0,2) T-12	3,36	1,83	1,53	26,51%	32,48%

Tabla 4-6. Error de ajuste medio del método Theta para la línea de túneles de lavado automático

Son, como intuía en el gráfico comparativo de la previsión y la demanda real, bastante más elevados que los de la línea anterior.

Por otro lado, los cálculos correspondientes a los periodos de 2017 son los expuestos a continuación:

Año	Mes	Previsión	Demanda real	Error de pronóstico absoluto	Error de pronóstico porcentual
2017	1	7	4	3	75,00%
2017	2	6	7	1	14,29%
2017	3	8	8	0	0,00%
2017	4	6	7	1	14,29%
2017	5	6	16	10	62,50%
2017	6	7	9	2	22,22%
2017	7	11	4	7	175,00%
2017	8	3	1	2	200,00%
2017	9	7	4	3	75,00%
2017	10	10	6	4	66,67%
2017	11	6	3	3	100,00%
2017	12	6	3	3	100,00%

Tabla 4-7. Demanda real y previsión futura calculada a través del método Theta para la línea de túneles de lavado automático

En este caso, las previsiones calculadas por el modelo Theta son bastante erróneas ya que tan solo en 3 de los 12 periodos son inferiores al 50% y se iguala o supera el 100% en 4 ocasiones. Este hecho se evidencia aún más en la gráfica correspondiente:

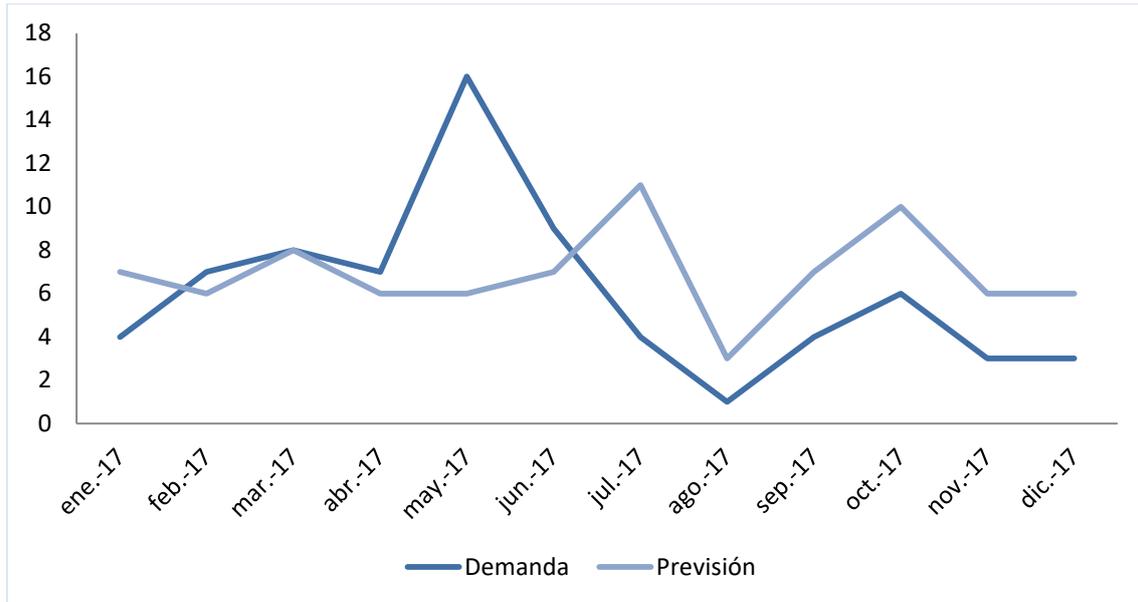


Ilustración 4-16. Demanda real y previsión futura calculada a través del método Theta para la línea de túneles de lavado automático

En el gráfico se visualiza más claramente la gran diferencia existente entre la curva de demanda y los pronósticos, que se alejan claramente, sobre todo a partir del mes de mayo, en que la demanda crece de una manera muy acentuada.

El resultado de los errores de acierto medio se muestra en la siguiente tabla:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
THT (0,2) T-12	17,58	4,19	3,25	75,41%	52,70%

Tabla 4-8. Error de acierto medio del método Theta para la línea de túneles de lavado automático

Son unos resultados de error bastante más elevados que en la línea anterior. A continuación, se aplica el modelo a las otras dos líneas restantes.

4.2.3 Línea de Lavado de Vehículos Industriales

En esta ocasión se han calculado los pronósticos por el método Theta de la línea de puentes para el lavado de vehículos industriales, la tercera en cuanto a volumen de producción. Tras introducir los datos en PrevGIP, los resultados obtenidos son los siguientes:

Año	Mes	Previsión	Demanda real	Error de pronóstico absoluto	Error de pronóstico porcentual
2014	1	12	12	0	0,00%
2014	2	19	19	0	0,00%
2014	3	15	15	0	0,00%
2014	4	23	19	4	21,05%
2014	5	24	22	2	9,09%
2014	6	18	17	1	5,88%
2014	7	31	36	5	13,89%
2014	8	7	5	2	40,00%
2014	9	21	23	2	8,70%
2014	10	20	24	4	16,67%
2014	11	20	16	4	25,00%
2014	12	10	8	2	25,00%
2015	1	11	13	2	15,38%
2015	2	17	17	0	0,00%
2015	3	14	13	1	7,69%
2015	4	21	18	3	16,67%
2015	5	22	22	0	0,00%
2015	6	17	19	2	10,53%
2015	7	30	25	5	20,00%
2015	8	6	7	1	14,29%
2015	9	21	18	3	16,67%
2015	10	19	14	5	35,71%
2015	11	17	20	3	15,00%
2015	12	9	11	2	18,18%
2016	1	11	8	3	37,50%
2016	2	16	15	1	6,67%
2016	3	13	13	0	0,00%
2016	4	19	21	2	9,52%
2016	5	21	19	2	10,53%
2016	6	16	13	3	23,08%
2016	7	27	23	4	17,39%
2016	8	5	8	3	37,50%
2016	9	20	23	3	13,04%
2016	10	19	13	6	46,15%
2016	11	17	19	2	10,53%
2016	12	9	11	2	18,18%

Tabla 4-9. . Demanda real y previsión pasada calculada a través del método Theta para la línea de puentes de lavado de vehículos industriales

En los cálculos de las previsiones para esta línea no aparecen puntos con errores tan grandes como en el caso anterior. En este sentido el punto peor explicado es el de octubre de 2016,

con un error del 46,15%. En el gráfico siguiente se representa el valor de la demanda y el pronóstico calculado para cada periodo del histórico.

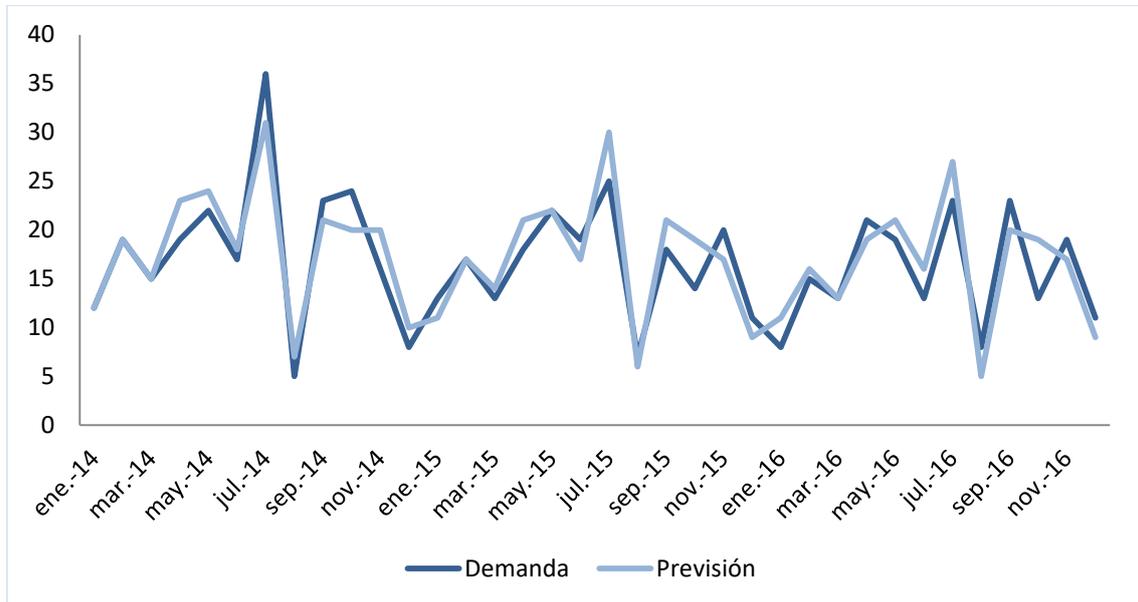


Ilustración 4-17. Demanda real y previsión pasada calculada a través del método Theta para la línea de lavado de vehículos industriales

En el gráfico puede observarse, más claramente, cómo la curva de la previsión calculada sigue de una forma bastante acertada a la de la demanda real observada, desviándose de ésta en un porcentaje aceptable. Ello se refleja en los errores medios, que se exponen a continuación:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
THT (0,2) T-12	7,94	2,82	2,33	15,71%	15,08%

Tabla 4-10. Error de ajuste medio del método Theta para la línea de lavado de vehículos industriales

El modelo ofrece, por tanto, un grado de acierto en los pronósticos de los periodos pasados bastante aceptables, con una tasa de error absoluto medio porcentual de tan solo un 15,71%. A continuación se calculan las previsiones para los valores futuros con el objetivo de evaluar si el modelo continúa siendo igual de efectivo.

Año	Mes	Previsión	Demanda real	Error de pronóstico absoluto	Error de pronóstico porcentual
2017	1	10	20	10	50,00%
2017	2	16	29	13	44,83%
2017	3	13	27	14	51,85%
2017	4	20	12	8	66,67%
2017	5	21	28	7	25,00%
2017	6	16	21	5	23,81%
2017	7	28	19	9	47,37%
2017	8	6	6	0	0,00%
2017	9	19	23	4	17,39%
2017	10	18	13	5	38,46%
2017	11	17	12	5	41,67%
2017	12	9	4	5	125,00%

Tabla 4-11. Demanda real y previsión futura calculada a través del método Theta para la línea de lavado de vehículos industriales

En la tabla anterior, en la cual se representan los valores de demanda real, previsión y error de los periodos de 2017, puede observarse como la fiabilidad del modelo ha bajado considerablemente, siendo en el 30% de los casos menores al 50%. Incluso llega a aparecer, en el último periodo, un error de pronóstico del 125%.

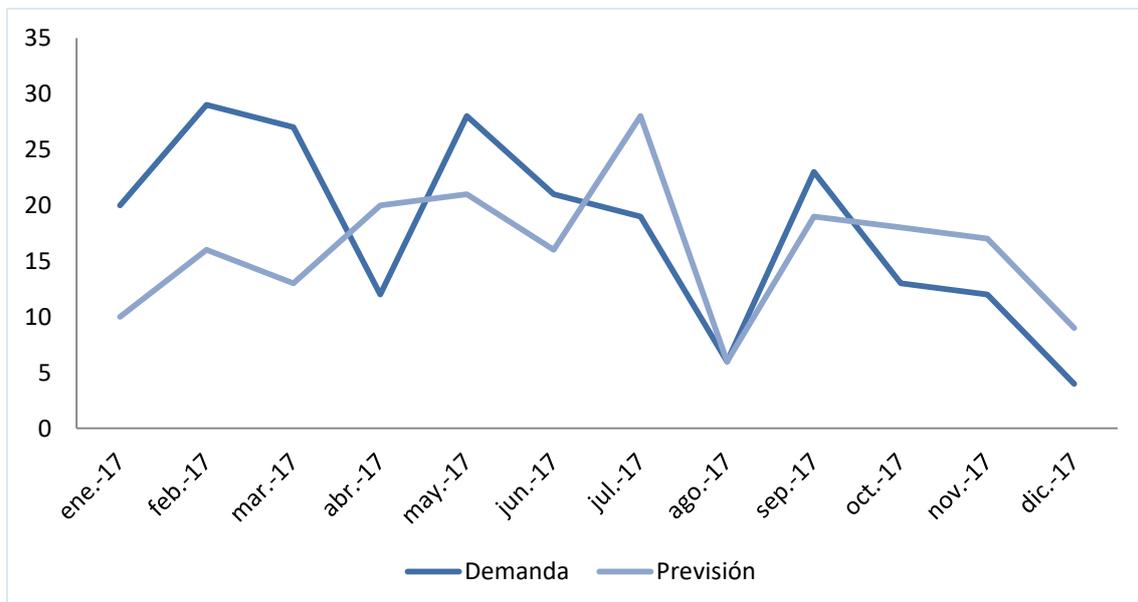


Ilustración 4-18. Demanda real y previsión futura calculada a través del método Theta para la línea de lavado de vehículos industriales

En el gráfico se visualiza más claramente la diferencia entre los valores reales y pronosticados, que distan bastante en la mayoría de los periodos. En cuanto a los valores medios de los errores de acierto, se representan en la siguiente tabla:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
THT (0,2) T-12	64,58	8,04	7,08	44,34%	41,75%

Tabla 4-12. Error de acierto medio del método Theta para la línea de lavado de vehículos industriales

En conclusión, el modelo Theta ofrece resultados muy buenos en cuanto al pronóstico de los valores pasados. Sin embargo, en su proyección hacia 2017 el grado de acierto es muy inferior.

4.2.4 Línea de Centros de Lavado

La línea de Centros de Lavado es la última del análisis y la segunda en cuanto volumen de fabricación. Para ella, los resultados obtenidos, con la ayuda de PrevGIP, a través de la aplicación del método Theta han sido los siguientes:

Año	Mes	Previsión	Demanda real	Error de pronóstico absoluto	Error de pronóstico porcentual
2014	1	21	21	0	0,00%
2014	2	29	23	6	26,09%
2014	3	29	17	12	70,59%
2014	4	32	39	7	17,95%
2014	5	33	54	21	38,89%
2014	6	50	59	9	15,25%
2014	7	54	39	15	38,46%
2014	8	11	12	1	8,33%
2014	9	39	27	12	44,44%
2014	10	40	35	5	14,29%
2014	11	36	29	7	24,14%
2014	12	22	19	3	15,79%
2015	1	19	14	5	35,71%
2015	2	25	21	4	19,05%
2015	3	26	23	3	13,04%
2015	4	30	27	3	11,11%
2015	5	29	24	5	20,83%
2015	6	37	38	1	2,63%
2015	7	39	43	4	9,30%

2015	8	9	6	3	50,00%
2015	9	29	36	7	19,44%
2015	10	32	33	1	3,03%
2015	11	30	33	3	9,09%
2015	12	20	20	0	0,00%
2016	1	18	21	3	14,29%
2016	2	26	28	2	7,14%
2016	3	27	28	1	3,57%
2016	4	33	35	2	5,71%
2016	5	32	37	5	13,51%
2016	6	45	45	0	0,00%
2016	7	47	54	7	12,96%
2016	8	10	16	6	37,50%
2016	9	41	32	9	28,13%
2016	10	42	32	10	31,25%
2016	11	37	55	18	32,73%
2016	12	26	29	3	10,34%

Tabla 4-13. Demanda real y previsión pasada calculada a través del método Theta para la línea de Centros de Lavado

A simple vista se observan unos resultados bastante aceptables, aunque existen algunos puntos con porcentajes de error muy elevados como por ejemplo, marzo de 2014, con un 70,59% de error; o agosto de 2015, con un 50%. Sin embargo, por lo general, existe una distancia entre la demanda real observada y la pronosticada ajustada y regular.

Este hecho se refleja en la siguiente gráfica, la cual representa el nivel de demanda y valores pronosticados para cada periodo del histórico.

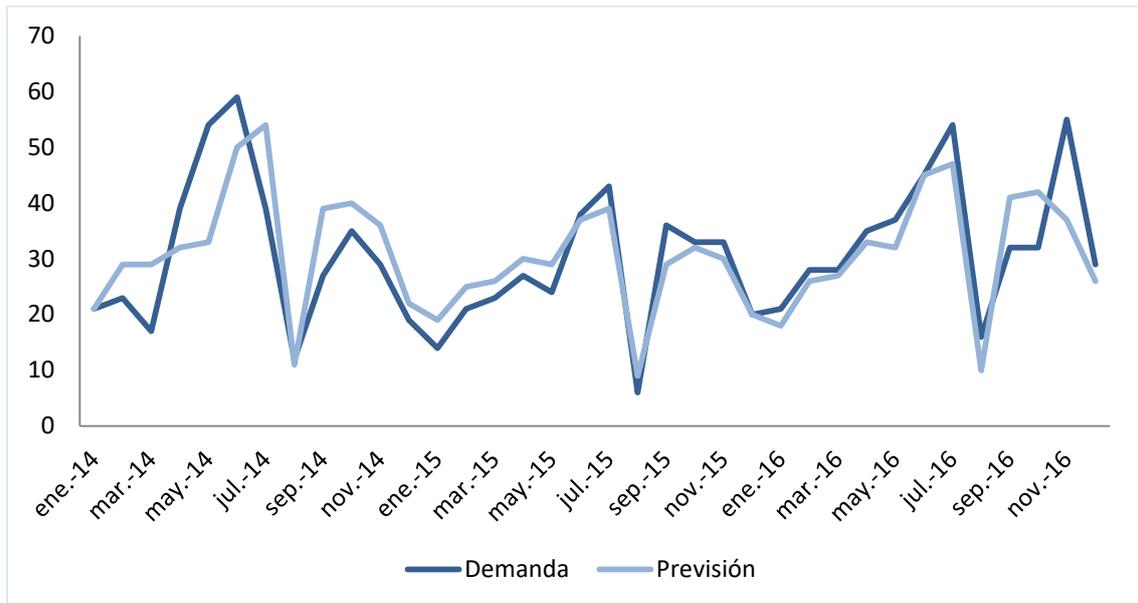


Ilustración 4-19. Demanda real y previsión pasada calculada a través del método Theta para la línea de Centros de Lavado

Los valores medios de los errores de ajuste son representados en la siguiente tabla:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
THT (0,2) T-12	55,97	7,48	5,64	19,57%	18,64%

Tabla 4-14. Error de ajuste medio del método Theta para la línea de Centros de Lavado

A continuación se ha aplicado el modelo de previsión a los valores futuros, en este caso, a los de 2017, con el objetivo de comprobar si la adaptación del modelo a los periodos futuros es tan buena como al de los pasados. Los resultados se muestran a continuación:

Año	Mes	Previsión	Demanda real	Error de pronóstico absoluto	Error de pronóstico porcentual
2017	1	23	22	1	4,55%
2017	2	32	36	4	11,11%
2017	3	34	44	10	22,73%
2017	4	41	27	14	51,85%
2017	5	39	48	9	18,75%
2017	6	53	66	13	19,70%
2017	7	55	67	12	17,91%
2017	8	12	21	9	42,86%
2017	9	42	43	1	2,33%
2017	10	45	47	2	4,26%
2017	11	42	44	2	4,55%
2017	12	27	35	8	22,86%

Tabla 4-15. Demanda real y previsión futura calculada a través del método Theta para la línea de Centros de Lavado

Nuevamente, no aparecen demasiados valores con un error muy elevado. Destacan en este sentido, abril y agosto de 2017; en el primero por una planificación al alza, y en el segundo por una a la baja. De manera gráfica se observan estos resultados a continuación:

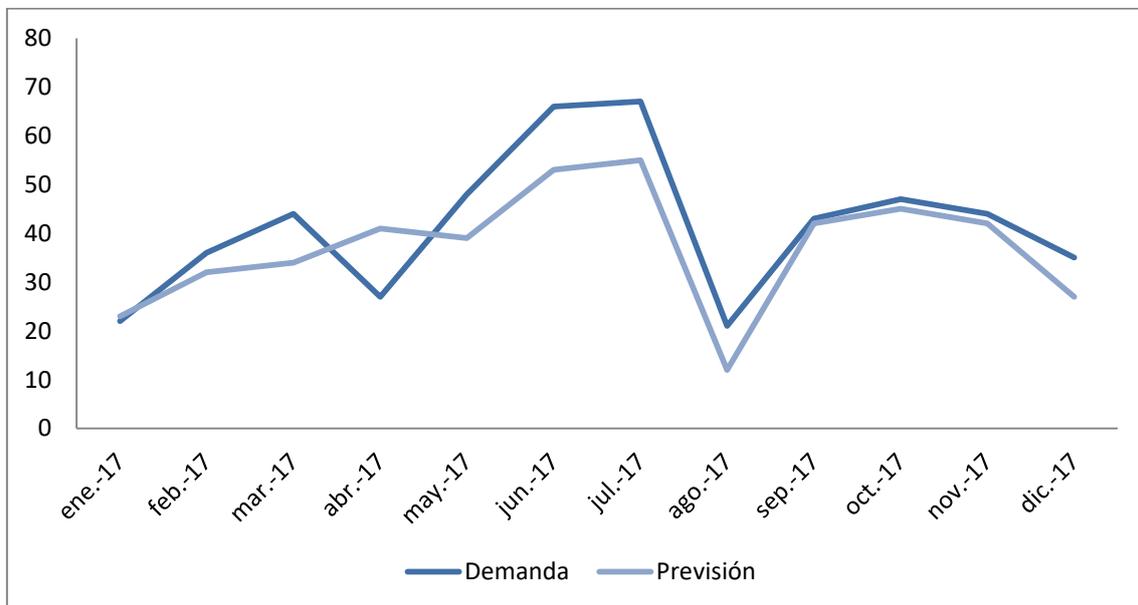


Ilustración 4-20. Demanda real y previsión futura calculada a través del método Theta para la línea de Centros de Lavado

Por último, se representan los errores de acierto medios, que, como puede comprobarse, son los primeros de las cuatro líneas analizadas para los que el error porcentual absoluto medio de acierto es menor al error de ajuste, aunque los demás indicadores no lo son.

