



UNIVERSIDAD NACIONAL DE COLOMBIA

Aplicación de modelos de series de tiempo para el pronóstico de la demanda de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia)

Beatriz Cecilia Usta Díaz

Universidad Nacional de Colombia
Facultad de Ciencias, Escuela de Estadísticas
Medellín, Colombia
2023

Aplicación de modelos de series de tiempo para el pronóstico de la demanda de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia)

Beatriz Cecilia Usta Díaz

Trabajo de grado presentado como requisito parcial para optar al título de:
Magister en Ciencias-Estadística

Director:
Ph.D. Víctor Ignacio López Ríos

Línea de Investigación:
Profundización

Universidad Nacional de Colombia
Facultad de Ciencias, Escuela de Estadísticas
Medellín, Colombia
2023

A mis hijos Abraham y Elena y a mi esposo José quienes me motivan a emprender estos retos y a mi familia por su apoyo.

Agradecimientos

Al Hospital San Vicente Fundación quien me proporcionó los datos para la realización de este trabajo.

A la escuela de estadística de Universidad Nacional de Colombia sede Medellín y a sus profesores y en especial al profesor Víctor Ignacio López Ríos quien me acompañó y asesoró en el desarrollo de este trabajo.

Resumen

En este trabajo se realiza una aplicación de modelos estadísticos de suavizamiento para el pronóstico de la demanda mensual de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia).

Inicialmente se genera la base de datos de consumo de los medicamentos desde el módulo MM (*Material Management*) del sistema SAP (*Systeme Anwendungen und Produkte*) y se realiza la lectura de la base de datos en R Core Team (2022). Para el análisis se seleccionan dos medicamentos de mayor consumo en el Hospital, el sodio cloruro y la dipirona, se hace un análisis descriptivo de los datos de consumo semanal de cada medicamento, se identifican datos atípicos, sus causas y se realizan los ajustes correspondientes en la base de datos.

Se definen los modelos de suavizamiento a emplear en el pronóstico de la demanda de medicamentos y el modelo de pronóstico que aplica actualmente el Hospital, se realiza el pronóstico de consumo de las últimas cuatro semanas del año 2019 y se compara con los datos reales. Finalmente, se obtienen las métricas de precisión del pronóstico de cada modelo con el objetivo de hacer comparaciones que conduzcan a la selección del mejor modelo de pronóstico.

En el caso del sodio cloruro todos los modelos de suavizamiento presentan mejores valores en las métricas de precisión del pronóstico de la demanda que el método que aplica actualmente el Hospital, siendo el mejor modelo el de suavizamiento exponencial único, y para el caso de la dipirona el mejor modelo es el promedio móvil simple. Finalmente, se calcula el ahorro en unidades de sodio cloruro y dipirona con la aplicación de modelos de suavizamiento frente al modelo actual del Hospital.

Palabras clave: Pronóstico de la demanda, industria farmacéutica, modelado de series de tiempo, eficiencia en la cadena de suministros, hospital.

Abstract

In this work, an application of statistical smoothing models is carried out for the forecast of the monthly demand for medicines in the Hospital San Vicente Fundación (Rionegro/Colombia).

Initially, the drug consumption database is generated from the MM module (*Material Management*) of the SAP system (*Systeme Anwendungen und Produkte*) and the database is read in R Core Team (2022). For the analysis, two drugs with the highest consumption in the Hospital, sodium chloride and dipyrone, were selected, a descriptive analysis of the weekly consumption data of each medication is made, atypical data and their causes are identified and the corresponding adjustments are made in the database.

The smoothing models to be used in the forecast of the demand for medicines and the forecast model currently applied by the Hospital are defined, the consumption forecast for the last four weeks of the year 2019 is made and compared with the real data, finally , the forecast accuracy metrics of each model are obtained in order to make comparisons that lead to the selection of the best forecast model.

In the case of sodium chloride, all the smoothing models present better values in the precision metrics of the demand forecast than the method currently applied by the Hospital, the best model being that of single exponential smoothing, and in the case of dipyrone the best model is the simple moving average. Finally, the savings in sodium chloride and dipyrone units are calculated with the application of smoothing models compared to the current model of the Hospital.