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
THT (0,2) T-12	71,75	8,47	7,08	18,62%	19,75%

Tabla 4-16. Error de acierto medio del método Theta para la línea de Centros de Lavado

4.2.5 Conclusiones. Aplicación del método Theta.

Una vez aplicado el método Theta a las cuatro líneas, se han podido observar rendimientos muy diferentes en cada una de ellas. Estas diferencias son debidas a los diferentes comportamientos propios de la demanda. En este sentido, características como el volumen de fabricación, la estabilidad de la serie, los lanzamientos regulares de nuevos modelos, la influencia de la acción comercial, etc., los cuales son muy diferentes en cada una de las líneas, provocan que el modelo de previsión sea capaz de explicar unas mejor que otras.

4.3 Cálculo de las previsiones. Modelo Causal.

En este apartado se han calculado las previsiones para 2017 a través del modelo causal desarrollado en el presente proyecto. Para ello, se ha tomado como base los datos de demanda observada por la organización, en cada una de las líneas de producción, en los periodos comprendidos entre enero de 2014 y diciembre de 2017. Además, se han considerado las variables causales pertinentes en cada una de las divisiones.

En primer lugar, se ha tenido en cuenta la variable causal referente a los días laborables de cada periodo ya que se ha observado que no se mantienen constantes año tras año. Esto es debido principalmente al movimiento sobre el calendario de algunas festividades, como por ejemplo la Pascua, la celebración o no de “puentes” por decisión de la organización, el número de días declarados anualmente como no productivos fruto de la devolución de la bolsa de horas de los trabajadores, las paradas de planta de verano y navidad, etc. Todo ello provoca que haya una variación importante de los días laborables de un mismo mes en diferentes años. Por ello, se han obtenido los datos de los calendarios propios de ISTOBAL para obtener esta variable explicativa, que ha sido aplicada a todas las líneas de producción.

Periodo	Número de días laborables	Periodo	Número de días laborables	Periodo	Número de días laborables
1	20	13	17	25	17
2	20	14	16	26	21
3	20	15	19	27	19
4	19	16	18	28	20
5	21	17	20	29	21
6	21	18	22	30	22
7	23	19	23	31	21
8	5	20	6	32	8
9	21	21	20	33	20
10	22	22	20	34	19
11	20	23	21	35	21
12	14	24	15	36	11

Tabla 4-17. Variable explicativa (número de días laborables)

En segundo lugar, se consideró tener en cuenta una variable explicativa que hiciera referencia a la influencia sobre la demanda de la participación de ISTOBAL en Ferias y Eventos. Sin embargo, no se conservaba desde ISTOBAL MANUFACTURING un histórico de los periodos en qué se habían producido dichos eventos.

Por último, se han tenido en cuenta diferentes variables propias de cada una de las líneas, como el número de modelos que coexisten en cada periodo o el futuro lanzamiento o desaparición de alguno de ellos etc. Su valor, al no ser generalizado para todas las secciones, se expondrá en cada caso.

En los siguientes apartados se calculan las previsiones aplicando el Modelo Causal, para cada una de las cuatro líneas de producción de ISTOBAL, siguiendo la siguiente estructura:

- Definición de variables causales: se presentan las variables propias de cada línea (además de las variables explicativas mes, año y número de días laborables, que afectan a todas ellas).
- Resultados de las variables de decisión: se exponen los resultados de la influencia que el modelo de previsión ha calculado para cada una de las variables explicativas.
- Cálculo del Error de Ajuste: se muestran los errores de pronóstico obtenidos por el modelo en su aplicación a los valores pasados para esta línea.
- Cálculo del Error de Acierto: se muestran los errores de acierto obtenidos por el modelo en su aplicación a los valores futuros para esta línea.
- Identificación de valores extraordinarios: en el caso de existir se incluirán variables causales nuevas que y se recalcularán de las previsiones.
- Conclusiones y comparación con el Método Theta aplicado anteriormente.

4.3.1 Línea de lavado automático de puentes

Definición de variables causales

Actualmente la línea de puentes cuenta con once modelos en el mercado, cada uno de los cuales se encuentra en una fase de su ciclo de vida diferente.

Para tener en cuenta este hecho, se han incluido en el modelo dos variables explicativas que hacen referencia al número de modelos de la línea situados en un estado de su ciclo de vida diferente. A saber: el número de modelos en estado de introducción y el número de modelos en estado de crecimiento-madurez.

Con ello se ha podido calcular la influencia, sobre las ventas totales de la línea, del lanzamiento de una nueva gama o del paso de un modelo a un estado más maduro dentro del mercado.

Para ello, se han obtenido, en primer lugar, las fechas en las que cada uno de los modelos fue dado de alta en el sistema y tras lo cual se comenzaron a dar las primeras ventas. Y en segundo lugar, la fecha en la que éstas comenzaron a ser estables y se alcanzaron los niveles de demanda esperados por parte de los gestores de producto. Con ello se han contabilizado, en cada uno de los periodos, los modelos que se encuentran en uno u otro estado.

Periodo	Número de modelos en estado de introducción	Número de modelos en estado de madurez
1	0	7
2	0	7
3	0	7
4	1	7
5	1	7
6	1	7
7	1	7
8	1	7
9	1	7
10	1	7
11	2	7
12	3	7
13	3	7
14	3	7
15	3	7
16	3	7
17	3	7
18	3	7
19	3	7
20	3	7
21	3	7
22	3	7
23	3	7

24	3	7
25	3	7
26	3	7
27	3	7
28	3	7
29	4	7
30	4	7
31	4	7
32	3	8
33	3	8
34	3	8
35	2	9
36	2	9

Tabla 4-18. Variable explicativa (modelos por fase de su ciclo de vida)

Resultados de las variables de decisión

Una vez añadida la nueva variable “modelos por fase de su ciclo de vida” al modelo de programación matemática, se han lanzado los cálculos para esta línea, siendo los resultados los siguientes:

Los valores tomados por la variable P_a (valor de la previsión para el año a), representan la tendencia de la demanda de la línea y muestran una tendencia ascendente aunque ligeramente descendente en el último año:

Año	Previsión-Año
2014	0
2015	24
2016	20

Tabla 4-19. Valor de la tendencia para la línea de puentes

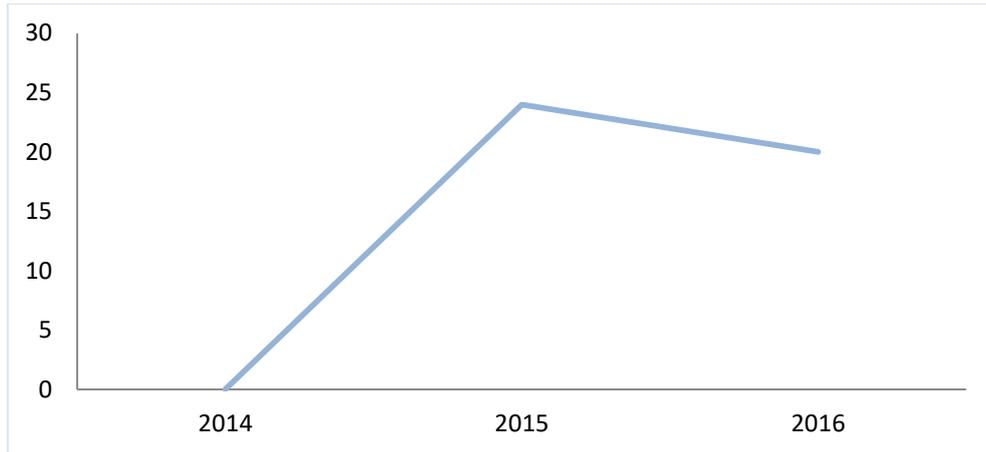


Ilustración 4-21. Gráfico de la tendencia para la línea de puentes

Los valores aportados por la variable P_m (valor de la previsión para el mes m) que representan la estacionalidad de la demanda de la línea son los siguientes:

Mes	Previsión-Mes
Enero	0
Febrero	18
Marzo	16
Abril	30
Mayo	24
Junio	34
Julio	24
Agosto	0
Septiembre	14
Octubre	28
Noviembre	18
Diciembre	0

Tabla 4-20. Valor de la estacionalidad para la línea de puentes

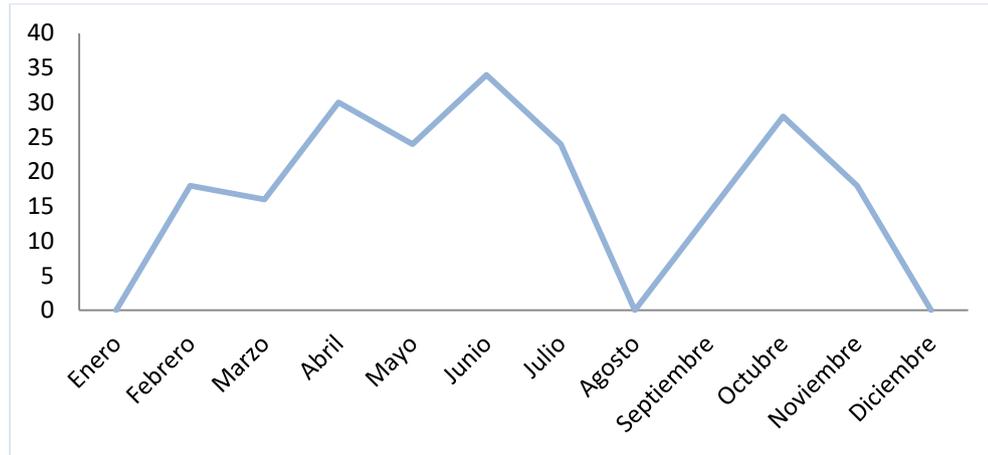


Ilustración 4-22. Gráfico de la estacionalidad para la línea de puentes

En el caso de la línea de Puentes se observa un descenso de la demanda en los meses de enero, agosto y diciembre mientras que asciende durante el segundo trimestre y los dos últimos meses del año.

Los valores de la variable $PrevDL_t$ (valor de la previsión para el número de días laborables l) son:

Días Laborables	Previsión-Días Laborables	Días Laborables	Previsión-Días Laborables
1	0	16	46
2	0	17	40
3	0	18	38
4	0	19	57
5	24	20	71
6	0	21	70
7	0	22	68
8	18	23	72
9	0	24	0
10	0	25	0
11	42	26	0
12	0	27	0
13	0	28	0
14	57	29	0
15	59	30	0

Tabla 4-21. Valor de la previsión por días laborables para la línea de puentes

Por último, los resultados para las variables causales número de modelos en estado de introducción y número de modelos en estado de crecimiento-madurez, han sido:

Número de modelos en estado de introducción	Influencia
1	0
2	12
3	3
4	16
5	0
6	0
7	0
8	0
9	0
10	0
11	0

Tabla 4-22. Variable explicativa: número de modelos en estado de introducción.

Número de modelos en estado de madurez	Influencia
1	0
2	0
3	0
4	0
5	0
6	0
7	0
8	0
9	0
10	0
11	0

Tabla 4-23. Variable explicativa: número de modelos en estado de introducción

Estos resultados reflejan que la introducción de un nuevo modelo a la línea de producción tiene un impacto sobre la demanda total de dicha línea. Sin embargo, conforme el modelo va madurando y la demanda se estabiliza disminuye su influencia, de modo que el paso del modelo al estado de madurez no la hace disminuir ni aumentar.

Cálculo del error de ajuste

A continuación se exponen los resultados de previsión que se han obtenido con el modelo causal, además de los valores de demanda real y los errores de pronóstico, errores absolutos y errores porcentuales para cada periodo:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2014	1	71	71	0	0	0,00%
2014	2	89	84	-5	5	5,90%
2014	3	87	87	0	0	0,00%
2014	4	75	75	0	0	0,00%
2014	5	94	94	0	0	0,00%
2014	6	104	104	0	0	0,00%
2014	7	95	95	0	0	0,00%
2014	8	24	24	0	0	0,00%
2014	9	84	84	0	0	0,00%
2014	10	95	95	0	0	0,00%
2014	11	101	101	0	0	0,00%
2014	12	60	60	0	0	0,00%
2015	1	67	67	0	0	0,00%
2015	2	91	91	0	0	0,00%
2015	3	96	96	0	0	0,52%
2015	4	94	94	0	0	0,00%
2015	5	110	124	14	14	12,95%
2015	6	128	128	0	0	0,00%
2015	7	146	122	-24	24	16,78%
2015	8	27	27	0	0	0,00%
2015	9	117	102	-14	14	12,39%
2015	10	116	116	0	0	0,00%
2015	11	116	112	-4	4	3,45%
2015	12	86	86	0	0	0,00%
2016	1	59	59	0	0	0,42%
2016	2	111	111	0	0	0,00%
2016	3	101	101	0	0	0,00%
2016	4	123	123	0	0	0,00%
2016	5	132	125	-7	7	5,30%
2016	6	136	132	-4	4	2,57%
2016	7	129	129	0	0	0,00%
2016	8	40	40	0	0	0,00%
2016	9	107	107	0	0	0,00%
2016	10	107	107	0	0	0,00%
2016	11	120	120	0	0	0,00%
2016	12	73	73	0	0	0,00%

Tabla 4-24. Demanda y Previsión 2014-2016 para la línea de puentes

Representado de forma gráfica la demanda real de la línea y la previsión que se ha calculado se puede apreciar que el ajuste realizado por el modelo se asemeja considerablemente a la demanda original.

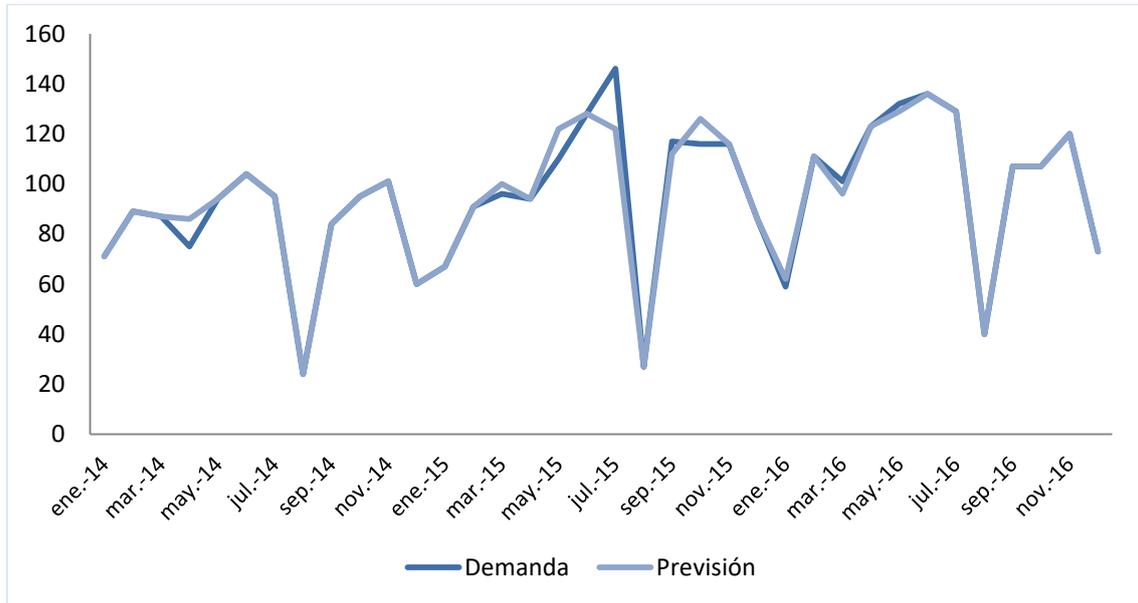


Ilustración 4-23. Comparación Demanda y Previsión 2014-2016. Línea de puentes

Además se han calculado los errores de ajuste que se han considerado más representativos: **MSE** (Mean Squared Error o Error Cuadrático Medio), **RMSE** (Root Mean Square Error o Raíz del Error Cuadrático Medio), **MAE** (Mean Absolute Error o Error Medio Absoluto), **MAPE** (Mean Absolute Percentage Error o Error Medio Porcentual Absoluto) y **WMAPE** (Weighted Mean Absolute Percentage Error o Error Medio Porcentual Absoluto Ponderado).

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	29,83	5,46	2	1,67%	1,70%

Tabla 4-25. Error de ajuste del modelo causal para la línea de Puentes de Lavado Automático

Como ya se entreveía en la representación anterior, los indicadores corroboran que el modelo de previsión causal explica de un modo bastante satisfactorio el comportamiento pasado de la demanda de esta línea. Ello se refleja también en la no aparición de ningún valor extraordinario.

Cálculo del error de acierto

Para comprobar si el modelo da resultados igual de satisfactorios explicando el comportamiento futuro como el pasado, se han calculado las previsiones para el 2017, suponiendo estos valores desconocidos, para posteriormente compararlos con la demanda que se dio realmente en esos periodos. De este modo se ha calculado el error de acierto del modelo.

Para ello, en primer lugar, se han supuesto los valores, para los 12 nuevos periodos a prever, de todas las variables consideradas en el modelo: valor de la previsión para el año a, valor de la previsión para el mes m, valor de la previsión para el número de días laborables l, número de modelos en estado de introducción y número de modelos en estado de madurez.

Para estimar la primera variable, valor de la previsión para el año a, se ha aplicado el método de Holt a los resultados de años anteriores. De este modo se ha tenido una estimación de la tendencia que tendrá la línea al año siguiente.

Año	Previsión-Año
2014	0
2015	24
2016	20
2017	35

Tabla 4-26. Tendencia 2017. Línea de Puentes de Lavado Automático

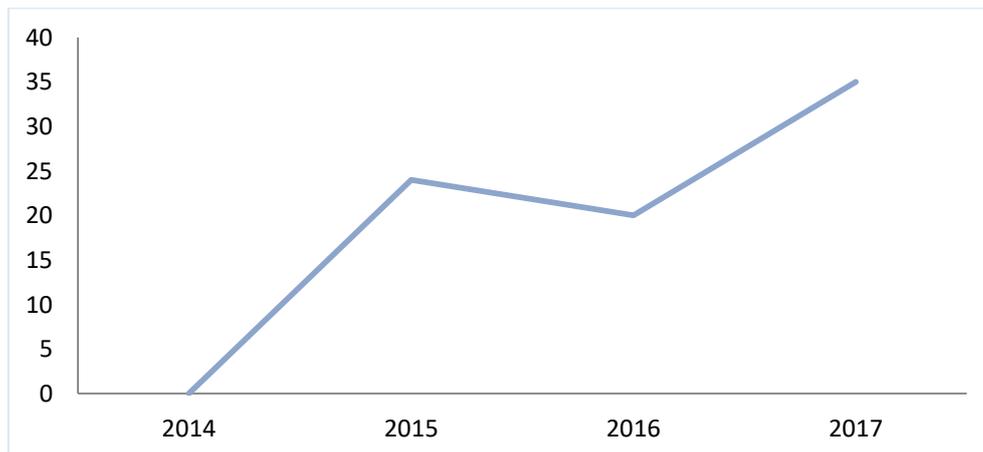


Ilustración 4-24. Tendencia 2017. Línea de Puentes de Lavado Automático

En segundo lugar, se le ha dado a la variable valor de la previsión para el mes m los mismos valores que fueron resultado de la aplicación del modelo causal en los periodos de 2014 a 2016. Esta variable representa la estacionalidad de la línea, de modo que es independiente del año.

Mes	Previsión-Mes
1	0
2	18
3	16
4	30
5	24
6	34
7	24
8	0
9	14
10	28
11	18
12	0

Tabla 4-27. Valores de estacionalidad para 2017

La tercera variable, valor de la previsión para el número de días laborables l, al tratarse de un dato proporcionado directamente de los acuerdos de calendario realizados cada inicio de año entre los trabajadores, simplemente se han recopilado los correspondientes a 2017.

Periodo	Número de días laborables	Periodo	Número de días laborables
37	17	43	21
38	20	44	8
39	23	45	19
40	16	46	20
41	22	47	21
42	22	48	14

Tabla 4-28. Variable explicativa (número de días laborables) para 2017

Por último, los valores para las dos últimas variables se han tomado iguales a las del último periodo estudiado, el periodo 36, ya que se ha supuesto que no va a haber ningún lanzamiento de un nuevo modelo durante 2017.

Periodo	Número de modelos en estado de introducción	Número de modelos en estado de madurez
37	2	9
38	2	9
39	2	9
40	2	9
41	2	9
42	2	9

43	2	9
44	2	9
45	2	9
46	2	9
47	2	9
48	2	9

Tabla 4-29. Variable explicativa (modelos por fase de su ciclo de vida)

Una vez calculados los valores de las variables para para 2017, se han calculado las previsiones para dicho año siendo los resultados los expuestos en la siguiente tabla:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2017	1	86	75	11	11	12,79%
2017	2	94	124	-30	30	31,91%
2017	3	142	123	19	19	13,38%
2017	4	104	111	-7	7	6,73%
2017	5	140	127	13	13	9,29%
2017	6	125	137	-12	12	9,60%
2017	7	156	129	27	27	17,31%
2017	8	50	53	-3	3	6,00%
2017	9	108	106	2	2	1,85%
2017	10	126	134	-8	8	6,35%
2017	11	127	123	4	4	3,15%
2017	12	81	92	-11	11	13,58%

Tabla 4-30. Demanda y Previsión 2017 para la línea de puentes

Los errores de pronóstico alcanzan unos niveles relativamente bajos, siendo el mayor de ellos el correspondiente al mes de febrero, con un error de 30 unidades, equivalente a un 31,91%.