Keywords: Demand forecasting, pharmaceutical industry, time series modeling, supply chain efficiency, hospital.

Contenido

Agradecimientos	vii
Resumen	ix
1. Introducción	1
2. Planteamiento del problema	3
2.1. Descripción del problema	3
2.2. Antecedentes del problema	3
3. Objetivos	5
3.1. Objetivo general	5
3.2. Objetivos específicos	5
4. Marco teórico	6
4.1. Modelo de predicción de series de tiempo	6
4.2. Métodos de suavizamiento	7
4.2.1. Promedio Móvil Simple	7
4.2.2. Suavizamiento Exponencial Único	7
4.2.3. Suavizamiento Exponencial Lineal (Suavizamiento Exponencial de Holt)	8
4.2.4. Suavizamiento Exponencial Lineal y Estacional de Winters, versión multiplicativa.	9
4.3. Métricas de precisión del pronóstico de la demanda	10
5. Metodología	12
5.1. Generación y lectura de la base de datos en R	12
5.2. Análisis descriptivo	14
5.3. Definición de modelos para el pronóstico de consumo	15
5.3.1. Separación de los datos en conjuntos de entrenamiento y prueba	15
5.3.2. Ajuste, evaluación y selección de los modelos de suavizamiento	15
5.4. Comparación de las métricas de precisión del pronóstico de los modelos	16
6. Resultados	17
6.1. Análisis descriptivo para el sodio cloruro	17
6.2. Análisis descriptivo para la dipirona	22
6.3. Definición de modelos para el pronóstico de consumo de sodio cloruro	26
6.3.1. Promedio móvil simple	26

6.3.2.	Suavizamiento exponencial único	30
6.3.3.	Suavizamiento exponencial de Holt	33
6.3.4.	Suavizamiento Exponencial Lineal y Estacional de Winters, versión multiplicativa	36
6.3.5.	Modelo de pronóstico del Hospital	36
6.4.	Definición de modelos para el pronóstico de consumo de dipirona	37
6.4.1.	Promedio móvil simple	37
6.4.2.	Suavizamiento exponencial único	40
6.4.3.	Suavizamiento exponencial de Holt	42
6.4.4.	Suavizamiento Exponencial Lineal y Estacional de Winters, versión multiplicativa	45
6.4.5.	Método de pronóstico del Hospital	45
7.	Análisis de Resultados	46
7.1.	Métricas de precisión del pronóstico de la demanda de sodio cloruro para los modelos evaluados	46
7.1.1.	Comparación del modelo seleccionado vs modelo de pronóstico del Hospital	47
7.2.	Métricas de precisión del pronóstico de la demanda de dipirona para los modelos evaluados	47
7.2.1.	Comparación del modelo seleccionado vs modelo de pronóstico del Hospital	48
8.	Conclusiones y recomendaciones	49
8.1.	Conclusiones	49
8.2.	Recomendaciones	50
A.	Macro para organizar la base de datos que se extrae de SAP	51

1. Introducción

Pronosticar la demanda es un elemento clave en el proceso de planeación de los inventarios en las organizaciones (Valencia-Cárdenas, Díaz-Serna, y Correa-Morales, 2015), en particular, pronosticar la demanda de medicamentos con precisión en entidades hospitalarias cobra suma importancia, debido al equilibrio que debe existir entre la disponibilidad de medicamentos para los pacientes y la optimización de los recursos económicos para la adquisición de los mismos (Maestre *et al.*, 2013). La gestión eficiente de inventarios en los servicios farmacéuticos de los hospitales, contribuye notablemente a la optimización de los gastos hospitalarios globales (Fernández García, 2021).

La estimación de la demanda de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia) consiste en un promedio simple de los últimos tres meses de consumo de medicamentos para la estimación del consumo del siguiente mes para todos los medicamentos del hospital, por lo cual toma importancia ampliar el estudio de otros modelos estadísticos con el objetivo de mejorar la calidad de los pronósticos.