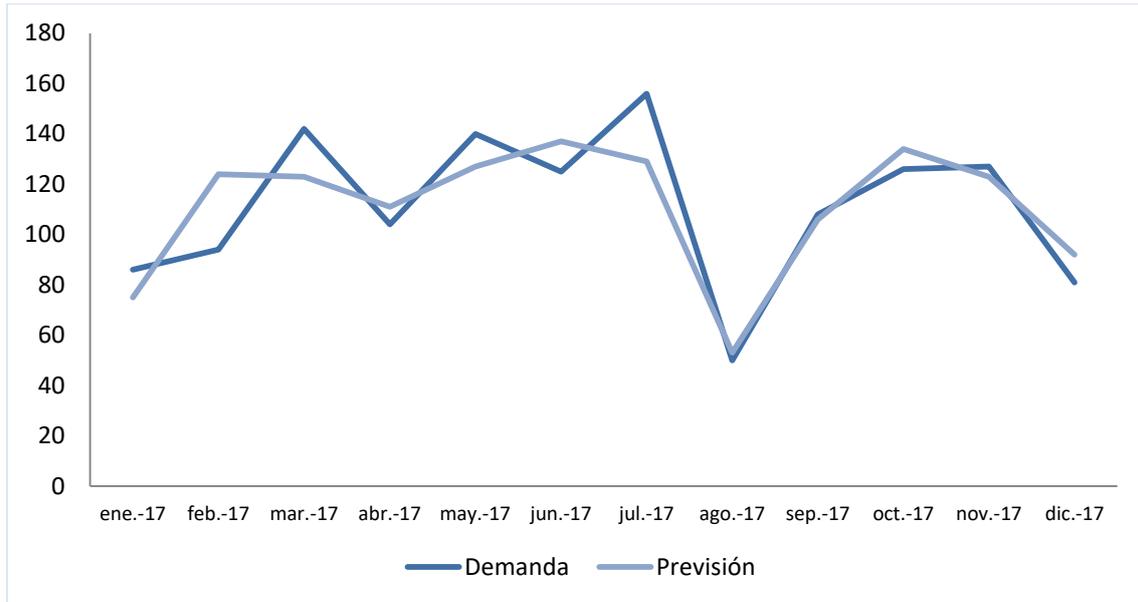


Ilustración 4-25. Comparación Demanda y Previsión 2017. Línea de puentes

De este modo, los valores de los errores de acierto medios del modelo son:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	223,92	14,96	12,25	11,00%	10,80%

Tabla 4-31. Error de acierto del modelo causal para la línea de puentes

Al comparar los resultados del Modelo Causal con el Método Theta, aplicado en el apartado anterior, se observa una diferencia considerable, sobre todo en cuanto a errores de ajuste. En este sentido, mientras que el Modelo Causal consigue un MAPE de un 1,67%, el Método Theta alcanza un 10,62% que, aunque es un valor muy aceptable, es bastante superior. De igual modo ocurre al considerar el MAE, que es de 2 unidades para el Modelo Causal y de 9,58 para el Método Theta.

En el siguiente gráfico se ha representado el Error Absoluto Porcentual para cada periodo, con el objetivo de reflejar las diferencias en cuanto al error cometido en cada momento por cada uno de los métodos utilizados.

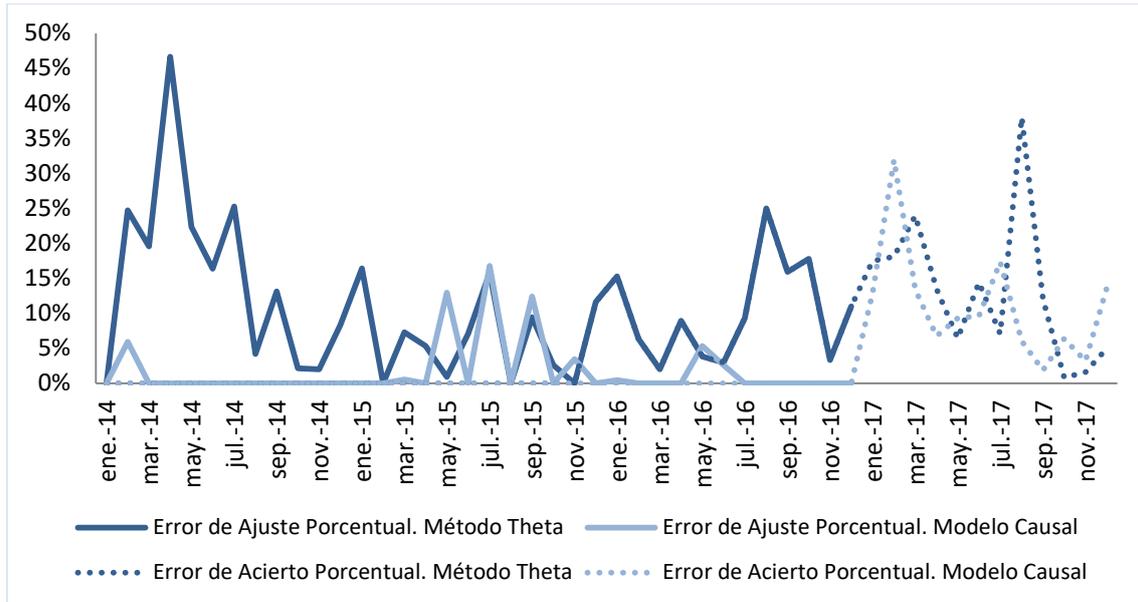


Ilustración 4-26. Comparación del Error Porcentual del Método Theta y el Modelo Causal para la línea de Puentes de Lavado Automático

Tras la comparación anterior se evidencia que el Modelo Causal obtiene unos resultados mejores en casi todos los periodos analizados. Sin embargo, al observar el último año estudiado, el correspondiente a los datos de errores de acierto, no se estima una diferencia tan marcada. En esta ocasión, el Modelo Causal obtiene un MAPE de un 11% y un MAE de 12,25 unidades mientras que el Método Theta alcanza un MAPE de un 13,18% y un MAE de 13,08 unidades.

Por tanto, se puede concluir que para la línea de Puentes de Lavado Automático, el Modelo Causal es capaz de explicar con mayor exactitud el comportamiento pasado de la demanda. Mientras que, por otro lado, ambos métodos se encuentran bastante igualados en cuando a Errores de Acierto aunque siguen siendo inferiores todos los indicadores del Modelo Causal.

4.3.2 Línea de túneles de lavado automático

Definición de variables causales

En esta línea se fabrican los túneles de lavado automático. Estas máquinas se componen de una línea, cuya longitud determina el cliente, sobre la que se distribuyen una serie de opcionales para el lavado automático de vehículos. Este carácter versátil hace que tan solo existan dos modelos en esta línea de producción de forma constante. Por ello, no se ha considerado la variable $PrevNM_{nm}$ (valor de la previsión para el número de modelos nm) para el cálculo de las previsiones de esta línea.

Resultados de las variables de decisión

Para el resto de variables, sus resultados se exponen a continuación:

Los valores aportados por la variable P_a (valor de la previsión para el año a) que representan la tendencia de la demanda de la línea son:

Año	Previsión-Año
2014	-1
2015	0
2016	0

Tabla 4-32. Valor de la tendencia para la línea de Túneles de Lavado Automático

Para esta línea aparece también una tendencia ascendente que has el segundo año se estabiliza.

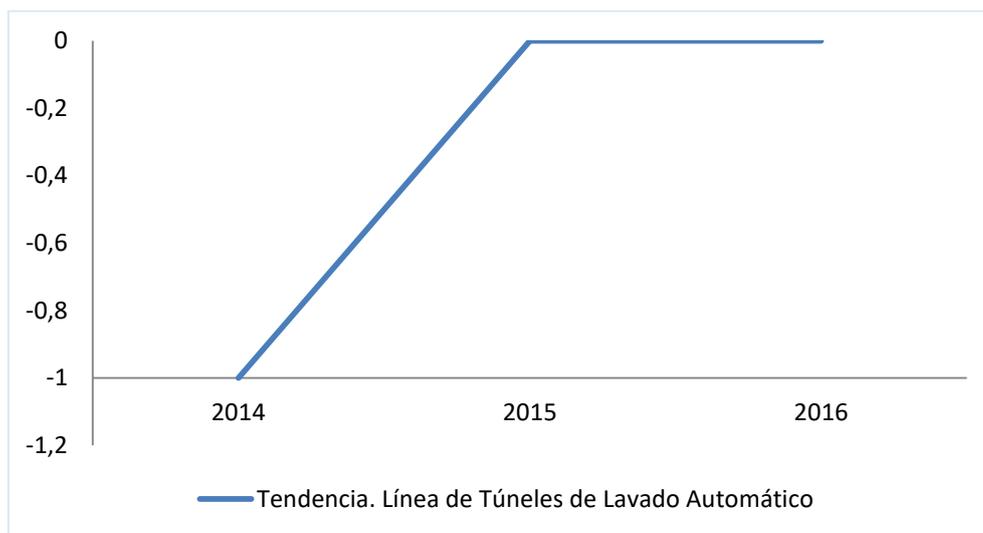


Ilustración 4-27. Gráfico de la tendencia para la línea de Túneles de Lavado Automático

Los valores aportados por la variable P_m (valor de la previsión para el mes m) que representan la estacionalidad de la demanda de la línea son:

Mes	Previsión-Mes
1	5
2	4
3	5

4	6
5	5
6	3
7	9
8	0
9	6
10	8
11	8
12	0

Tabla 4-33. Valor de la estacionalidad para la línea de túneles de lavado automático

La estacionalidad de los Túneles de Lavado Automático es similar a la de la sección anterior. Sin embargo en esta ocasión es más acentuada sobre todo durante el mes de julio, octubre y noviembre.

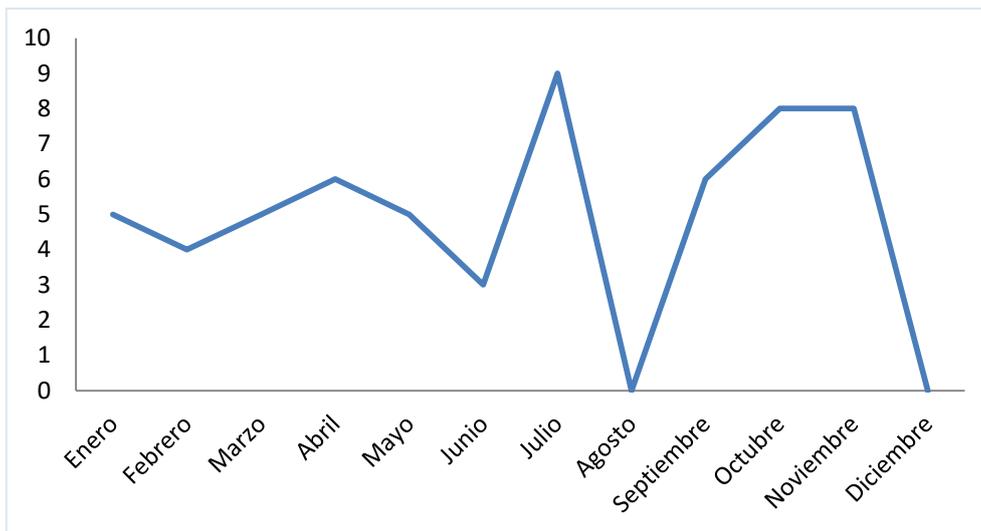


Ilustración 4-28. Gráfico de la estacionalidad para la línea de Túneles de Lavado Automático

Los valores aportados por la variable $PrevDL_l$ (valor de la previsión para el número de días laborables l) son:

Días Laborables	Previsión-Días Laborables	Días Laborables	Previsión-Días Laborables
1	0	16	3
2	0	17	0
3	0	18	0
4	0	19	0
5	3	20	-1
6	2	21	0
7	0	22	1
8	0	23	0
9	0	24	0
10	0	25	0
11	5	26	0
12	0	27	0
13	0	28	0
14	7	29	0
15	5	30	0

Tabla 4-34. Valor de la previsión por días laborables para la línea de túneles de lavado automático

Cálculo del error de ajuste

Para los periodos comprendidos entre enero de 2014 y diciembre de 2016, los resultados de las previsiones calculadas a través del modelo causal han sido las siguientes:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2014	1	3	3	0	0	0,00%
2014	2	3	2	1	1	33,33%
2014	3	3	3	0	0	0,00%
2014	4	5	5	0	0	0,00%
2014	5	4	4	0	0	0,00%
2014	6	2	2	0	0	0,00%
2014	7	8	8	0	0	0,00%
2014	8	2	2	0	0	0,00%
2014	9	5	5	0	0	0,00%
2014	10	8	8	0	0	0,00%
2014	11	3	6	-3	3	100,00%
2014	12	6	6	0	0	0,00%
2015	1	8	5	3	3	37,50%
2015	2	7	7	0	0	0,00%
2015	3	5	5	0	0	0,00%
2015	4	6	6	0	0	0,00%
2015	5	4	4	0	0	0,00%
2015	6	4	4	0	0	0,00%
2015	7	9	9	0	0	0,00%

2015	8	2	2	0	0	0,00%
2015	9	6	5	1	1	16,67%
2015	10	8	7	1	1	12,50%
2015	11	8	8	0	0	0,00%
2015	12	5	5	0	0	0,00%
2016	1	5	5	0	0	0,00%
2016	2	4	4	0	0	0,00%
2016	3	10	5	5	5	50,00%
2016	4	5	5	0	0	0,00%
2016	5	8	5	3	3	37,50%
2016	6	9	4	5	5	55,56%
2016	7	9	9	0	0	0,00%
2016	8	0	0	0	0	-
2016	9	5	5	0	0	0,00%
2016	10	8	8	0	0	0,00%
2016	11	9	8	1	1	11,11%
2016	12	5	5	0	0	0,00%

Tabla 4-35. Demanda y Previsión 2014-2016 para la línea de túneles de lavado automático

Comparando los resultados con los obtenidos para la línea de producción anterior, se observa claramente que, en esta ocasión, aparecen más periodos con errores de pronóstico elevados. De hecho algunos de ellos sobrepasan el 50% de error como son:

- Periodo 11: noviembre de 2014.
- Periodo 27: marzo de 2016.
- Periodo 30: junio de 2016.

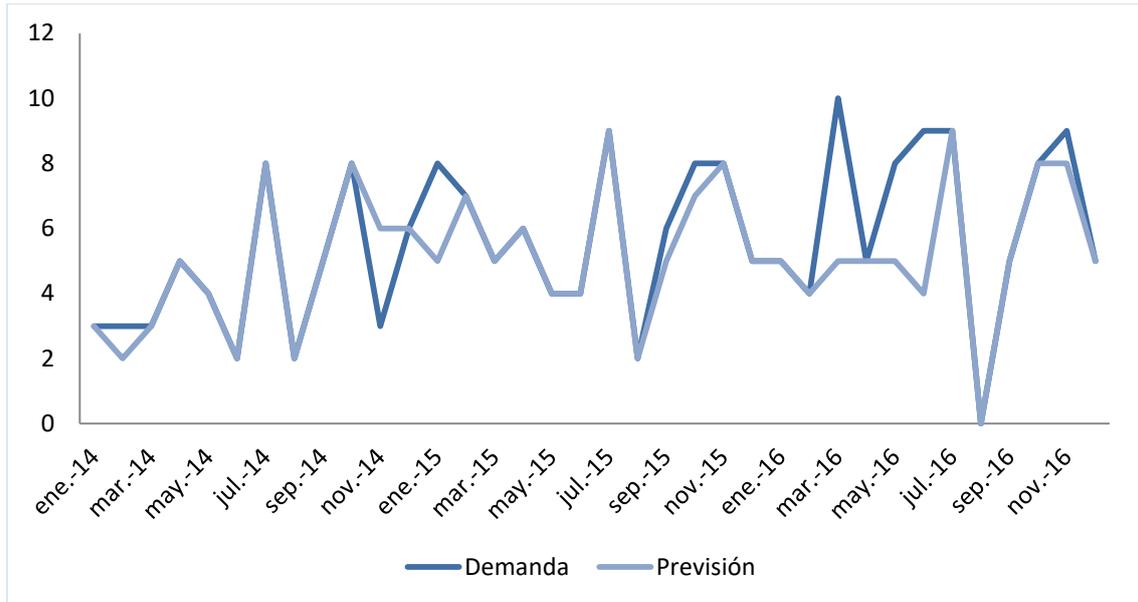


Ilustración 4-29. Comparación Demanda y Previsión 2014-2016 para la línea de túneles de lavado automático

Este hecho provoca, por tanto, que los errores medios de ajuste obtenidos sean significativamente mayores:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	2,25	1,50	0,64	9,84%	10,72%

Tabla 4-36. Error de ajuste del modelo causal para la línea de túneles de lavado automático

A continuación se han calculado las previsiones para el siguiente año y comprobado el grado de acierto del modelo con respecto a las previsiones de los periodos futuros.

Cálculo del error de acierto

Para ello, en primer lugar, se le han dado valor a las variables causales consideradas en el modelo para estos nuevos 12 periodos. Estos son: valor de la previsión para el año a , valor de la previsión para el mes m y valor de la previsión para el número de días laborables l .

Para estimar la primera variable, valor de la previsión para el año a , se ha aplicado el método de Holt a los resultados de años anteriores. De este modo se ha tenido una estimación de la tendencia que tendrá la línea al año siguiente.

Año	Previsión-Año
2014	-1
2015	0
2016	0
2017	1

Tabla 4-37. Cálculo tendencia 2017. Línea de túneles de lavado automático

En esta ocasión también se observa una tendencia marcadamente ascendente.

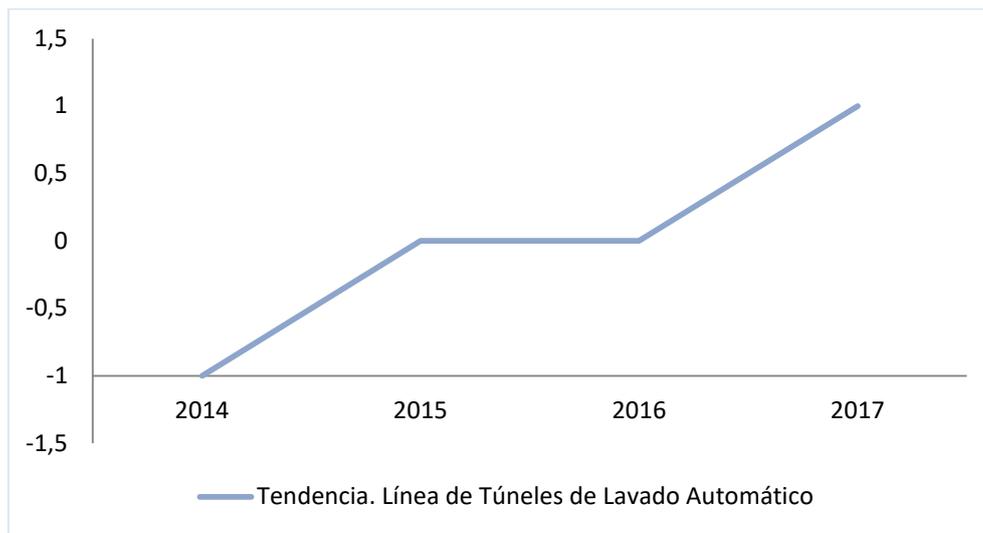


Ilustración 4-30. Tendencia 2017. Línea de Túneles de Lavado Automático

En segundo lugar, se le ha dado a la variable valor de la previsión para el mes m los mismos valores que fueron resultado de la aplicación del modelo causal en los periodos de 2014 a 2016. Esta variable representa la estacionalidad de la línea, de modo que es independiente del año.

Mes	Previsión-Mes
1	5
2	4
3	5
4	6
5	5
6	3
7	9
8	0
9	6
10	8
11	8
12	0

Tabla 4-38. Valores de estacionalidad para 2017. Línea de túneles de lavado automático

La tercera variable, valor de la previsión para el número de días laborables l , al tratarse de un dato proporcionado directamente de los acuerdos de calendario realizados cada inicio de año entre los trabajadores, simplemente se han recopilado los correspondientes a 2017.

Periodo	Número de días laborables	Periodo	Número de días laborables
37	17	43	21
38	20	44	8
39	23	45	19
40	16	46	20
41	22	47	21
42	22	48	14

Tabla 4-39. Variable explicativa (número de días laborables) para 2017

Con estos nuevos valores para cada una de las variables se ha relanzado el cálculo de los pronósticos, siendo los resultados los siguientes:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2017	1	4	6	-2	2	50,00%
2017	2	7	4	3	3	42,86%
2017	3	8	6	2	2	25,00%
2017	4	7	10	-3	3	42,86%
2017	5	16	7	9	9	56,25%
2017	6	9	5	4	4	44,44%
2017	7	4	10	-6	6	150,00%
2017	8	1	1	0	0	0,00%
2017	9	4	7	-3	3	75,00%
2017	10	6	8	-2	2	33,33%
2017	11	4	9	-5	5	125,00%
2017	12	3	8	-5	5	166,67%

Tabla 4-40. Demanda y Previsión 2017 para la línea de túneles de lavado automático

Al representar estos datos gráficamente, se evidencia que esta línea no es pronosticada con el mismo grado de exactitud que la anterior.

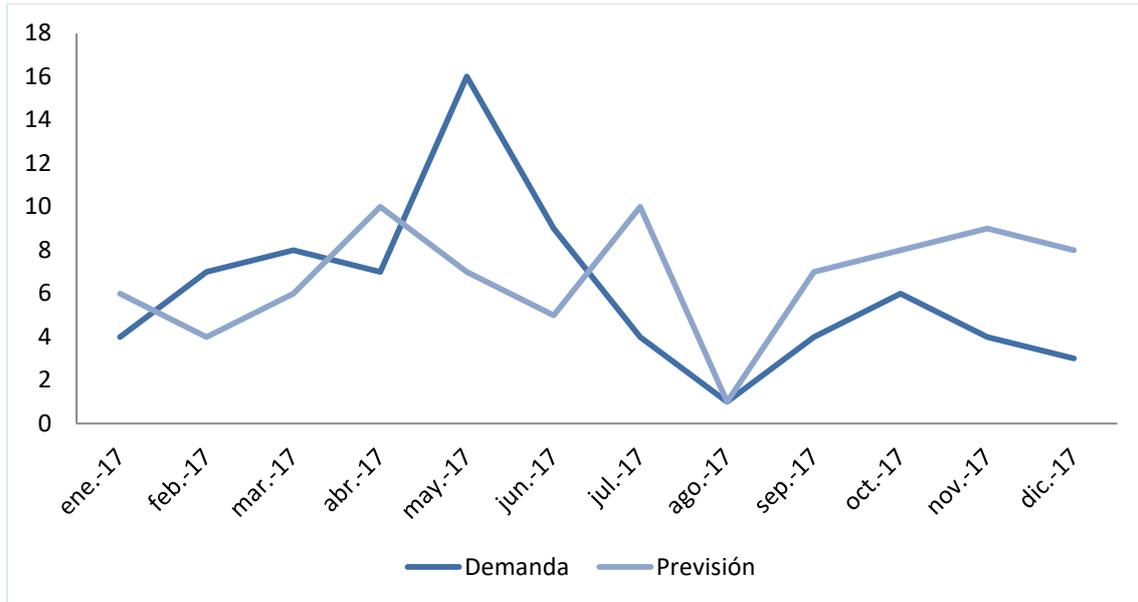


Ilustración 4-31. Comparación Demanda y Previsión 2017. Línea de túneles de lavado automático

En este caso, los errores de acierto medios son:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	18,50	4,30	3,67	67,62%	52,54%

Tabla 4-41. Error de acierto del modelo causal para la línea de túneles de lavado automático

Son, como puede apreciarse, valores bastante elevados que evidencian que el Modelo Causal no es capaz de pronosticar de forma satisfactoria la demanda futura. Para mejorar estos resultados se han rehecho los cálculos de las previsiones añadiendo algunas variables causales más. Con ello se pretende que estas nuevas variables absorban el impacto de eventos no identificados que afectan a la bondad del método de pronóstico.

Identificación de valores extraordinarios

Para esta línea se han añadido tres variables, una para cada periodo cuyo error de pronóstico supera el 50%, es decir:

- Periodo 11: noviembre de 2014.
- Periodo 27: marzo de 2016.
- Periodo 30: junio de 2016.

La inclusión de estas nuevas variables explicativas representa la suposición de que existe una causa que justifica esas variaciones en la demanda, que el modelo causal no es capaz de explicar y que no se han tenido en cuenta en el primer cálculo. Estas variables pueden ser, por

ejemplo, información no compartida con el planificador de demanda, variables conocidas pero sin registro histórico de cuando se han producido...

Por tanto, en este segundo cálculo, se espera que los resultados de los errores medios de pronóstico sean menores.

Resultados de las variables de decisión. Segundo Cálculo

Nuevamente se han calculado los valores aportados por la variable P_a (valor de la previsión para el año a) que representan la tendencia de la demanda de la línea, y que en este caso han sido:

Año	Previsión-Año
2014	0
2015	1
2016	0

Tabla 4-42. Valor de la tendencia para la línea de túneles de lavado automático. Segundo Cálculo.

Puede observarse que la introducción al Modelo Causal de las nuevas variables ha modificado la tendencia de la línea, haciendo que, en esta ocasión descienda a partir del segundo año estudiado.

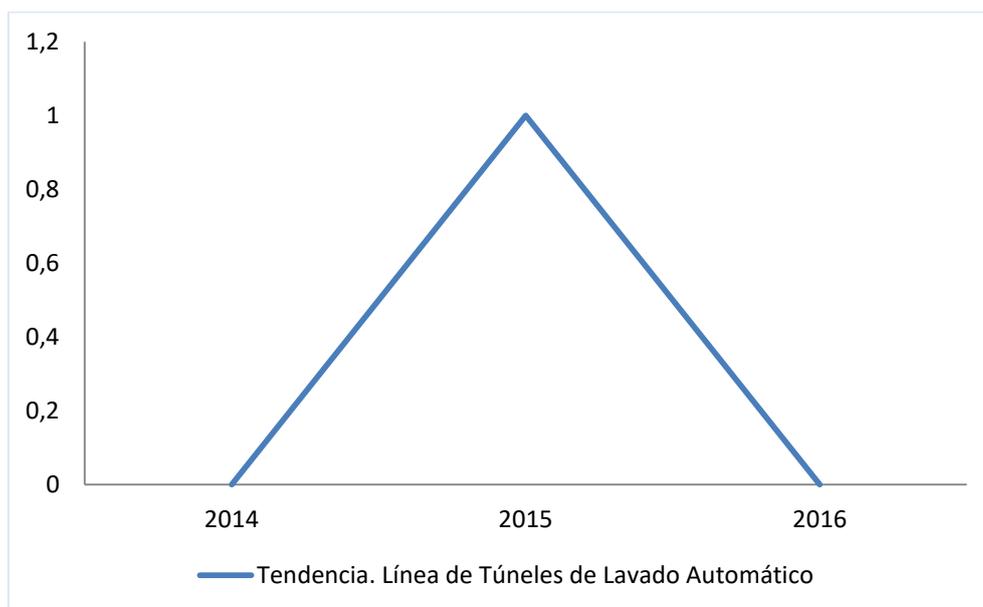


Ilustración 4-32. Gráfico de la tendencia para la línea de Túneles de Lavado Automático. Segundo Cálculo

Los valores aportados por la variable P_m (valor de la previsión para el mes m) que representan la estacionalidad de la demanda de la línea son:

Mes	Previsión-Mes
1	4
2	4
3	4
4	5
5	4
6	2
7	8
8	0
9	5
10	7
11	8
12	0

Tabla 4-43. Valor de la estacionalidad para la línea de túneles de lavado automático. Segundo Cálculo.

En este segundo cálculo se ha mantenido la forma de la curva de la estacionalidad haciendo pequeñas variaciones sobre la influencia de distintos meses.

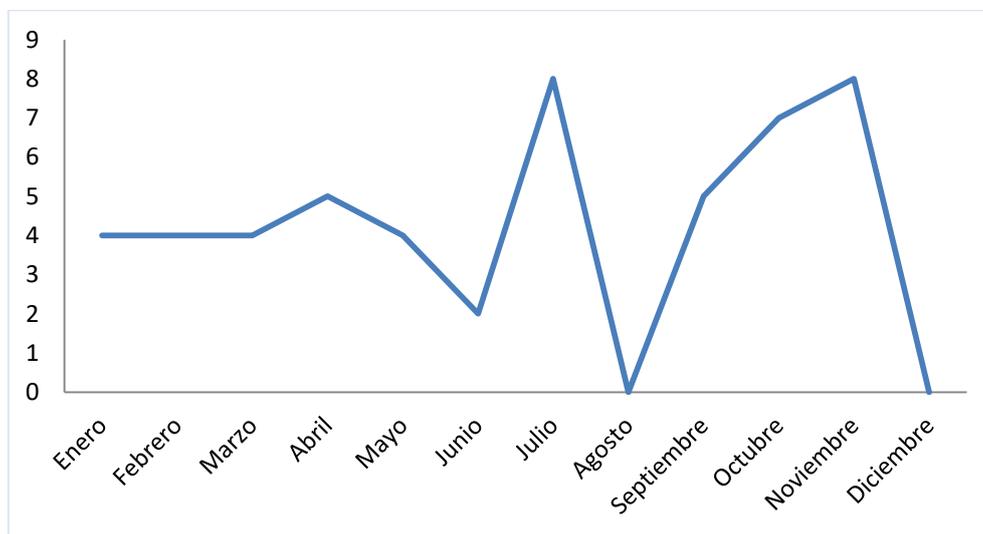


Ilustración 4-33. Gráfico de la estacionalidad para la línea de Túneles de Lavado Automático. Segundo Cálculo

Los valores aportados por la variable $PrevDL_l$ (valor de la previsión para el número de días laborables l) son:

Días Laborables	Previsión-Días Laborables	Días Laborables	Previsión-Días Laborables
1	0	16	2
2	0	17	3
3	0	18	0
4	0	19	0
5	2	20	0
6	1	21	0
7	0	22	1
8	0	23	-1
9	0	24	0
10	0	25	0
11	4	26	0
12	0	27	0
13	0	28	0
14	6	29	0
15	4	30	0

Tabla 4-44. Valor de la previsión por días laborables para la línea de Túneles de Lavado Automático. Segundo Cálculo.

Por último, la influencia de las variables recién incluidas, $PrevVC_n$ (valor de la previsión asociado a la aparición de la variable causal n) son:

Id	Periodo	Previsión-variable causal
1	11	-5
2	27	6
3	30	6

Tabla 4-45. Valor de la previsión de la variable causal añadida para la línea de centros

Cálculo del error de ajuste. Segundo Cálculo

Para los periodos comprendidos entre enero de 2014 y diciembre de 2016, los resultados de las previsiones calculadas a través del modelo causal son:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2014	1	3	3	0	0	0,00%
2014	2	3	3	0	0	0,00%
2014	3	3	3	0	0	0,00%
2014	4	5	5	0	0	0,00%
2014	5	4	4	0	0	0,00%
2014	6	2	2	0	0	0,00%

2014	7	8	8	0	0	0,00%
2014	8	2	2	0	0	0,00%
2014	9	5	5	0	0	0,00%
2014	10	8	8	0	0	0,00%
2014	11	3	3	0	0	0,00%
2014	12	6	6	0	0	0,00%
2015	1	8	8	0	0	0,00%
2015	2	7	7	0	0	0,00%
2015	3	5	5	0	0	0,00%
2015	4	6	6	0	0	0,00%
2015	5	4	5	-1	1	25,00%
2015	6	4	4	0	0	0,00%
2015	7	9	9	0	0	0,00%
2015	8	2	2	0	0	0,00%
2015	9	6	6	0	0	0,00%
2015	10	8	8	0	0	0,00%
2015	11	8	10	-2	2	25,00%
2015	12	5	5	0	0	0,00%
2016	1	5	7	-2	2	40,00%
2016	2	4	4	0	0	0,00%
2016	3	10	10	0	0	0,00%
2016	4	5	5	0	0	0,00%
2016	5	8	4	4	4	50,00%
2016	6	9	9	0	0	0,00%
2016	7	9	9	0	0	0,00%
2016	8	0	0	0	0	-
2016	9	5	5	0	0	0,00%
2016	10	8	8	0	0	0,00%
2016	11	9	9	0	0	0,00%
2016	12	5	5	0	0	0,00%

Tabla 4-46. Demanda y Previsión 2014-2016 para la línea de Túneles de Lavado Automático. Segundo Cálculo

Tras la inclusión de las nuevas variables se aprecia un descenso del error en varios periodos, sobre todo en los periodos 11, 27 y 30 donde la variable causal ha absorbido parte de la demanda que no quedaba explicada en la fase anterior y por tanto formaba parte del error. Esto ha provocado que las curvas de la demanda y la previsión se acerquen algo más.

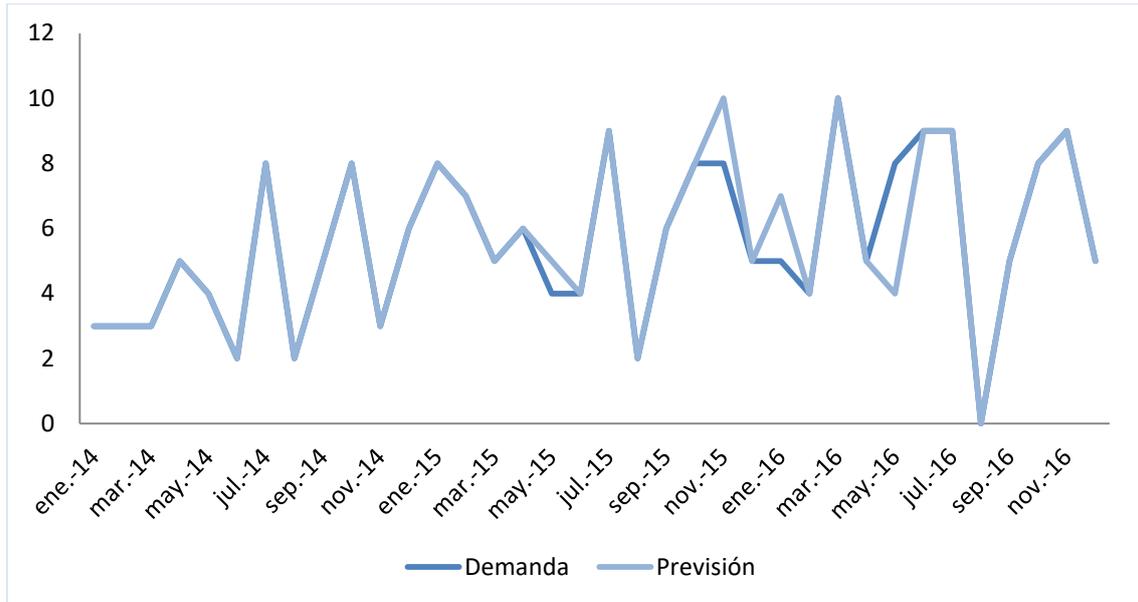


Ilustración 4-34. Comparación Demanda y Previsión 2014-2016. Línea de túneles de lavado automático. Segundo Cálculo

Por su parte, todos los indicadores del error de pronóstico medio han mejorado en cuanto a ajuste. En este sentido, por ejemplo, el MAE ha pasado de 0,64 unidades a solo 0,25 y el MAPE de un 9,84% a un 3,89%.

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	0,69	0,83	0,25	3,89%	4,01%

Tabla 4-47. Error de ajuste del modelo causal para la línea de túneles de lavado automático. Segundo Cálculo

Sin embargo, aunque se ha conseguido mejorar considerablemente el grado de acierto del modelo con respecto a la demanda pasada, ello no conlleva necesariamente que los pronósticos con respecto al futuro vayan a mejorar de igual manera.

Para comprobarlo, se han vuelto a calcular las previsiones para 2017 para posteriormente compararlas con la que se dio realmente en la empresa. Con ello se podrá comprobar cuánto mejora el error de acierto la inclusión de estas nuevas variables causales.

Cálculo del error de acierto. Segundo Cálculo

Para calcular las previsiones de los periodos correspondientes a 2017, se ha procedido a dar valor a las variables causales que afectarán a dichos periodos y cuyo sumatorio dará como resultado el pronóstico calculado por el modelo causal.

En primer lugar, para dar valor a la variable, valor de la previsión para el año a, se ha aplicado el método de Holt a los resultados de años anteriores. De este modo se ha tenido una estimación de la tendencia que tendrá la línea al año siguiente.

Año	Previsión-Año
2014	0
2015	1
2016	0
2017	0

Tabla 4-48. Cálculo tendencia 2017. Línea de túneles de lavado automático. Segundo Cálculo

Tras aplicar el método de Holt a la previsión de la tendencia, se estima que ésta se mantendrá igual a la de 2016.

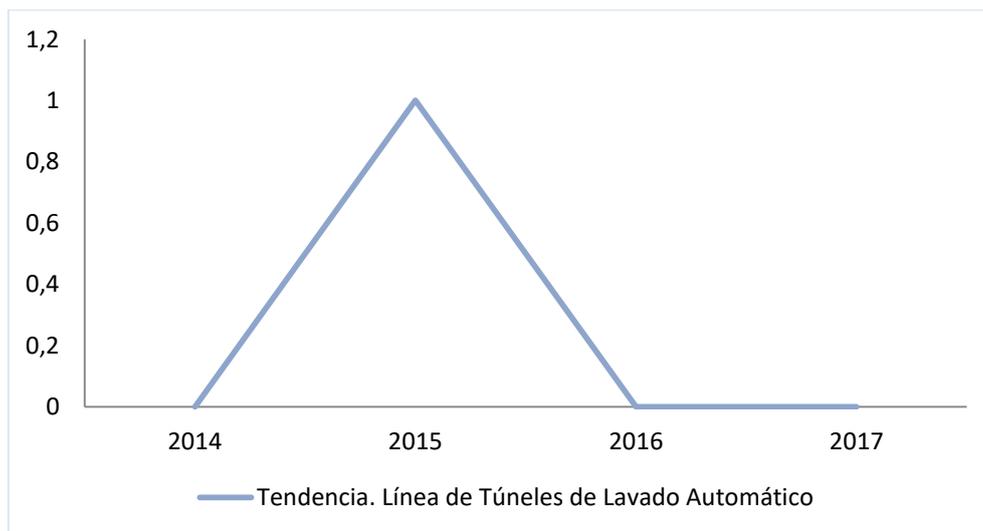


Ilustración 4-35. Tendencia 2017. Línea de Túneles de Lavado Automático. Segundo Cálculo

En segundo lugar, los valores de la variable valor de la previsión para el mes m serán los mismos que fueron resultado de la aplicación del modelo causal en los periodos de 2014 a 2016. Esta variable representa la estacionalidad de la línea, de modo que es independiente del año.

Mes	Previsión-Mes
1	4
2	4
3	4
4	5
5	4

6	2
7	8
8	0
9	5
10	7
11	8
12	0

Tabla 4-49. Valores de estacionalidad para 2017. Línea de Túneles de Lavado Automático. Segundo Cálculo

Por último, se ha dado valor a la variable valor de la previsión para el número de días laborables I que, al tratarse de un dato proporcionado directamente de los acuerdos de calendario realizados cada inicio de año entre los trabajadores, simplemente se han recopilado los correspondientes a 2017.

Periodo	Número de días laborables	Periodo	Número de días laborables
37	17	43	21
38	20	44	8
39	23	45	19
40	16	46	20
41	22	47	21
42	22	48	14

Tabla 4-50. Variable explicativa (número de días laborables) para 2017

Con estos nuevos valores aplicados a todas las variables, se han recalculado las previsiones para 2017, obteniendo las previsiones y errores de acierto siguientes:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2017	1	4	7	-3	3	75,00%
2017	2	7	4	3	3	42,86%
2017	3	8	3	5	5	62,50%
2017	4	7	7	0	0	0,00%
2017	5	16	5	11	11	68,75%
2017	6	9	3	6	6	66,67%
2017	7	4	8	-4	4	100,00%
2017	8	1	0	1	1	100,00%

2017	9	4	5	-1	1	25,00%
2017	10	6	7	-1	1	16,67%
2017	11	4	8	-4	4	100,00%
2017	12	3	6	-3	3	100,00%

Tabla 4-51. Demanda y Previsión 2017 para la línea de túneles de lavado automático. Segundo Cálculo

En este segundo cálculo no han aparecido errores tan grandes como en el anterior aunque el Modelo Causal sigue cometiendo errores muy significativos. La mejora se ha dado sobre todo en los últimos periodos en los que gráficamente se aprecia el mayor acercamiento entre las curvas de la demanda y las previsiones.

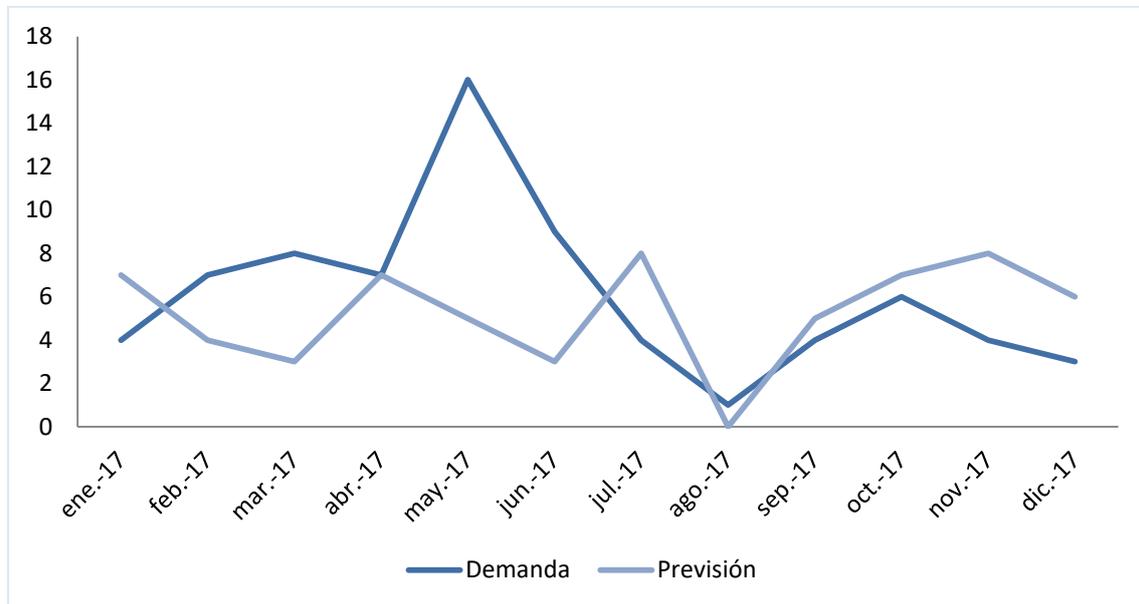


Ilustración 4-36. Comparación Demanda y Previsión 2017 para la línea de túneles de lavado automático. Segundo Cálculo

De este modo, se han alcanzado los siguientes niveles de error de acierto medios:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	20,33	4,51	3,50	63,12%	70,20%

Tabla 4-52. Error de acierto del modelo causal para la línea de túneles de lavado automático. Segundo Cálculo

Con este segundo cálculo han mejorado algunos de los indicadores de error mientras que otros han empeorado. En este sentido, los errores MSE y RMSE son ligeramente superiores, 20,33

frente a 18,5, y 4,51 frente a 4,3 respectivamente. Por otro lado, el MAE y MAPE sí han mejorado. Sus valores se sitúan en un 3,5 frente a un 3,67 y en un 63,12% frente a un 67,62%. El sMAPE, por su parte, también es superior en esta ocasión, un 70,20% frente al 52,54% anterior.

Podemos concluir por tanto que, aunque la inclusión al modelo de las nuevas variables ha mejorado considerablemente el ajuste del modelo, la fiabilidad de los pronósticos no lo ha hecho en la misma medida. De hecho, en este segundo cálculo de las previsiones siguen apareciendo valores extraordinarios. Por tanto se va a realizar el proceso de nuevo hasta conseguir que su influencia quede totalmente absorbida.