Para la estimación de la demanda de medicamentos en entidades hospitalarias, la literatura presenta la aplicación de diferentes métodos estadísticos de series de tiempo, por lo cual es importante conocer a profundidad estos métodos y utilizarlos de forma adecuada al caso particular en el Hospital San Vicente Fundación (Rionegro/Colombia).

El objetivo es por tanto estudiar y aplicar modelos estadísticos de series de tiempo para el pronóstico de la demanda mensual de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia) con el fin de mejorar la calidad de los pronósticos.

Debido al alto volúmen de medicamentos que se manejan en el hospital, es preciso seleccionar los medicamentos objeto de estudio, teniendo en cuenta los niveles de consumo. Por lo anterior se seleccionaron dos medicamentos con mayores niveles de consumo en el Hospital para la realización del estudio.

Por otro lado, es preciso mencionar, que el personal de la cadena de suministros responsable de realizar el pronóstico de la demanda de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia), no cuenta con formación estadística, por lo tanto, los métodos, metodologías y herramientas propuestas deben contribuir a facilitar el proceso.

En el capítulo 2 se presenta la descripción del problema y la revisión de la literatura de los modelos estadísticos de pronóstico que se aplican para la estimación de la demanda de medicamentos en

diferentes hospitales del mundo y en el sector farmacéutico en general.

En el capítulo 3 se exponen el objetivo general y los objetivos específicos planteados.

En el capítulo 4 se exponen con detalle los modelos que resultan más apropiados para la estimación de la demanda de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia).

En el capítulo 5 se expone la metodología desarrollada, la cual comprende, la descripción del proceso de generación y lectura de la base de datos, el análisis descriptivo, la definición de los modelos para el pronóstico de consumo, la comparación de las métricas de precisión del pronóstico entre los modelos y la selección del mejor modelo de pronóstico.

En el capítulo 6 se presentan los resultados obtenidos al aplicar la metodología para el caso específico del sodio cloruro y la dipirona y en el capítulo 7 se realiza el análisis de esos resultados.

En el capítulo 8 se presentan las conclusiones y las recomendaciones.

2. Planteamiento del problema

2.1. Descripción del problema

Uno de los aspectos más importantes de los modelos de inventarios es el tratamiento dado a la demanda. Precisamente, frente a la incertidumbre de la demanda, los pronósticos de ésta se han utilizado como insumos o entradas para optimizar los inventarios, o como parte del proceso de optimización (Valencia-Cárdenas *et al.*, 2015).

En los hospitales se deben satisfacer por una parte las necesidades clínicas, ya que los costos sociales de la falta de disponibilidad de medicamentos pueden ser inmensos, conduciendo en ocasiones a la pérdida de vidas humanas, y por otro lado, no es posible aumentar demasiado el inventario tanto por motivos económicos como logísticos (Maestre *et al.*, 2013).

En la industria farmacéutica, la previsión de la demanda es fundamental para optimizar y gestionar procesos empresariales complejos (Merkuryeva, Valberga, y Smirnov, 2019). Es importante señalar que cuanto más precisa sea la previsión de la demanda más eficiente será el ahorro en inventario y menor será la escasez (Riahi, Hosseini-Motlagh, y Teimourpour, 2013), sin embargo, la estimación de la demanda constituye un proceso crítico, porque, aunque hay muchos métodos estadísticos, no se utilizan correctamente o se desconocen (Ramirez *et al.*, 2014).

El trabajo planteado contribuirá al pronóstico de la demanda de medicamentos y su adecuada aplicación en el contexto hospitalario, lo cual es un insumo fundamental para el área de farmacia en su gestión de manejo óptimo del inventario de medicamentos.

2.2. Antecedentes del problema

En la literatura se encuentran aplicaciones de modelos de suavizamiento para la estimación de la demanda de medicamentos. Ramirez *et al.* (2014) realizan la selección de los 10 medicamentos más costosos del Hospital Reina Sofía en España y para cada uno se estima la demanda mediante los modelos de series temporales como son media móvil simple, suavizado exponencial, Box-Jenkins: ARIMA (Modelo autorregresivo integrado de media móvil), tomando datos históricos del servicio farmacéutico de las últimas 28 semanas, finalmente se indica para cada medicamento cual es el mejor modelo de estimación de demanda de acuerdo a los valores del error absoluto medio y desviación típica, mientras en Lakshmi Anusha, Alok, y Shaik (2014) utilizan alguna forma de suavizamiento (promedio ponderado) de las observaciones históricas para suprimir las fluctuaciones a corto plazo; las técnicas de pronóstico que se examinan en este estudio son media móvil simple, suavizamiento

exponencial simple, suavizamiento exponencial de Holt, suavizamiento exponencial de Winter.

Otro modelo de pronóstico que también se utiliza es el ARIMA. Pratyaksa, Permanasari, Fauziati, y Fitriana (2016) exponen los resultados empíricos para evaluar y predecir la cantidad de povidona yodada que utiliza el hospital veterinario Prof. Soeparwi. El modelo se selecciona debido a su utilidad para ajustar modelos de pronóstico cuando hay una serie de tiempo no estacionaria y el modelo tiene la capacidad de corregir la tendencia local en los datos.

También se aplican modelos híbridos para la estimación de demanda de medicamento. Riahi *et al.* (2013) desarrollan un marco de modelado híbrido que combina la media móvil integrada autorregresiva (ARIMA) como componente lineal y la red neuronal artificial (ANN) como componente no lineal para la predicción de la demanda de medicamentos en el Hospital de Moheb que es uno de los principales centros de subespecialidades en Irán, mientras que Siddiqui, Azmat, Ahmed, y Kummer (2021) desarrollan e introducen un nuevo modelo de pronóstico híbrido, combinando los modelos ARIMA y Holt y lo denominan ARHOW.

Los anteriores métodos estadísticos propuestos sirven de referencia para determinar cual de ellos aplicar en la construcción del modelo de pronóstico de la demanda de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia).

3. Objetivos

3.1. Objetivo general

Aplicar modelos estadísticos de series de tiempo para el pronóstico de la demanda mensual de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia).

3.2. Objetivos específicos

- Identificar que modelos estadísticos de pronóstico se aplican para la estimación de la demanda de medicamentos en hospitales y en el sector farmacéutico en general y seleccionar entre los modelos estadísticos propuestos en la literatura aquellos que resulten más apropiados.
- Recopilar, preprocesar y analizar la base de datos de demanda de medicamentos en el Hospital San Vicente Fundación (Rionegro/ Colombia).
- Modelar el comportamiento de la serie temporal de la demanda para los medicamentos que se eligieron previamente y posteriormente evaluar su desempeño con datos de prueba.
- Comparar el desempeño y los resultados de cada uno de los modelos ajustados mediante las métricas de precisión más utilizadas, como son el error medio (ME), la raíz del error cuadrado medio (RMSE), el error absoluto medio (MAE), el error porcentual medio (MPE) y el error porcentual absoluto medio (MAPE).

4. Marco teórico

En este capítulo se expondrá el modelo de predicción de series de tiempo y los métodos de suavizamiento que se aplican en la predicción de la demanda de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia). Todo el desarrollo teórico fue extraído del texto de Makridakis y Wheelwright (2007).

4.1. Modelo de predicción de series de tiempo

Un modelo de series de tiempo supone la existencia de algún patrón o combinación de patrones recurrentes en el tiempo que al ser identificados permiten hacer pronósticos para períodos posteriores, a partir de datos observados del pasado.

El valor real observado será determinado por algún patrón más algunas influencias aleatorias o desviaciones entre los valores reales observados y los pronosticados. El objetivo es minimizar tales desviaciones o errores de pronóstico.

Los valores reales observados se representan por una variable aleatoria X la cual toma diferentes valores dependiendo del período de tiempo t . Además, el valor de la predicción para el período de tiempo $t + 1$ se denota por \hat{X}_{t+1} .

Los errores se definen como la diferencia entre el valor real y lo que se ha pronosticado, ver ecuación (4-1)

$$e_t = X_t - \hat{X}_t. \quad (4-1)$$

Donde e_t es la diferencia entre los valores real X_t y pronosticado \hat{X}_t .