Identificación de valores extraordinarios

En esta tercera vuelta va a incluirse una nueva variable causal más, en el periodo 29 (mayo de 2016). Con esta, serán cuatro las variables que se habrán añadido al Modelo Causal. A continuación se rehacen de nuevo los cálculos y se comparan los resultados.

Resultados de las variables de decisión. Tercer cálculo

Una vez calculada la influencia de las variables causales de nuevo, los resultados obtenidos para las consideradas en el bucle anterior han ido idénticos. Es decir, tanto la tendencia, la estacionalidad, el valor explicado por la variación de los días laborales de cada mes y las tres primeras variables causales incluidas en el segundo recálculo de las previsiones, se han mantenido. La única diferente es, por tanto, la de la única variable que se ha añadido al modelo en este paso, la que intenta explicar el error cometido en el periodo 29. Los resultados han sido los siguientes:

Id	Periodo	Previsión-variable causal
4	29	4

Tabla 4-53 Valor de la previsión de la variable causal añadida para la línea de centros

Cálculo del error de ajuste. Tercer cálculo

Los nuevos valores de las previsiones y errores de pronóstico se presentan a continuación:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2014	1	3	3	0	0	0,00%
2014	2	3	3	0	0	0,00%
2014	3	3	3	0	0	0,00%
2014	4	5	5	0	0	0,00%

2014	5	4	4	0	0	0,00%
2014	6	2	2	0	0	0,00%
2014	7	8	8	0	0	0,00%
2014	8	2	2	0	0	0,00%
2014	9	5	5	0	0	0,00%
2014	10	8	8	0	0	0,00%
2014	11	3	3	0	0	0,00%
2014	12	6	6	0	0	0,00%
2015	1	8	8	0	0	0,00%
2015	2	7	7	0	0	0,00%
2015	3	5	5	0	0	0,00%
2015	4	6	6	0	0	0,00%
2015	5	4	5	-1	1	25,00%
2015	6	4	4	0	0	0,00%
2015	7	9	9	0	0	0,00%
2015	8	2	2	0	0	0,00%
2015	9	6	6	0	0	0,00%
2015	10	8	8	0	0	0,00%
2015	11	8	10	-2	2	25,00%
2015	12	5	5	0	0	0,00%
2016	1	5	7	-2	2	40,00%
2016	2	4	4	0	0	0,00%
2016	3	10	10	0	0	0,00%
2016	4	5	5	0	0	0,00%
2016	5	8	8	0	0	0,00%
2016	6	9	9	0	0	0,00%
2016	7	9	9	0	0	0,00%
2016	8	0	0	0	0	-
2016	9	5	5	0	0	0,00%
2016	10	8	8	0	0	0,00%
2016	11	9	9	0	0	0,00%
2016	12	5	5	0	0	0,00%

Tabla 4-54. Demanda y Previsión 2014-2016 para la línea de Túneles de Lavado Automático. Tercer cálculo

Como puede observarse, la única previsión que se ha modificado es la correspondiente al periodo 29, en la que se ha incluido la nueva variable causal. El resto de periodos al mantenido los valores calculados en la fase anterior debido a que esta nueva variable no ha afectado al valor de las ya existentes.

El nuevo gráfico comparativo de la curva de demanda y previsión es el siguiente:

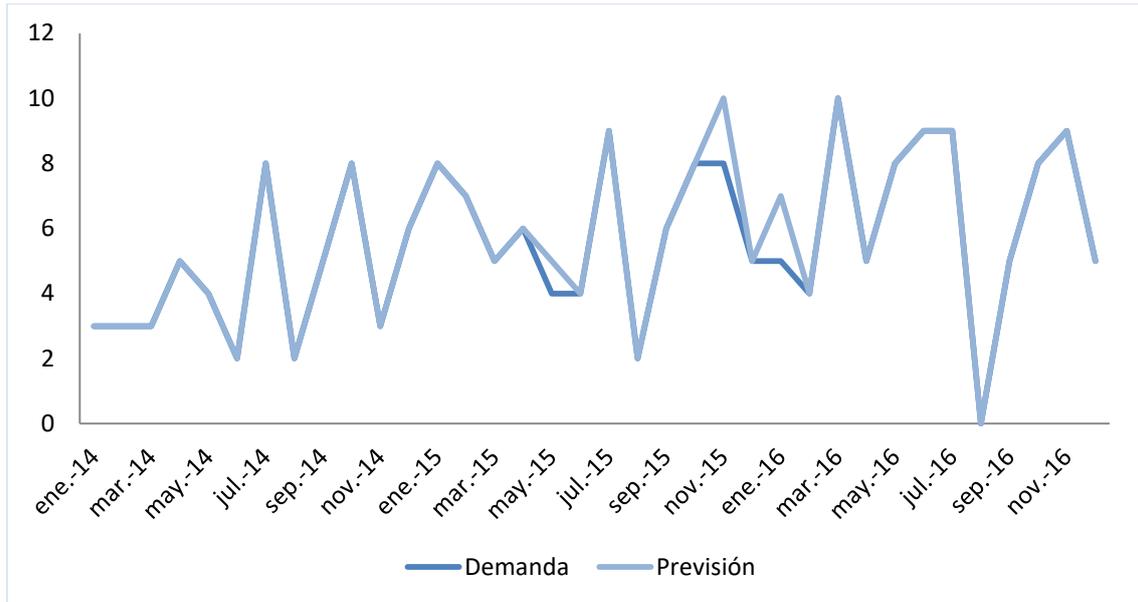


Ilustración 4-37. Comparación Demanda y Previsión 2014-2016. Línea de túneles de lavado automático. Tercer cálculo

Por último, los nuevos valores para los errores de ajuste medios son:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	0,25	0,50	0,14	2,50%	2,16%

Tabla 4-55. Error de ajuste del modelo causal para la línea de túneles de lavado automático. Tercer cálculo

Cálculo del error de acierto. Tercer cálculo

Debido a que la inclusión de la cuarta variable explicativa no ha modificado el valor de las ya existentes, y ésta afecta tan solo a un periodo pasado, los valores de pronóstico para 2017 no han sido modificados. De este modo, en esta nueva fase, aunque se ha mejorado el ajuste del modelo, el acierto se ha mantenido.

Podemos concluir por tanto que, aunque la inclusión al modelo de las nuevas variables ha mejorado considerablemente el ajuste del modelo, la fiabilidad de los pronósticos no lo ha hecho en la misma medida. Sin embargo, es importante la identificación de estas posibles variables explicativas ya que abre paso a la búsqueda de información dentro de la organización y a la posible proyección de su influencia a eventos futuros de similares características.

En cuanto a la exactitud de las previsiones, comparadas con las del Método Theta, se ha obtenido una mejora muy significativa en cuanto a al ajuste del modelo a la demanda pasada, ya que el error porcentual cometido por el Modelo Causal es inferior, o al menos igual, en prácticamente todos los periodos del histórico utilizados en el cálculo del ajuste. Por otro lado, los errores porcentuales de acierto son más semejantes. Aunque con el Modelo Causal no se

alcanzan valores de error tan elevados y, por tanto, en términos porcentuales sí se obtienen mejores resultados, los indicadores MSE, RMSE y MAE muestran grados de acierto muy similares.

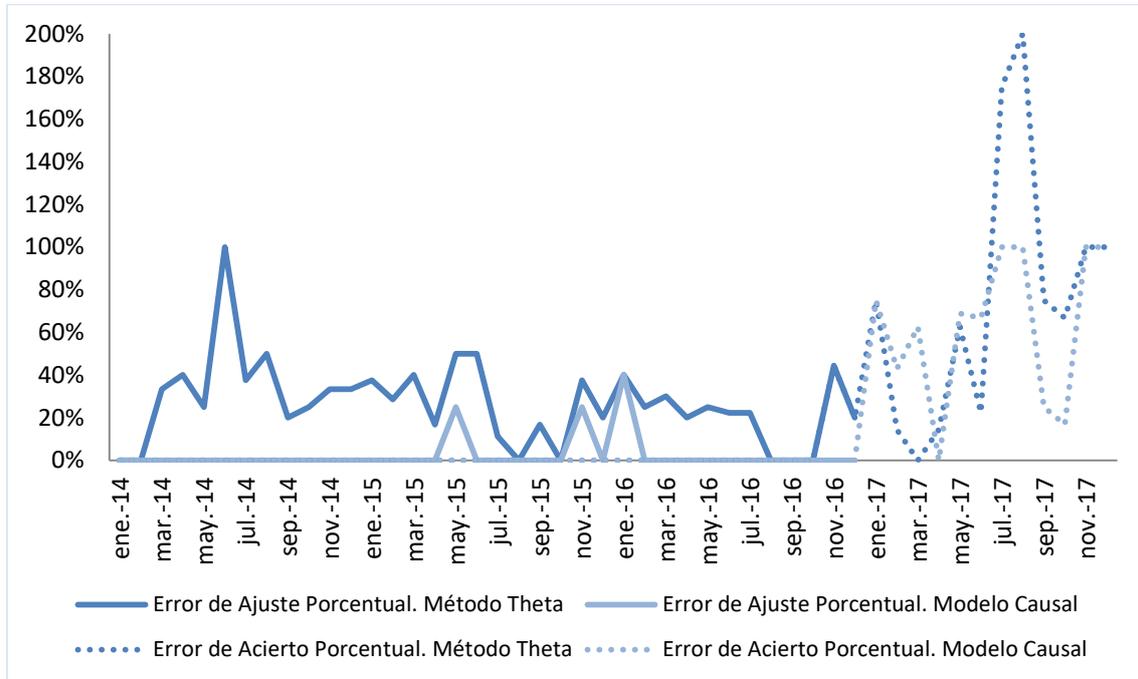


Ilustración 4-38. Comparación del Error Porcentual del Método Theta y el Modelo Causal para la línea de Túneles de Lavado Automático

4.3.3 Línea de Lavado de Vehículos Industriales

En la línea de lavado automático de vehículos industriales se fabrican las máquinas para el aseo de autobuses, camiones, tranvías, ambulancias... y demás vehículos de grandes dimensiones. En ella, se producen el 10% de las máquinas que se fabrican en ISTOBAL. En este apartado se analizan los resultados de los pronósticos tras la aplicación del Modelo Causal así como el error obtenido.

Definición de variables causales

Actualmente, en la línea de máquinas de lavado de vehículos industriales se fabrican 8 modelos diferentes, además de sus múltiples opcionales. Cada una de ellas, se diseñó y lanzó al mercado en un momento concreto y diferente al de las demás. Por tanto, al igual que para la línea de Puentes de Lavado Automático, se han considerado dos variables referentes al número de modelos que se encuentran en estado de introducción y el número de modelos en estado de crecimiento-madurez.

Con ello se ha podido calcular la influencia, sobre las ventas totales de la línea, del lanzamiento de una nueva gama o del paso de un modelo a un estado más maduro dentro del mercado.

Para ello se han buscado las fechas en las que cada uno de los ocho modelos se lanzó al mercado así como la fecha en la que alcanzó las ventas esperadas. Con ello, se obtuvo la siguiente tabla:

Periodo	Número de modelos en estado de introducción	Número de modelos en estado de madurez
1	2	3
2	2	3
3	2	3
4	2	3
5	2	3
6	1	4
7	1	4
8	1	4
9	1	4
10	1	4
11	1	4
12	1	4
13	1	4
14	1	4
15	0	5
16	0	5
17	0	5
18	0	5
19	0	5
20	0	5
21	0	5
22	0	5
23	0	5
24	0	5
25	0	5
26	0	5
27	1	5
28	0	6
29	1	6
30	1	6
31	1	7
32	1	7
33	1	7
34	1	7
35	1	7
36	0	8

Tabla 4-56. Variable explicativa (modelos por fase de su ciclo de vida). Línea de Lavado de Vehículos Industriales

Además de estas dos variables, se han incluido, al igual que en el resto de líneas, las variables causales referentes al año y al mes que definirán la tendencia y estacionalidad de la demanda, respectivamente.

Por último, también se ha considerado la variable causal que definirá los días laborables de cada mes para tener en cuenta las variaciones en las festividades y los días declarados como no laborables por el convenio con los trabajadores.

Esta última variable se incluye en los cálculos de las cuatro líneas y su valor en cada periodo es idéntico en cada una de ellas.

Resultados de las variables de decisión

Tras lanzar el cálculo del modelo causal, los resultados para las variables analizadas han sido los siguientes:

Los valores aportados por la variable P_a (valor de la previsión para el año a) que representan la tendencia de la demanda de la línea son:

Año	Previsión-Año
2014	6
2015	0
2016	-7

Tabla 4-57. Valor de la tendencia para la línea de Lavado de Vehículos Industriales

En la línea de Lavado de Vehículos Industriales aparece por primera vez una tendencia marcadamente descendente.

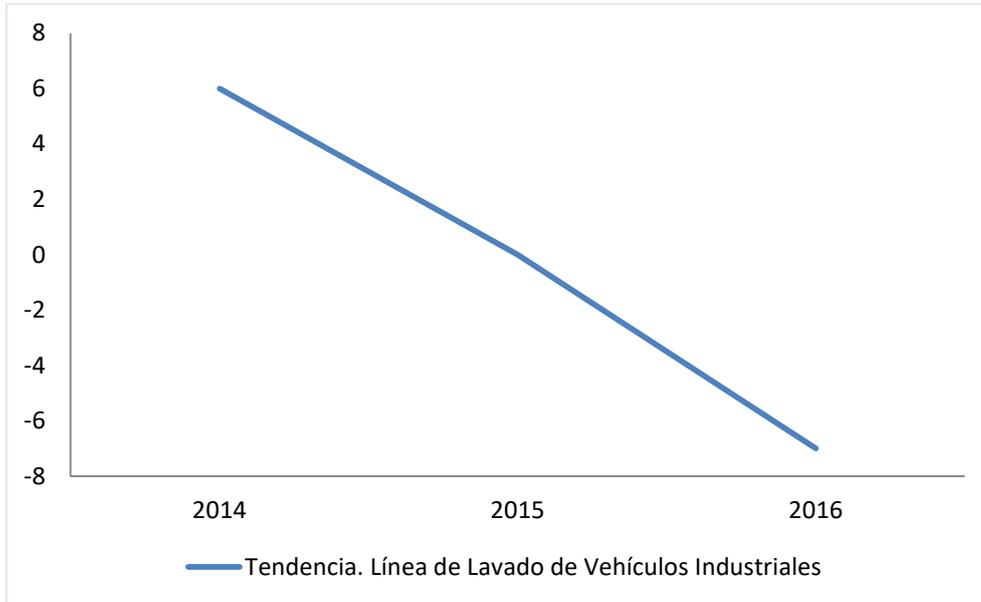


Ilustración 4-39. . Gráfico de la tendencia para la línea de Lavado de Vehículos Industriales

Los valores aportados por la variable P_m (valor de la previsión para el mes m) que representan la estacionalidad de la demanda de la línea son:

Mes	Previsión-Mes
1	8
2	15
3	14
4	21
5	16
6	6
7	11
8	-4
9	12
10	8
11	7
12	4

Tabla 4-58. Valor de la estacionalidad para la línea de Lavado de Vehículos Industriales

Para esta línea, se calcula un aumento de la demanda durante los meses de febrero a mayo, teniendo una segunda, aunque menor subida en julio. Durante los meses de meses hay un descenso considerable, sobre todo el me de agosto, en cual la variable llega a alcanzar valores negativos.

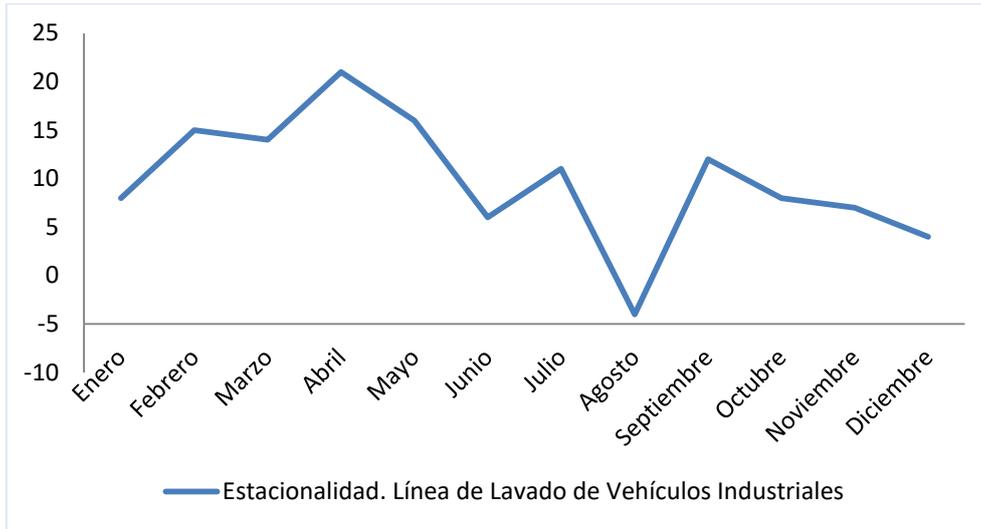


Ilustración 4-40. Gráfico de la estacionalidad para la línea de Lavado de Vehículos Industriales

Los valores aportados por la variable $PrevDL_t$ (valor de la previsión para el número de días laborables l) son:

Días Laborables	Previsión-Días Laborables	Días Laborables	Previsión-Días Laborables
1	0	16	-3
2	0	17	0
3	0	18	-10
4	0	19	-8
5	-2	20	-2
6	4	21	0
7	0	22	5
8	0	23	7
9	0	24	0
10	0	25	0
11	0	26	0
12	0	27	0
13	0	28	0
14	-6	29	0
15	0	30	0

Tabla 4-59. Valor de la previsión por días laborables para la línea de Lavado de Vehículos Industriales

Por último, los resultados para las variables causales número de modelos en estado de introducción y número de modelos en estado de crecimiento-madurez, han sido:

Número de modelos en estado de introducción	Influencia
0	8
1	10
2	0
3	0
4	0
5	0
6	0
7	0
8	0

Tabla 4-60. Variable explicativa: número de modelos en estado de introducción

Para esta línea, según los resultados obtenidos a través del Modelo Causal, la introducción de un nuevo modelo afectará positivamente a la demanda, de igual modo que el paso progresivo de esos mismos modelos a un estado de madurez dentro del mercado.

Número de modelos en estado de madurez	Influencia
0	0
1	0
2	0
3	0
4	-4
5	-2
6	0
7	10
8	6

Tabla 4-61. Variable explicativa: número de modelos en estado de madurez

Cálculo del error de ajuste

A continuación se exponen los resultados de previsión que se han obtenido con el modelo causal, además de los valores de demanda real y los errores de pronóstico, errores absolutos y errores porcentuales para cada periodo:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2014	1	12	12	0	0	0,00%
2014	2	19	19	0	0	0,00%

2014	3	15	18	-3	3	20,00%
2014	4	19	19	0	0	0,00%
2014	5	22	22	0	0	0,00%
2014	6	17	17	0	0	0,00%
2014	7	36	28	8	8	22,22%
2014	8	5	5	0	0	0,00%
2014	9	23	23	0	0	0,00%
2014	10	24	24	0	0	0,00%
2014	11	16	16	0	0	0,00%
2014	12	8	8	0	0	0,00%
2015	1	13	13	0	0	0,00%
2015	2	17	17	0	0	0,00%
2015	3	13	13	0	0	0,00%
2015	4	18	18	0	0	0,00%
2015	5	22	22	0	0	0,00%
2015	6	19	18	1	1	5,26%
2015	7	25	25	0	0	0,00%
2015	8	7	7	0	0	0,00%
2015	9	18	18	0	0	0,00%
2015	10	14	14	0	0	0,00%
2015	11	20	14	6	6	30,00%
2015	12	11	11	0	0	0,00%
2016	1	8	8	0	0	0,00%
2016	2	15	15	0	0	0,00%
2016	3	13	7	6	6	46,15%
2016	4	21	21	0	0	0,00%
2016	5	19	19	0	0	0,00%
2016	6	13	14	-1	1	7,69%
2016	7	23	23	0	0	0,00%
2016	8	8	8	0	0	0,00%
2016	9	23	23	0	0	0,00%
2016	10	13	13	0	0	0,00%
2016	11	19	19	0	0	0,00%
2016	12	11	11	0	0	0,00%

Tabla 4-62. Demanda y Previsión 2014-2016 para la línea de Lavado de Vehículos Industriales

En este caso se observan unos valores de error bastante bajos en la mayoría de los periodos, siendo los más elevados los del periodo 7 (julio de 2014), periodo 23 (noviembre de 2015) y periodo 27 (marzo de 2016).

Al representarlo de forma gráfica se observa más claramente los periodos en los que el modelo es capaz de explicar con mayor o menor acierto el comportamiento de la demanda.

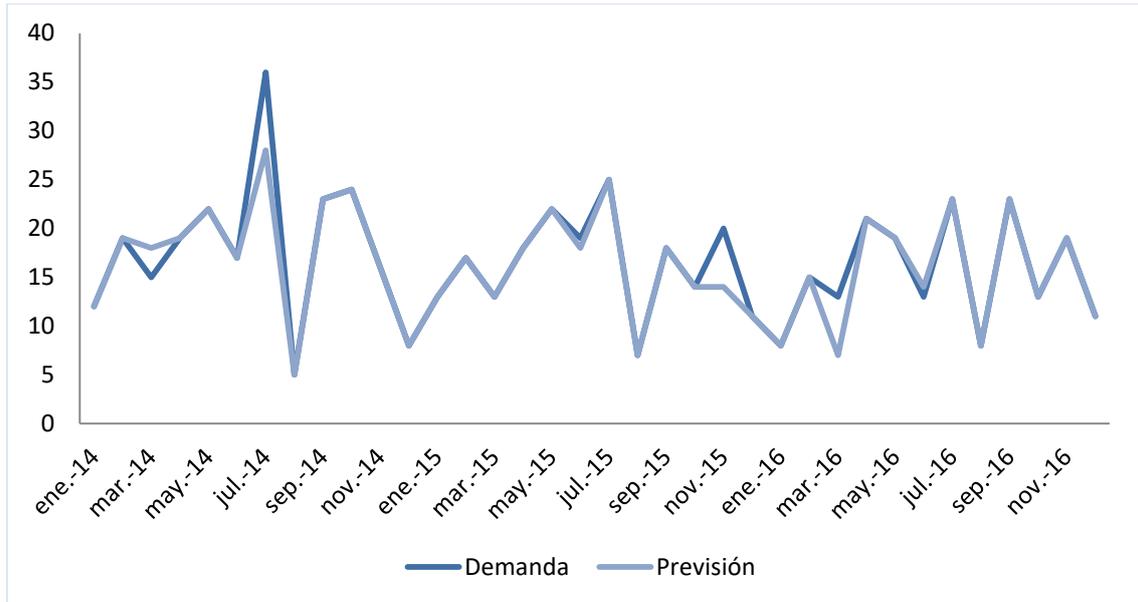


Ilustración 4-41. Comparación Demanda y Previsión 2014-2016. Línea de Lavado de Vehículos Industriales

Además se han calculado los errores de ajuste que se han considerado más representativos: **MSE** (Mean Squared Error o Error Cuadrático Medio), **RMSE** (Root Mean Square Error o Raíz del Error Cuadrático Medio), **MAE** (Mean Absolute Error o Error Medio Absoluto), **MAPE** (Mean Absolute Percentage Error o Error Medio Porcentual Absoluto) y **WMAPE** (Weighted Mean Absolute Percentage Error o Error Medio Porcentual Absoluto Ponderado). Siendo los resultados los siguientes:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	4,08	2,02	0,69	3,65%	4,20%

Tabla 4-63. Error de ajuste del modelo causal para la línea de Lavado de Vehículos Industriales

Como quedaba reflejado en la representación gráfica de la comparativa demanda-previsión, los errores de ajuste del modelo para esta línea muestran unos errores bastante pequeños que demuestran la fiabilidad de modelo en cuanto a la explicación de la demanda pasada.

Cálculo del error de acierto

A continuación se presentan los resultados para la previsión de los periodos de 2017 con lo que se medirá el error de acierto del modelo. Para ello, en primer lugar, se le han dado valor para estos nuevos periodos a las variables que afectarán al modelo causal.

Para estimar la primera variable, valor de la previsión para el año a, se ha aplicado el método de Holt a los resultados de años anteriores. En este sentido y como ya habían aparecido

valores negativos en las variables propias de la tendencia, se han calculado sin permitir valores negativos con el objetivo de no proponer para los periodos futuros una tendencia con demasiada pendiente. Así se ha obtenido la siguiente estimación para el año próximo.

Año	Previsión-Año
2014	6
2015	0
2016	-7
2017	0

Tabla 4-64. Cálculo tendencia 2017. Línea de Lavado de Vehículos Industriales

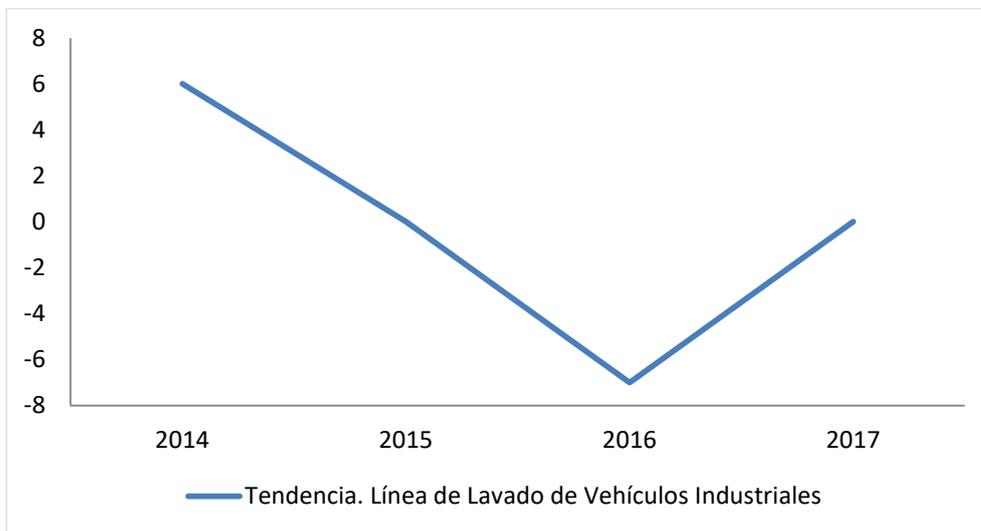


Ilustración 4-42. Tendencia 2017. Línea de Lavado de Vehículos Industriales

En segundo lugar, se le ha dado a la variable valor de la previsión para el mes m los mismos valores que fueron resultado de la aplicación del modelo causal en los periodos de 2014 a 2016. Esta variable representa la estacionalidad de la línea, de modo que es independiente del año.

Mes	Previsión-Mes
1	8
2	15
3	14
4	21
5	16
6	6
7	11
8	-4
9	12

10	8
11	7
12	4

Tabla 4-65. Valores de estacionalidad para 2017. Línea de Lavado de Vehículos Industriales

La tercera variable, valor de la previsión para el número de días laborables I, al tratarse de un dato proporcionado directamente de los acuerdos de calendario realizados cada inicio de año entre los trabajadores, simplemente se han recopilado los correspondientes a 2017.

Periodo	Número de días laborables	Periodo	Número de días laborables
37	17	43	21
38	20	44	8
39	23	45	19
40	16	46	20
41	22	47	21
42	22	48	14

Tabla 4-66. Variable explicativa (número de días laborables) para 2017

Por último, ha sido necesario dar valor a las dos variables que hacen referencia al estado del ciclo de vida de cada modelo. En este sentido, y como no existe información por parte de Gestión de Producto, de que vaya a anularse o lanzarse al mercado ningún nuevo modelo durante 2017, para estos periodos se ha supuesto que se mantienen los del último periodo analizado, es decir, diciembre de 2016.

Periodo	Número de modelos en estado de introducción	Número de modelos en estado de madurez
37	0	8
38	0	8
39	0	8
40	0	8
41	0	8
42	0	8
43	0	8
44	0	8
45	0	8
46	0	8
47	0	8
48	0	8

Tabla 4-67. Variable explicativa (modelos por fase de su ciclo de vida)

Una vez dado valor a todas las variables, se procede a lanzar el cálculo de las previsiones a través de modelo causal y calcular los errores de acierto.

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2017	1	20	16	4	4	20,00%
2017	2	29	21	8	8	27,59%
2017	3	28	29	-1	1	3,57%
2017	4	13	26	-13	13	100,00%
2017	5	28	29	-1	1	3,57%
2017	6	25	19	6	6	24,00%
2017	7	20	19	1	1	5,00%
2017	8	11	4	7	7	63,64%
2017	9	23	12	11	11	47,83%
2017	10	19	14	5	5	26,32%
2017	11	12	15	-3	3	25,00%
2017	12	4	6	-2	2	50,00%

Tabla 4-68. Demanda y Previsión 2017 para la línea de Lavado de Vehículos Industriales

En cuanto a los errores de pronóstico cometidos por el Modelo Causal para la línea de Lavado de Vehículos Industriales, aparecen periodos con una elevada tasa de error, sobre todo en los periodos de abril y noviembre de 2017. Además se observa un incremento considerable del nivel de error comparándolo con el de ajuste.

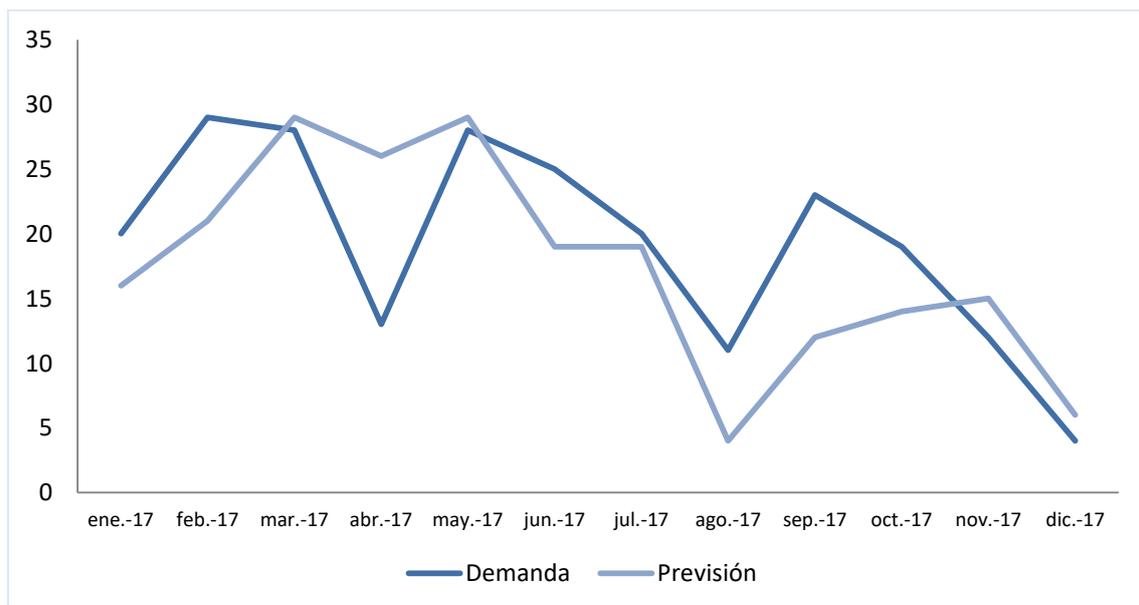


Ilustración 4-43. Comparación Demanda y Previsión 2017. Línea de Lavado de Vehículos Industriales

Una vez obtenidos los valores medios de los errores de previsión de los valores futuros, los resultados son los siguientes:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	41,33	6,43	5,17	33,04%	34,09%

Tabla 4-69. Error de acierto del modelo causal para la línea de Lavado de Vehículos Industriales

En esta ocasión, y atendiendo a los indicadores de error porcentuales, el Modelo Causal consigue unos niveles de error menores que en la línea de Túneles de Lavado Automático aunque superiores a los de la de Puentes de Lavado Automático.

En comparación con la fiabilidad obtenida por el Método Theta, el Modelo Causal obtiene mejores resultados en los cinco indicadores considerados, tanto en Ajuste como en Acierto. En este sentido, por el ejemplo el MAPE, pasa de un 15,71% en Ajuste del Método Theta a un 3,65% para el Modelo Causal; y cuanto al acierto se ha calculado un 44,34% a través del Método Theta frente al 33,04% conseguido por el segundo.

En el siguiente gráfico se puede comparar periodo a periodo la evolución de los errores porcentuales que son cometidos por la aplicación de ambos métodos de pronóstico. En él se evidencia que los cometidos por el Modelo Causal son significativamente inferiores en la gran mayoría de los periodos.

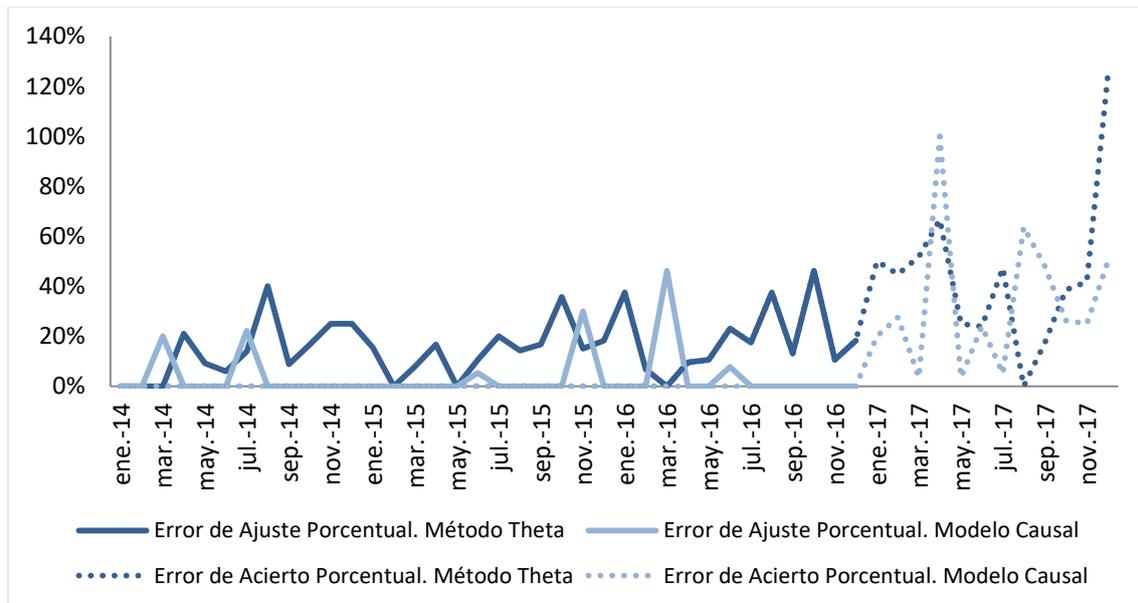


Ilustración 4-44. Comparación del Error Porcentual del Método Theta y el Modelo Causal para la línea de Lavado de Vehículos Industriales

4.3.4 Línea de Centros de Lavado

Por último se han calculado las previsiones para 2017 de la línea de Centros de Lavado, la segunda en cuanto a volumen de producción de la organización.

Definición de variables causales

Actualmente, en la línea de Centros de Lavado se fabrican 5 modelos, que corresponden con diferentes soluciones de lavado y sus correspondientes grupos de opcionales.

Aunque cada uno de ellos ha sido lanzado al mercado en distinto momento, las máquinas propias de esta línea tienen un grado de personalización y configuración inferior a las del resto de secciones. En este sentido, generalmente la aparición de un nuevo modelo no constituye un cambio drástico en la línea. Suele tratarse de cambios estéticos, de producto químico o lanzamiento de nuevos opcionales. Este hecho provoca que no sea necesaria una acción comercial tan ponente para dar a conocer los nuevos modelos haciendo que su entrada en el mercado no sea tan progresiva como en el resto de líneas. Por este motivo se ha decidido considerar únicamente una variable causal asociada al número de modelos disponibles en cada momento, en lugar de utilizar una para el número de máquinas nuevas (en fase de lanzamiento) y otra para el número de máquinas en estado de madurez.

De este modo, los valores en cada periodo para dicha variable son los siguientes:

Periodo	Número de modelos de la línea	Periodo	Número de modelos de la línea
1	4	19	7
2	4	20	6
3	4	21	5
4	5	22	5
5	5	23	5
6	5	24	5
7	5	25	5
8	5	26	5
9	5	27	5
10	6	28	5
11	6	29	5
12	6	30	5
13	7	31	5
14	7	32	5
15	7	33	5
16	7	34	5
17	7	35	5
18	7	36	5

Tabla 4-70. Variable explicativa (número de modelos por periodo). Línea de Centros de Lavado

Para esta línea se ha incluido también una variable referente a la fabricación de cantidades inusuales de máquinas idénticas provenientes del lanzamiento de ofertas a clientes concretos o de la consecución de algún contrato especial para la venta e instalación de un grupo de Centros de Lavado.

Debido a que la aparición de este tipo de ofertas conlleva una negociación previa sobre el volumen de ventas que se va a alcanzar, se ha supuesto que este dato era conocido con anterioridad por el planificador. De este modo se han incluido variables causales que absorban el impacto sobre la demanda de dichos eventos especiales y cuyo valor será igual a número de máquinas incluidas en cada oferta. En este sentido, se han considerado las siguientes:

Periodo	Fecha	Valor
4	Abril 2014	11
25	Enero 2016	6
35	Noviembre 2016	25

Tabla 4-71. Variables causales Tenders. Línea de Centros de Lavado

Estas variables corresponden con contratos de ofertas para la instalación de 11 máquinas en abril de 2014 y 6 en enero de 2016 en México y otras 25 que se negociaron con una estación de servicio de Estambul en noviembre de 2016.

Además de esta variable, se han incluido, al igual que en el resto de líneas, las variables causales referentes al año y al mes que definirán la tendencia y estacionalidad de la demanda, respectivamente.

Por último, también se ha considerado la variable causal que definirá los días laborables de cada mes para tener en cuenta las variaciones en las festividades y los días declarados como no laborables por el convenio con los trabajadores.

En los apartados siguientes se presentan los resultados de los cálculos de los pronósticos así como el error cometido por el Modelo Causal

Resultados de las variables de decisión

A continuación se presentan los resultados de todas las variables causales consideradas en el modelo.

Los valores aportados por la variable P_a (valor de la previsión para el año a) que representan la tendencia de la demanda de la línea son:

Año	Previsión-Año
2014	-5
2015	3
2016	0

Tabla 4-72. Valor de la tendencia para la línea de centros

En esta línea se observa una tendencia que asciende entre 2014 y 2015 para luego disminuir ligeramente de 2015 a 2016.

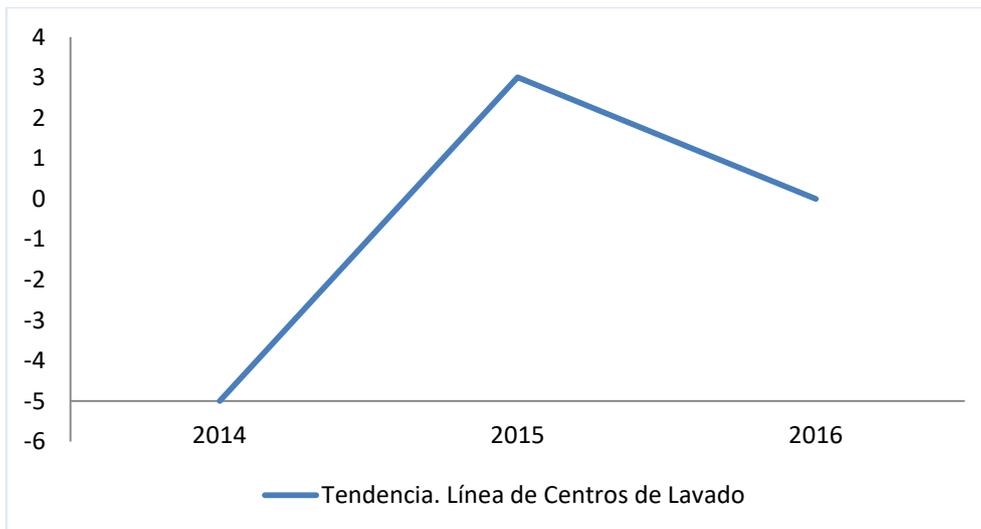


Ilustración 4-45. Gráfico de la tendencia para la línea de Centros de Lavado

Los valores aportados por la variable P_m (valor de la previsión para el mes m) que representan la estacionalidad de la demanda de la línea son:

Mes	Previsión-Mes
1	34
2	24
3	30
4	44
5	34
6	60
7	50
8	0
9	40
10	38
11	26
12	0

Tabla 4-73. Valor de la estacionalidad para la línea de centros

Para la línea de Centros de Lavado la estacionalidad sigue un patrón similar al de resto. En este sentido se observan bajadas de demanda muy marcadas tanto en el mes de agosto como en diciembre, coincidiendo los periodos vacaciones de planta. Además existen dos grandes subidas durante el año, una en el segundo trimestre, que se alarga hasta el mes de julio; y una segunda tras las vacaciones de verano, durante los meses de septiembre, octubre y noviembre.

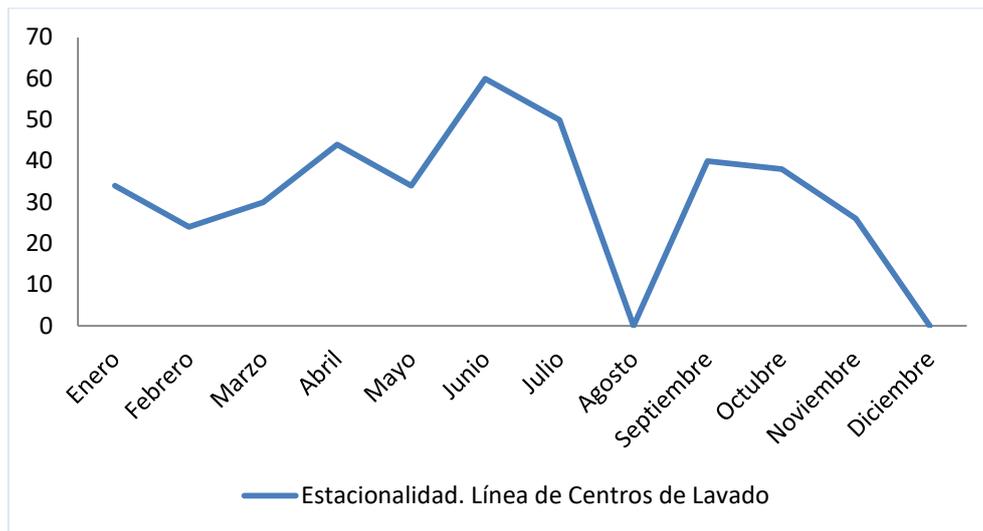


Ilustración 4-46. Gráfico de la estacionalidad para la línea de Centros de Lavado

Los valores aportados por la variable $PrevDL_t$ (valor de la previsión para el número de días laborables l) son:

Días Laborables	Previsión-Días Laborables	Días Laborables	Previsión-Días Laborables
1	0	16	-6
2	0	17	-24
3	0	18	-20
4	0	19	-10
5	13	20	-12
6	-18	21	0
7	0	22	-19
8	12	23	-10
9	0	24	0
10	0	25	0
11	25	26	0
12	0	27	0
13	0	28	0
14	4	29	0
15	13	30	0

Tabla 4-74. Valor de la previsión por días laborables para la línea de centros

Por su parte, valores aportados por la variable $PrevNM_{nm}$ (valor de la previsión para el número de modelos nm) son:

Id	Previsión-Número de Modelos
1	0
2	0
3	0
4	4
5	4
6	20
7	0
8	0

Tabla 4-75. Valor de la previsión por número de modelos para la línea de centros

Analizando los valores de estas variables se puede estudiar el impacto, sobre las ventas totales de la línea, de la inclusión al mercado de cada uno de los modelos que se han ido lanzando durante el periodo de análisis.