Algunos de los tipos de patrones que se pueden identificar en los datos de series de tiempo son los siguientes:

- Patrón horizontal: No hay tendencia alguna de los datos. Cuando existe tal patrón, generalmente se hace referencia a la serie como estacionaria, es decir, no tiende a aumentar o disminuir a través del tiempo de ninguna manera sistémica.
- Patrón estacional: Cuando una serie fluctúa de acuerdo con un factor estacional.

- Patrón cíclico: Es semejante al patrón estacional, pero la duración de un ciclo único generalmente es mayor a un año.
- Patrón tendencial: Cuando existe un aumento o disminución general del valor de la variable a lo largo del tiempo.

4.2. Métodos de suavizamiento

Los métodos de suavizamiento se aplican cuando se requiere predecir la demanda de grandes volúmenes de artículos y no es práctico desarrollar y aplicar un método refinado de predicción para cada uno, proporcionando pronósticos razonablemente buenos en el corto plazo.

En los métodos de suavizamiento, los datos históricos se usan para obtener un valor “suavizado” para la serie. El valor suavizado se extrapola después para convertirse en el valor futuro de la serie.

En las subsecciones siguientes se presenta una descripción de los métodos de suavizamiento.

4.2.1. Promedio Móvil Simple

En este método el pronóstico del valor futuro es igual al promedio de los últimos N datos históricos, se actualiza eliminando la primera observación y agregando la última.

El modelo se representa de la siguiente forma:

$$\hat{X}_{t+1} = l_t = \frac{X_t + X_{t-1} + \dots + X_{t-N+1}}{N} = \frac{1}{N} \sum_{i=t-N+1}^t X_i, \quad (4-2)$$

donde \hat{X}_{t+1} es el pronóstico para el tiempo $t+1$, l_t es el valor suavizado en el tiempo t , X_i es el valor actual en el tiempo i , i es el período de tiempo y N es el número de valores incluidos en el promedio.

La principal desventaja que presenta este método es que al ser un promedio, todas las observaciones tienen el mismo peso, cuando en realidad se debería dar mayor peso a las observaciones más recientes por tener información más actualizada del comportamiento de los datos.

4.2.2. Suavizamiento Exponencial Único

El modelo de suavizamiento exponencial único tiene la siguiente forma:

$$\hat{X}_{t+1} = \alpha X_t + (1 - \alpha)\hat{X}_t. \quad (4-3)$$

Para hallar un nuevo pronóstico se requiere la observación más reciente X_t , el pronóstico más reciente \hat{X}_t y un valor para α . Tanto α como $(1 - \alpha)$ son números entre cero y uno.

Si la ecuación anterior se expande al sustituir el valor de \hat{X}_t que es igual a $\hat{X}_t = \alpha X_{t-1} + (1-\alpha)\hat{X}_{t-1}$ y luego $\hat{X}_{t-1} = \alpha X_{t-2} + (1-\alpha)\hat{X}_{t-2}$ y así sucesivamente, se obtiene:

$$\begin{aligned} \hat{X}_{t+1} = & \alpha X_t + \alpha(1-\alpha)X_{t-1} + \alpha(1-\alpha)^2 X_{t-2} + \\ & \alpha(1-\alpha)^3 X_{t-3} + \dots \end{aligned} \quad (4-4)$$

Puesto que α y $(1-\alpha)$ son números entre cero y uno, las ponderaciones α , $\alpha(1-\alpha)$, $\alpha(1-\alpha)^2$, etc., tienen valores decrecientes exponencialmente, asignando las ponderaciones más bajas a los valores más antiguos.

Para determinar el valor de α , Correa Moreno (2004) propone un procedimiento de tanteo que consiste en considerar diferentes valores de α como 0.1, 0.2, 0.3, ..., 0.9 y para cada uno de esos valores se estiman los pronósticos, los errores de los pronósticos, la suma de los cuadrados de los errores (SSE), se comparan los SSE calculados y se elige el α para el cual el SSE es mínimo. Si se requiere mayor precisión, se elige un incremento menor.