Por último, los valores de las variables que representan los acuerdos con distribuidoras tienen los siguientes:

Periodo	Unidades-Tender	Periodo	Unidades-Tender
1	0	19	0
2	0	20	0
3	0	21	0
4	11	22	0
5	0	23	0
6	0	24	0
7	0	25	6
8	0	26	0
9	0	27	0
10	0	28	0
11	0	29	0
12	0	30	0
13	0	31	0
14	0	32	0
15	0	33	0
16	0	34	0
17	0	35	25
18	0	36	0

Tabla 4-76. Valor de la previsión por Tenders para la línea de Centros de Lavado

Cálculo del error de ajuste

Así mismo el modelo devuelve los valores de previsión y error para los periodos analizados:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2014	1	21	21	0	0	0,00%
2014	2	23	10	13	13	56,52%
2014	3	17	17	0	0	0,00%
2014	4	39	43	-4	4	10,26%
2014	5	54	32	22	22	40,74%
2014	6	59	59	0	0	0,00%
2014	7	39	39	0	0	0,00%
2014	8	12	12	0	0	0,00%
2014	9	27	40	-13	13	48,15%
2014	10	35	35	0	0	0,00%
2014	11	29	29	0	0	0,00%
2014	12	19	19	0	0	0,00%
2015	1	14	14	0	0	0,00%
2015	2	21	21	0	0	0,00%
2015	3	23	23	0	0	0,00%
2015	4	27	27	0	0	0,00%
2015	5	24	24	0	0	0,00%
2015	6	38	44	-6	6	15,79%
2015	7	43	43	0	0	0,00%
2015	8	6	6	0	0	0,00%
2015	9	36	35	1	1	2,78%
2015	10	33	33	0	0	0,00%
2015	11	33	33	0	0	0,00%
2015	12	20	20	0	0	0,00%
2016	1	21	21	0	0	0,00%
2016	2	28	28	0	0	0,00%
2016	3	28	24	4	4	14,29%
2016	4	35	35	0	0	0,00%
2016	5	37	38	-1	1	2,70%
2016	6	45	45	0	0	0,00%
2016	7	54	54	0	0	0,00%
2016	8	16	16	0	0	0,00%
2016	9	32	32	0	0	0,00%
2016	10	32	32	0	0	0,00%
2016	11	55	55	0	0	0,00%
2016	12	29	29	0	0	0,00%

Tabla 4-77. Demanda y Previsión 2014-2016 para la línea de centros

En esta línea de producción existen muchos periodos en los que el Modelo Causal explica la demanda al 100% manteniéndose en los demás unos niveles porcentuales de error, en la mayoría de los casos, no demasiado elevados. Sin embargo, aparece un periodo con un error mayor al 50%, que será estudiado posteriormente.

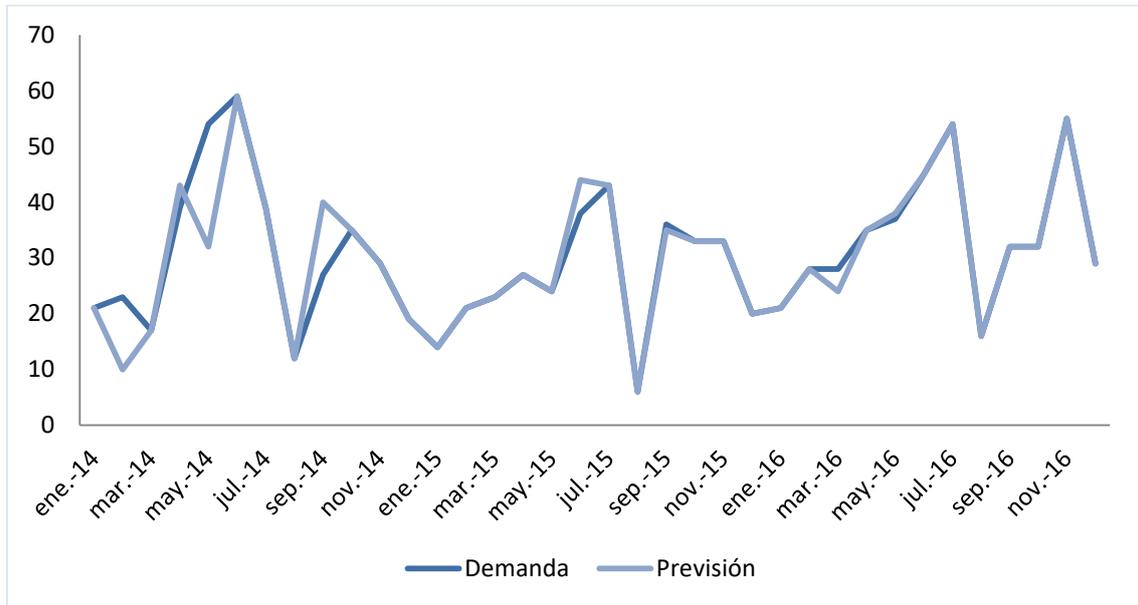


Ilustración 4-47. Demanda y Previsión 2014-2016 para la línea de Centros de Lavado

A continuación se ha calculado el error de ajuste medio del Modelo Causal para esta línea, siendo los resultados los siguientes:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	24,78	4,98	1,78	5,31%	5,94%

Tabla 4-78. Error de ajuste del modelo causal para la línea de centros

Como se anticipaba tras la observación del gráfico anterior, en esta línea, el Modelo Causal consigue unos valores de Error de Ajuste Medio bastante satisfactorios. En valores porcentuales tan solo del 5,31%.

En el siguiente apartado se calcularán las previsiones para 2017, los indicadores de error de pronóstico y se compararán los resultados obtenidos.

Cálculo del error de acierto

Para calcular el error de acierto cometido por el modelo en 2017 se han calculado las previsiones para esos periodos según los valores dados a las diferentes variables consideradas para los periodos anteriores.

Para estimar el valor de la previsión para el año a, se ha aplicado el método de Holt a los resultados de años anteriores. Así se ha obtenido la siguiente estimación para el año próximo.

Año	Previsión-Año
2014	-5
2015	3
2016	0
2017	4

Tabla 4-79. Cálculo tendencia 2017. Línea de Centros de Lavado

Según este método de pronóstico, se espera que para el siguiente año la demanda vuelva a tener una tendencia ascendente aunque más suave que entre los dos primeros años.

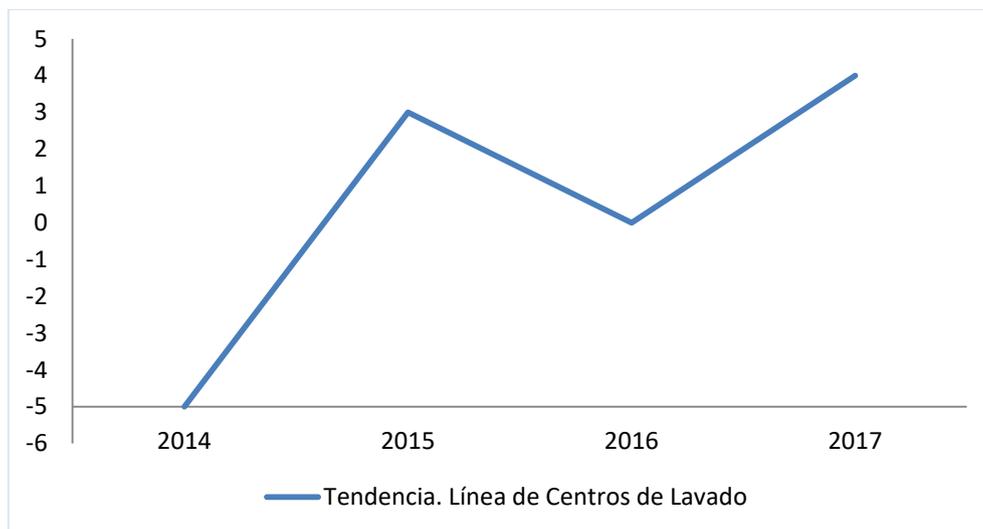


Ilustración 4-48. Tendencia 2017. Línea de Lavado de Vehículos Industriales

En segundo lugar, se le ha dado a la variable valor de la previsión para el mes m los mismos valores que fueron resultado de la aplicación del modelo causal en los periodos de 2014 a 2016. Esta variable representa la estacionalidad de la línea, de modo que es independiente del año.

Mes	Previsión-Mes
1	34
2	24
3	30
4	44
5	34
6	60
7	50
8	0
9	40
10	38
11	26
12	0

Tabla 4-80. Valores de estacionalidad para 2017. Línea de Centros de Lavado

La tercera variable, valor de la previsión para el número de días laborables l , al tratarse de un dato proporcionado directamente de los acuerdos de calendario realizados cada inicio de año entre los trabajadores, simplemente se han recopilado los correspondientes a 2017.

Periodo	Número de días laborables	Periodo	Número de días laborables
37	17	43	21
38	20	44	8
39	23	45	19
40	16	46	20
41	22	47	21
42	22	48	14

Tabla 4-81. Variable explicativa (número de días laborables) para 2017

Seguidamente, para la variable $PrevNM_{nm}$ (valor de la previsión para el número de modelos nm) se ha estimado un valor de 5 unidades para todos los periodos puesto que no se conoce que vaya a haber durante 2017 ningún lanzamiento o retirada de ningún modelo de la línea. De este modo, el valor que aporta a la previsión esta variable será el ya calculado anteriormente para un número de modelos igual a 5:

Periodo	Número de modelos en estado de introducción	Previsión-Número de Modelos
37	5	4
38	5	4

39	5	4
40	5	4
41	5	4
42	5	4
43	5	4
44	5	4
45	5	4
46	5	4
47	5	4
48	5	4

Tabla 4-82. Valor de la previsión por número de modelos para la línea de centros

Seguidamente, para estos nuevos periodos de 2017 no se ha considerado ninguna variable causal referente a Tenders puesto que no se ha obtenido ninguna información previa por parte del Departamento Comercial.

Con estos nuevos datos, se han calculado las previsiones para 2017, siendo los resultados los siguientes:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2017	1	22	18	4	4	18,18%
2017	2	36	20	16	16	44,44%
2017	3	44	28	16	16	36,36%
2017	4	27	46	-19	19	70,37%
2017	5	48	23	25	25	52,08%
2017	6	66	49	17	17	25,76%
2017	7	67	65	2	2	2,99%
2017	8	21	20	1	1	4,76%
2017	9	43	38	5	5	11,63%
2017	10	47	34	13	13	27,66%
2017	11	44	34	10	10	22,73%
2017	12	35	12	23	23	65,71%

Tabla 4-83. Demanda y Previsión 2017 para la línea de Centros de Lavado

En esta línea, la curva de la demanda real y la de la previsión calculada siguen fundamentalmente la misma forma aunque se desvían en todos los periodos. En este sentido, en los que más unidades varían son: en abril de 2017, en el que el error absoluto es de 19 unidades, que en términos porcentuales es un 70,37%, mayo de 2017 con una desviación de 25 unidades, 52,08% y diciembre de 2017 en el que el error es de 23 unidades llegando a un 65,71%.

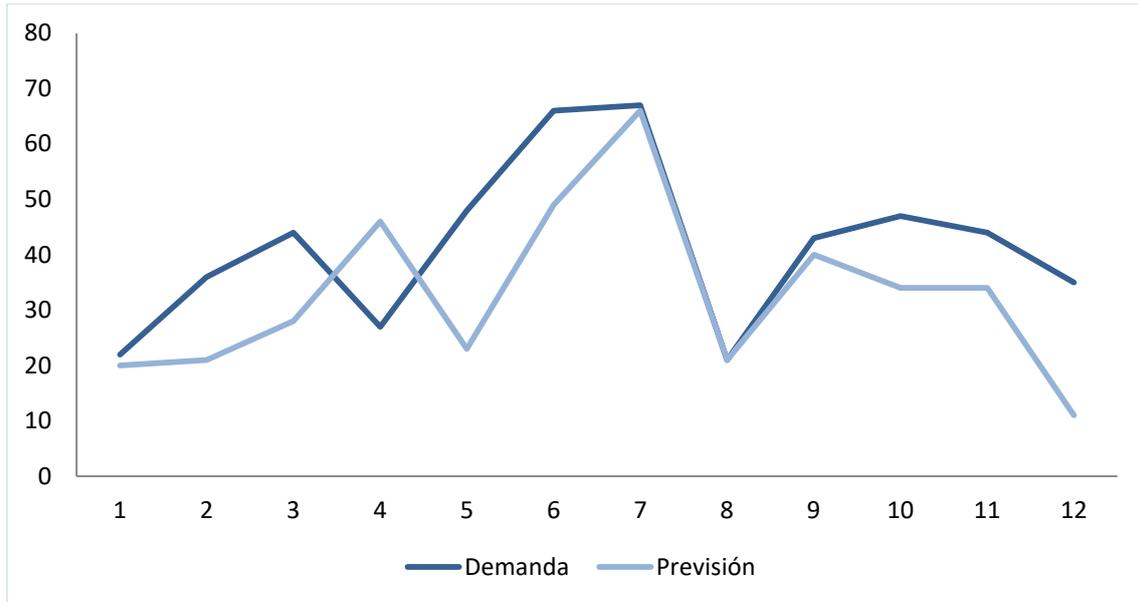


Ilustración 4-49. Comparación Demanda y Previsión 2017. Línea de Centros de Lavado

Los valores medios para el Error de Acierto de esta línea han sido los siguientes:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	219,25	14,81	12,58	31,89%	37,46%

Tabla 4-84. Error de acierto del modelo causal para la línea de centros

Como puede observarse según los valores medios, el Modelo Causal da, en esta ocasión una tasa de acierto menor a la del Método Theta, aplicado anteriormente. Sin embargo, como se han identificado periodos del histórico en los que el modelo ha cometido errores elevados se van a introducir nuevas variables causales con el objetivo de absorber el impacto de un posible evento no considerado en las ecuaciones y que provoca que el modelo no sea capaz de explicar por completo la demanda de estos periodos.

Identificación de valores extraordinarios

Como se puede observar, en esta línea el modelo comete un error de ajuste muy elevado para el periodo $t = 2$ correspondiente al mes de febrero de 2014. Este hecho implica que el modelo matemático no es capaz de explicar la demanda observada durante ese espacio de tiempo. Por tanto, se ha supuesto que durante ese periodo ha influido alguna variable que no ha sido considerada dentro del modelo matemático.

Para calcular la influencia de este evento, que es desconocido para el planificador de demanda, se ha introducido una nueva variable causal que actuará sobre ese periodo. Con ello, se han recalculado los valores de todas las variables así como las nuevas previsiones.

Resultados de las variables de decisión. Segundo Cálculo

A continuación se presentan los resultados obtenidos en el cálculo de las previsiones para la Línea de Centros de Lavado una vez incluida la nueva variable.

En esta ocasión el valor de la variable P_a (valor de la previsión para el año a) que representan la tendencia de la demanda de la línea, y que en este caso ha sido:

Año	Previsión-Año
2014	-5
2015	4
2016	0

Tabla 4-85. Valor de la tendencia para la línea de Centros de Lavado. Segundo Cálculo

La inclusión de la nueva variable ha provocado un aumento de la tendencia para el segundo año mientras que se mantiene idéntica en los otros dos ejercicios del histórico.

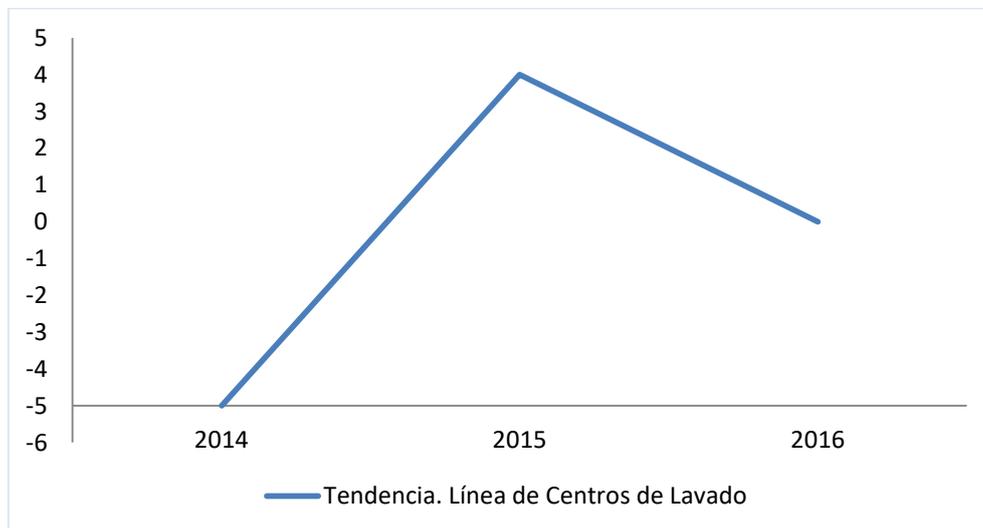


Tabla 4-86. Gráfico de la tendencia para la línea de Centros de Lavado. Segundo Cálculo

En cuanto a los nuevos valores para la variable P_m (valor de la previsión para el mes m) que representan la estacionalidad de la demanda de la línea, los resultados han sido los siguientes:

Mes	Previsión-Mes
1	33
2	24
3	29
4	43
5	33
6	59
7	50
8	0
9	40
10	37
11	25
12	0

Tabla 4-87. Valor de la estacionalidad para la línea de Centros de Lavado. Segundo Cálculo

La línea general de la estacionalidad se ha mantenido desplazándose tan solo en una unidad hacia abajo en algunos de los periodos.

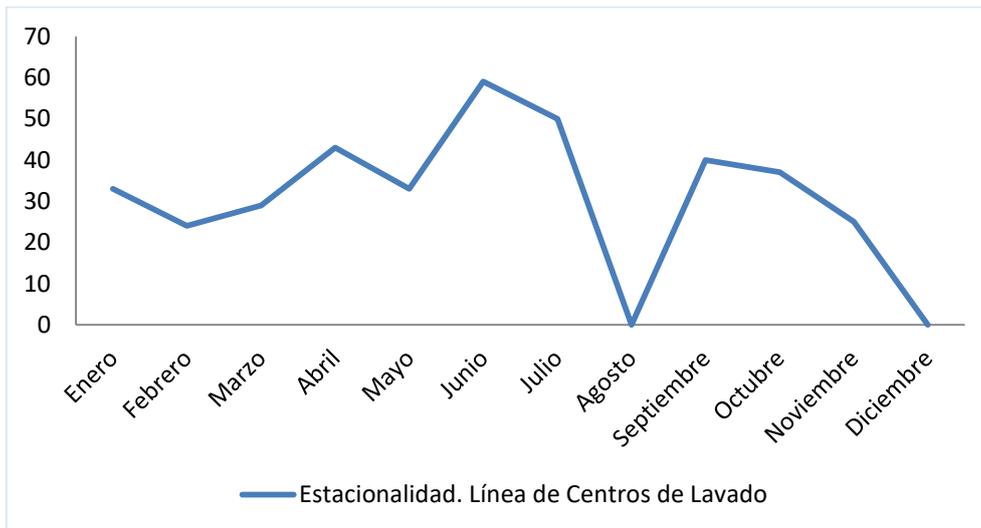


Ilustración 4-50. Gráfico de la estacionalidad para la línea de Centros de Lavado. Segundo Cálculo

En cuanto a los nuevos valores para la variable $PrevDL_l$ (valor de la previsión para el número de días laborables l), también se han mantenido similares al cálculo anterior teniendo pequeñas variaciones:

Días Laborables	Previsión-Días Laborables	Días Laborables	Previsión-Días Laborables
1	0	16	-6
2	0	17	-22
3	0	18	-20

4	0	19	-9
5	12	20	-12
6	-19	21	0
7	0	22	-19
8	12	23	-10
9	0	24	0
10	0	25	0
11	25	26	0
12	0	27	0
13	0	28	0
14	2	29	0
15	12	30	0

Tabla 4-88. Valor de la previsión por días laborables para la línea de Centros de Lavado. Segundo Cálculo

Por su parte, los nuevos valores aportados por la variable $PrevNM_{nm}$ (valor de la previsión para el número de modelos nm) han aumentado ligeramente.

Id	Previsión-Número de Modelos
1	0
2	0
3	0
4	6
5	5
6	22
7	0
8	0

Tabla 4-89. Valor de la previsión por número de modelos para la línea de Centros de Lavado

La variable causal que representa la influencia de las ofertas se mantiene constante. Por tanto, la última a considerar es la recién incluida, $PrevVC_1$ (valor de la previsión asociado a la aparición de la variable causal 1) que son:

Id	Previsión-variable causal
1	-6

Tabla 4-90. Valor de la previsión de la variable causal añadida para la línea de centros

Con la adición de esta nueva variable, los nuevos resultados de previsión son:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2014	1	21	21	0	0	0,00%
2014	2	23	12	11	11	47,83%
2014	3	17	17	0	0	0,00%
2014	4	39	39	0	0	0,00%
2014	5	56	32	22	22	40,74%
2014	6	60	59	0	0	0,00%
2014	7	41	39	0	0	0,00%
2014	8	12	12	0	0	0,00%
2014	9	29	40	-13	13	48,15%
2014	10	36	35	0	0	0,00%
2014	11	30	29	0	0	0,00%
2014	12	19	19	0	0	0,00%
2015	1	14	14	0	0	0,00%
2015	2	21	21	0	0	0,00%
2015	3	24	23	0	0	0,00%
2015	4	28	27	0	0	0,00%
2015	5	26	24	0	0	0,00%
2015	6	41	44	-6	6	15,79%
2015	7	50	43	0	0	0,00%
2015	8	7	6	0	0	0,00%
2015	9	36	36	0	0	0,00%
2015	10	35	33	0	0	0,00%
2015	11	34	33	0	0	0,00%
2015	12	20	20	0	0	0,00%
2016	1	23	21	0	0	0,00%
2016	2	30	28	0	0	0,00%
2016	3	28	24	4	4	14,29%
2016	4	35	35	0	0	0,00%
2016	5	40	37	0	0	0,00%
2016	6	45	45	0	0	0,00%
2016	7	56	54	0	0	0,00%
2016	8	16	16	0	0	0,00%
2016	9	34	32	0	0	0,00%
2016	10	33	32	0	0	0,00%
2016	11	55	54	1	1	1,82%
2016	12	29	29	0	0	0,00%

Tabla 4-91. Demanda y Previsión 2014-2016 para la línea de centros 2

En esta ocasión, las curvas de demanda y previsión son idénticas en muchos de los periodos del histórico, con algunas variaciones sobre todo al inicio de la serie temporal. En este sentido destacan los periodos 2, 5 y 9 en los que se alcanzan errores de más del 40%.