El promedio móvil simple y el suavizamiento exponencial único pueden utilizarse efectiva y económicamente cuando el patrón histórico de los datos se puede considerar como horizontal. Sin embargo, estas técnicas pueden no ser efectivas al manejar patrones estacionales.

4.2.3. Suavizamiento Exponencial Lineal (Suavizamiento Exponencial de Holt)

El método del suavizamiento exponencial de Holt toma en consideración la presencia de tendencia en una serie de datos, se utiliza para pronosticar una serie de tiempo con tendencia, pero sin patrón estacional. Una estimación suavizada de la tendencia en la serie de datos es la siguiente:

$$b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1}, t = 1, 2, \dots, T. \quad (4-5)$$

Donde l_t es equivalente del valor suavizado exponencial único, β es el coeficiente de suavizamiento, análogo a α y b_t denota la tendencia suavizada en la serie de datos.

La tendencia más reciente, $(l_t - l_{t-1})$, está ponderada por β y la última tendencia suavizada, b_{t-1} , está ponderada por $(1-\beta)$. La suma de estos valores ponderados es el nuevo valor de la tendencia suavizada.

El suavizamiento exponencial de Holt utiliza la ecuación (4-5) para obtener un valor suavizado de la tendencia y combina dicha tendencia con la ecuación estándar de suavizamiento para obtener:

$$l_t = \alpha X_t + (1-\alpha)(l_{t-1} + b_{t-1}). \quad (4-6)$$

La única diferencia entre ésta y la forma anterior, la ecuación (4-3), es el término adicional b_{t-1} que se suma a l_{t-1} para ajustar los valores suavizados del patrón tendencial de la serie de datos.

El pronóstico está dado por

$$\hat{X}_t = l_{t-1} + b_{t-1}. \quad (4-7)$$

El SSE se define como:

$$SSE(\alpha, \beta) = \sum_{t=1}^T (X_t - \hat{X}_t)^2. \quad (4-8)$$

Los parámetros de suavizamiento se escogen mediante un proceso de minimización del SSE, esto implica un problema de minimización no lineal y se requiere una herramienta de optimización para resolverlo según lo expuesto por R. J. Hyndman y Athanasopoulos (2018).

$$\begin{aligned} (\hat{\alpha}, \hat{\beta}) &= \operatorname{argmin} SSE(\alpha, \beta) \\ (\alpha, \beta) &\in (0, 1)^2 \end{aligned} \quad (4-9)$$

4.2.4. Suavizamiento Exponencial Lineal y Estacional de Winters, versión multiplicativa.

Este método tiene la ventaja de manejar datos con tendencia y estacionalidad. El suavizamiento exponencial lineal y estacional de Winters se basa en tres ecuaciones, cada una de las cuales suaviza un factor asociado con uno de los tres componentes del patrón (aleatoriedad, tendencia y estacionalidad):

$$l_t = \alpha \frac{X_t}{s_{t-m}} + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (4-10)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (4-11)$$

$$s_t = \gamma \frac{X_t}{l_t} + (1 - \gamma)s_{t-m} \quad (4-12)$$

donde l es el valor suavizado de la serie desestacionalizada, b es el valor suavizado de la tendencia, s es el valor suavizado del factor estacional y m es el período de estacionalidad.

La razón X_t/l_t hace referencia al nivel de estacionalidad de los datos. X_t es el valor actual de los datos que contiene estacionalidad, mientras que l_t está suavizado y no la contiene. La estacionalidad en cada período contiene aleatoriedad, por lo cual debe ser promediada o suavizada.

Para suavizar dicha estacionalidad, la ecuación de s_t pondera el factor estacional recientemente calculado (X_t/l_t) con γ y el número estacional más reciente que corresponde a la misma estación s_{t-m} con $(1 - \gamma)$.

La ecuación de b_t suaviza la tendencia pues pondera la tendencia incremental ($l_t - l_{t-1}$) con β y el valor tendencial previo b_{t-1} con $(1 - \beta)$.