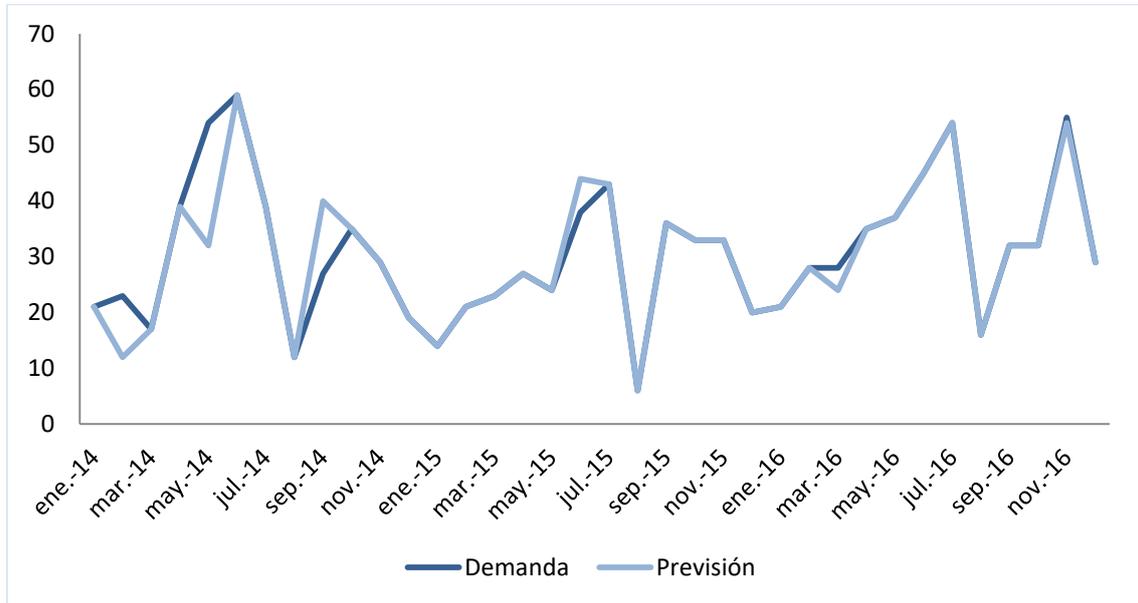


Ilustración 4-51. Demanda y Previsión 2014-2016 para la línea de Centros de Lavado. Segundo Cálculo

Para estos cálculos de la previsión, se ha calculado el error de ajuste del modelo para esta línea siendo los resultados los siguientes:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	22,97	4,79	1,58	4,68%	5,13%

Tabla 4-92. Error de ajuste del modelo causal para la línea de centros. Segundo Cálculo

Los resultados medios de error han mejorado en este segundo cálculo de las previsiones, aunque no lo han hecho drásticamente puesto que en la fase anterior el ajuste eran bastante pequeños. Aun así, han bajado todos los indicadores, consiguiendo, por ejemplo en el caso del MAPE pasar de un 5,31% a un 4,68%.

En el siguiente apartado se estudia el impacto de la inclusión de esta nueva variable causal a los resultados del error de acierto.

Cálculo del error de acierto. Segundo cálculo

Para proyectar el valor de la tendencia hacia 2017 se ha aplicado el método de Holt, siendo los resultados los siguientes:

Año	Previsión-Año
2014	-5
2015	4
2016	0
2017	4

Tabla 4-93. Cálculo tendencia 2017. Línea de Centros de Lavado. Segundo Cálculo

Se espera, por tanto, que la tendencia para 2017 sea de nuevo ascendente, hasta alcanzar los niveles de 2015.

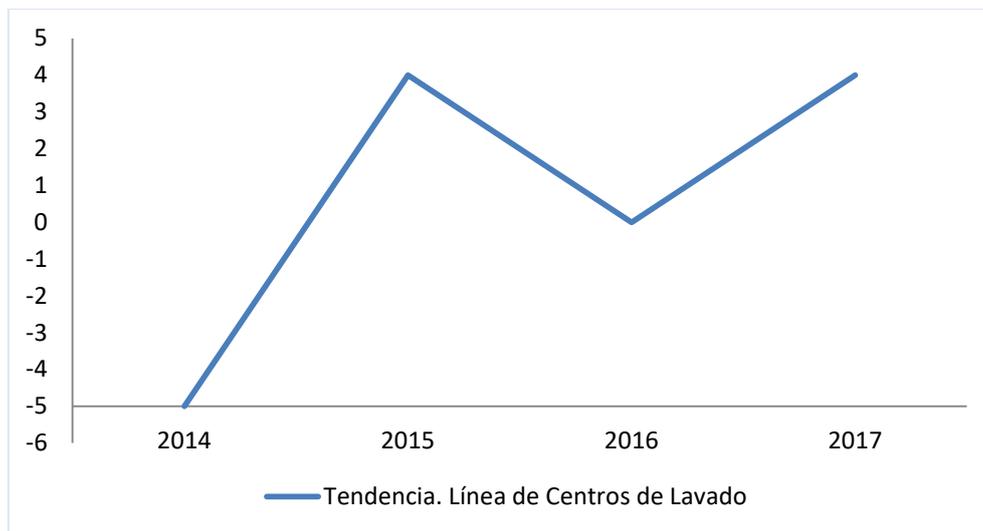


Ilustración 4-52. Tendencia 2017. Línea de Centros de Lavado. Segundo Cálculo

Por su parte, la estacionalidad se ha considerado igual a la obtenida para los periodos de 2014 a 2016 ya que se supone constante año tras año. Por tanto la estacionalidad para 2017 es la siguiente:

Mes	Previsión-Mes
1	33
2	24
3	29
4	43
5	33
6	59

7	50
8	0
9	40
10	37
11	25
12	0

Tabla 4-94. . Valor de la estacionalidad para 2017 para la línea de Centros de Lavado. Segundo Cálculo

Los valores para la variable $PrevNM_{nm}$ (valor de la previsión para el número de modelos nm) para 2017 también se han mantenido iguales a los ya calculados para los tres años anteriores, a saber:

Id	Previsión-Número de Modelos
1	0
2	0
3	0
4	6
5	5
6	22
7	0
8	0

Tabla 4-95. Valor de la previsión por número de modelos para 2017 para la línea de Centros de Lavado. Segundo cálculo

A continuación, los nuevos resultados de demanda y previsión y errores de acierto del Modelo Causal:

Año	Mes	Demanda real	Previsión	Error de pronóstico	Error Absoluto	Error Porcentual
2017	1	22	20	2	2	9,09%
2017	2	36	21	15	15	41,67%
2017	3	44	28	16	16	36,36%
2017	4	27	46	-19	19	70,37%
2017	5	48	23	25	25	52,08%
2017	6	66	49	17	17	25,76%
2017	7	67	66	1	1	1,49%
2017	8	21	21	0	0	0,00%
2017	9	43	40	3	3	6,98%
2017	10	47	34	13	13	27,66%
2017	11	44	34	10	10	22,73%
2017	12	35	11	24	24	68,57%

Tabla 4-96. Demanda y Previsión 2017 para la línea de Centros de Lavado. Segundo cálculo

En este segundo cálculo de las previsiones, se han obtenido mejoras en cuanto los errores de acierto en varios periodos, concretamente en los meses de enero, febrero, julio, agosto y septiembre. Por otro lado, en esta ocasión el modelo explica con menor exactitud el mes de diciembre.

Por otro lado, el modelo continúa cometiendo un error considerable en los meses de abril y mayo, en los que se pronostica una subida durante el primero y baja en el segundo, y la demanda real fue a la inversa; y durante el mes de diciembre en que la demanda fue mucho más elevada de los esperado.

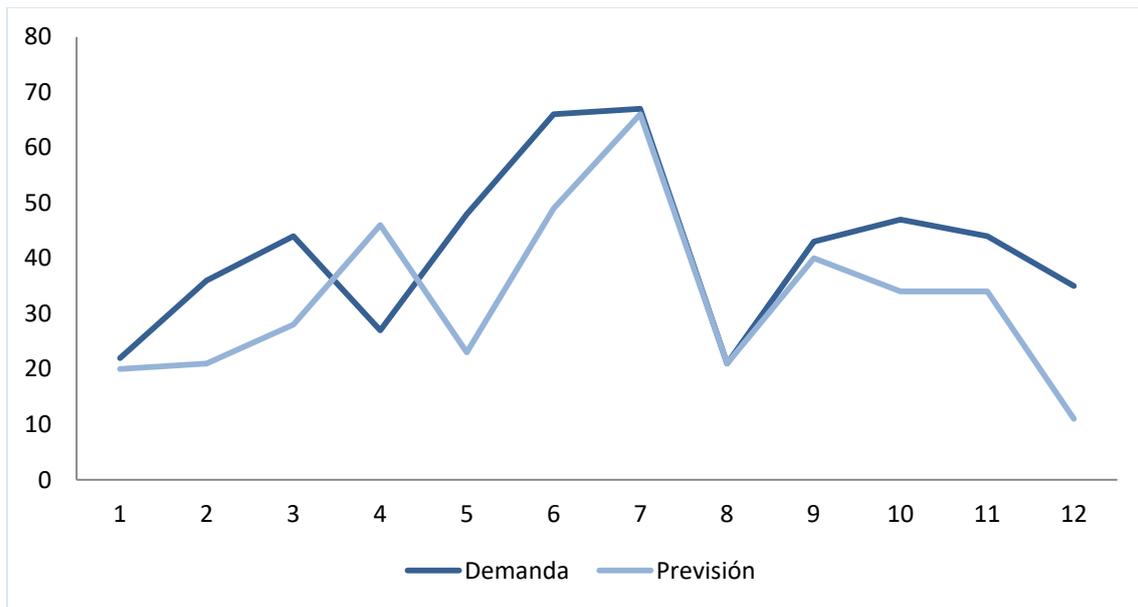


Ilustración 4-53. Comparación Demanda y Previsión 2017 para la línea de Centros de Lavado. Segundo cálculo

Por último, se han recalculados los valores de errores de acierto medio:

Modelo	MSE	RMSE	MAE	MAPE	sMAPE
Causal	217,92	14,76	12,08	30,23%	35,79%

Tabla 4-97. Error de acierto del modelo causal para la línea de centros. Segundo cálculo

Como se intuía por la mejora de los errores de acierto en los diferentes periodos, el valor de los errores medios también ha disminuido. Bien es cierto que no lo ha hecho de forma radical pero sí se han mejorado todos los indicadores.

En cuanto a la comparativa con el Método Theta, aunque el Modelo Causal consigue mejores resultados en ajuste, aún antes de realizar el segundo cálculo incluyendo la variable

explicativa, la línea de Centros de Lavado es la primera para la que el Método Theta ha dado resultados significativamente mejores en cuanto a errores de acierto.

En este sentido, se observa que mientras en el lado izquierdo del gráfico, correspondiente a los tres primeros periodos empleados para el cálculo del ajuste, destaca el bajo error porcentual cometido por el Modelo Causal, que tan solo alcanza valores importantes en tres de los periodos, en la segunda parte, donde se aprecian los errores de acierto, la situación cambia drásticamente siendo el primer modelo el que ofrece unos mejores resultados.

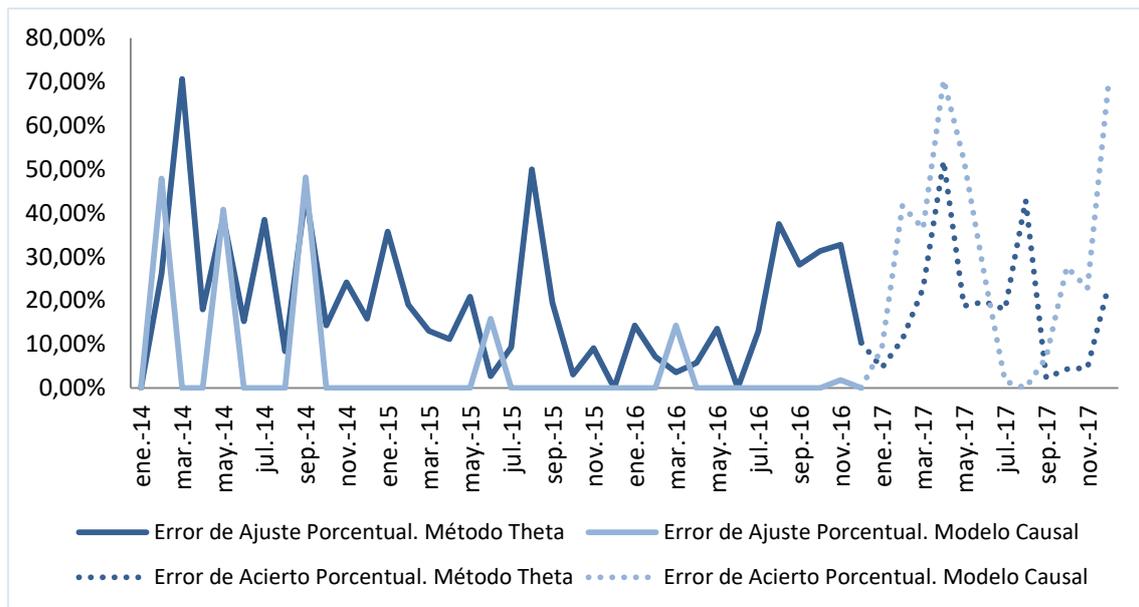


Ilustración 4-54. Comparación del Error Porcentual del Método Theta y el Modelo Causal para la línea de Centros de Lavado

4.3.5 Conclusiones. Aplicación del Modelo Causal.

Tras la aplicación y comparación del Modelo Causal con el Método Theta se puede concluir que el primero da mejores resultados en errores de ajuste en todas líneas de fabricación (incluso antes de aplicar ninguna variable causal extra). Sin embargo, ello no ha conllevado necesariamente una mejora de los errores de acierto en todos los casos.

En las líneas de Túneles de Lavado Automático y Lavado de Vehículos Industriales la aplicación del Modelo Causal ofrece mejores resultados para todos los indicadores. Además la diferencia entre ambos es significativa. Sin embargo en la línea de Túneles de Lavado Automático la ventaja del Modelo Causal no es tan evidente. Aunque se mejora el acierto a nivel porcentual, el resto de los indicadores no favorecen la aplicación de este modelo. Por último el caso de la línea de Centros de Lavado es la única para la que el Método Theta ha dado mejores resultados, aunque solo en cuanto a errores de acierto.

5 Conclusiones y futuras líneas de investigación

Tras la comparación del Método Theta con el Modelo Causal desarrollado, se concluye que, en la obtención de unas previsiones fiables, la naturaleza de las líneas juega un papel fundamental ya que según las características propias de cada una de ellas será adecuado la aplicación de uno u otro modelo. Sin embargo, los mejores resultados de ajuste del Modelo Causal dan a entender que, si se ha conseguido disminuir la tasa de error de los periodos pasados incluyendo las variables explicativas permitientes, probablemente, si se hubiera dispuesto de más y mejor información para hacer lo propio con los periodos futuros, el error de acierto también podría haber sido menor.

En este sentido se podrían haber obtenido estimaciones más certeras de, por ejemplo, la tendencia; o haber incluido variables referentes a anulaciones de modelos, lanzamiento de nuevos productos o acciones comerciales planificadas.

Esto evidencia que de ambos, el Modelo Causal es el más sensible a la calidad de la información disponible. Sin embargo esta cualidad hace también que sea posible mejorarlo conforme ésta se va obteniendo. De este hecho radica la importancia de identificar todas aquellas variables explicativas que, aunque no se haya dispuesto de la información en el momento de realizar el cálculo de los pronósticos, la aparición de errores extraordinarios señala su posible existencia. Esto abre una línea de investigación para el planificador, que buscará la causa de estos errores incluyendo, si fuera necesario, las variables que considere, mejorando el modelo progresivamente.

Con respecto a las previsiones de periodos futuros cabe señalar, además, que las nuevas variables explicativas identificadas podrían ser extrapolables a futuro, bien porque el evento se repita o bien porque aparezca uno diferente pero cuya influencia pueda estimarse por comparación. En este aspecto, el Modelo Causal sí ofrecería una ventaja significativa en cuanto a acierto.

Por último, cabe señalar que para la obtención de toda esta información, tanto pasada como futura, imprescindible para obtener unos pronósticos fiables, un buen complemento para un Modelo Causal sería la implementación de un S&OP dentro de la organización. De este modo el planificador podría obtener información de calidad, de forma regular, y lo que es más importante, consensuada por todas las áreas.

6 Referencias y bibliografía

Anggraeni, W., Vinarti, R.A. and Kurniawati, Y.D. (2015). Performance Comparisons Between ARIMA and ARIMAX Method in Moslem Kids Clothes Demand Forecasting: Case Study. *Procedia Computer Science*, vol. 72, p. 630-637.

Armstrong, J.S. (2006). Findings from evidence-based forecasting: Methods for reducing forecast error. *International Journal of Forecasting*, vol. 22, p. 583-598

Assimakopoulos, V. and Nikolopoulos, K (2000). The theta model: a decomposition approach to forecasting. *International Journal of Forecasting*, vol. 16, p. 521-530.

Beutel, A.L. & Minner, S. (2012). Safety stock planning under causal demand forecasting. *International Journal Production Economics*, vol. 140, p. 637- 645.

Cómo utilizar una Regresión Lineal para realizar un Pronóstico de Demanda (2014). Recuperado de www.gestiondeoperaciones.net

De Arce, R. & Mahía, R. (2003). Modelos Arima. Programa Citius-Técnicas de previsión de variables financieras. UDI Economía e Informática. Recuperado de: http://www.uam.es/personal_pdi/economicas/rarce/pdf/Box-Jenkins.PDF

Escoto, R. P., Hormazabal, J. E. H., Bru, J. M., & Esteban, F. C. L. (2007). Previsión colaborativa: una introducción al Estado del Arte. En XI Congreso de Ingeniería de Organización, p. 863-872.

Gaynor, P.E. & Kirkpatrick, R.C. (1994). *Introduction to Time Series Modeling and Forecasting in Business and Economics*. McGraw-Hill

González, F.R. (2011). Métodos cualitativos de previsión. UPV - Youtube. Valencia. Recuperado de <https://www.youtube.com/watch?v=4wmnaHjCUQU>

Grubbs, F.E. (1969). Procedures for detecting outlying observations in samples. *Technometrics*, vol. 11, p.1- 21.

Hodge, V. & Austin, J. (2004). A Survey of Outlier Detection Methodologies. *Artificial Intelligence Review*, vol. 22, p. 85- 126.

Hoyos, C. y Poler, R. (2013). Propuesta metodológica para la previsión de la demanda con modelos causales. *Revista Dirección y Organización*, vol. 51, p. 44-54.

Limas, S. (2012). *Marketing empresarial: dirección como estrategia competitiva*. Colombia: Ediciones de la U.

Liu, L. M., Hudak, G. B., Box, G. E., Muller, M. E., & Tiao, G. C. (1992). Forecasting and time series analysis using the SCA statistical system (Vol. 1, No. 2). DeKalb, IL: Scientific Computing Associates.

Método Delphi para Pronósticos de Ventas (2015). Recuperado de www.gestiondeoperaciones.net

Newbold, P., & Granger, C. (1974). Experience with Forecasting Univariate Time Series and the Combination of Forecasts. *Journal of the Royal Statistical Society. Series A (General)*, 137(2), 131-165.

Pankratz, A. (2009). *Forecasting with univariate Box-Jenkins models: Concepts and cases*. Vol. 224. John Wiley & Sons.

Poler, R. (2017). *Gestión de Demanda. Gestión Avanzada de Sistemas de Producción e Inventario*. MUIAPLCS. Accedido el 25/09/2017 desde https://poliformat.upv.es/access/content/group/DOC_32603_2018/02.-Transparencias/TEMA%2001/MIAPLCS_GASPI_Tema_01.pdf

Poler, R. (2014). *PrevGIP (versión 2014A) [Software]*. Valencia: Centro de Investigación Gestión e Ingeniería de Producción. Universidad Politécnica de Valencia. Recuperado de <https://poliformat.upv.es>

Quesada, I.F. (2002). Aplicación del Filtro de Kalman al Análisis y Predicción de Entornos Productivos Empresariales. En *II Conferencia de Ingeniería de Organización en Vigo*, p. 725-731.

Ruiz, Esther (1997): "STAMP 5.0: un programa para el análisis de series temporales". Departamento de Estadística y Econometría. Universidad Carlos III de Madrid.

Shcherbakov, M. V., Brebels, A., Shcherbakova, N. L., Tyukov, A. P., Janovsky, T. A., & Kamaev, V. A. E. (2013). A survey of forecast error measures. *World Applied Sciences Journal*, vol. 24, p.171-176.

Zhang, G.P. (2003). Time series forecating using a hybrid ARIMA and neural network model. *Neurocomputing*, vol. 50, p. 159-175.

Zhang, G., Patuwo, E. & Hu, M.Y. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting* vol. 14, p. 35–62.