En la ecuación del valor suavizado l_t , el primer término se divide entre el factor estacional s_{t-m} , esto se hace para desestacionalizar (eliminar las fluctuaciones estacionales) de X_t .

La predicción basada en el método de Winters se calcula como:

$$\hat{X}_{t+h} = (l_t + hb_t)s_{t-m+h}. \quad (4-13)$$

Uno de los problemas que acompañan el uso del método de Winters consiste en determinar los valores de α, β, γ que minimizan el error cuadrado medio (MSE) ó la desviación media absoluta (MAD). El enfoque para realizar esto es el de ensayo y error. La búsqueda de los valores óptimos se hace mediante un enfoque de rejilla en donde los resultados hallados para valores diferentes de α, β, γ , se comparan para encontrar la combinación que minimiza el MSE.

4.3. Métricas de precisión del pronóstico de la demanda

Las métricas de precisión del pronóstico de demanda más comúnmente utilizadas para evaluar la calidad de los pronósticos son variaciones de las siguientes métricas básicas: sesgo de pronóstico, error absoluto medio (MAE), error cuadrático medio (MSE) y error porcentual absoluto medio (MAPE)(Merkuryeva *et al.*, 2019).

Las métricas usadas por Ramirez *et al.* (2014) para comparar la calidad de los pronósticos de los modelos propuestos son: error medio, error absoluto medio y desviación típica.

A continuación se presentan las fórmulas matemáticas de las métricas de precisión del pronóstico. Los errores se definen como la diferencia entre el valor real y lo que se ha pronosticado, ver ecuación (4-1) y n es el número de períodos pronosticados.

- Error medio

$$ME = \frac{\sum_{t=1}^n e_t}{n}. \quad (4-14)$$

- Error absoluto medio

$$MAE = \frac{\sum_{t=1}^n |e_t|}{n}. \quad (4-15)$$

- Error cuadrado medio

$$MSE = \frac{\sum_{t=1}^n e_t^2}{n}. \quad (4-16)$$

- Raíz del error cuadrado medio

$$RMSE = \frac{\sum_{t=1}^n e_t^2}{n}. \quad (4-17)$$

- Desviación típica de los errores

$$SDE = \sqrt{\frac{\sum_{t=1}^n e_t^2}{n-1}}. \quad (4-18)$$

- Error porcentual

$$PE_t = \frac{X_t - \hat{X}_t}{X_t} 100\%. \quad (4-19)$$

- Error porcentual medio

$$MPE = \frac{\sum_{t=1}^n PE_t}{n}. \quad (4-20)$$

- Error porcentual absoluto medio

$$MAPE = \frac{\sum_{t=1}^n |PE_t|}{n}. \quad (4-21)$$

5. Metodología

En este capítulo se expone y aplica la metodología llevada a cabo en el desarrollo de este trabajo, la cual comprende la generación y lectura de la base de datos, el análisis descriptivo, la identificación y el tratamiento de los datos atípicos, la definición de los modelos de suavizamiento para el pronóstico de consumo y del método que aplica actualmente el hospital, y la comparación de las métricas de precisión del pronóstico de consumo para los modelos evaluados.

En las siguientes secciones se presenta una descripción detallada de los pasos que se realizaron para los medicamentos elegidos para la realización del respectivo pronóstico.

5.1. Generación y lectura de la base de datos en R

La base de datos de consumo de los medicamentos que se manejan en el Hospital San Vicente Fundación (Rionegro/Antioquia), se genera desde el módulo MM (*Material Management*) del sistema SAP (*Systeme Anwendungen und Produkte*), de acuerdo a los criterios definidos en la **Tabla 5-1**.

Debido al comportamiento atípico presentado durante el período de pandemia comprendido entre marzo de 2020 y septiembre de 2021, se tomó la decisión de analizar los datos entre enero de 2018 y diciembre de 2019.

El sistema arroja un archivo en Excel para cada mes con los siguientes campos de información:

- Código del medicamento: Código numérico de 10 dígitos con el cual se identifica un medicamento.
- Nombre del medicamento: Descripción breve del medicamento.
- Almacén: Almacén desde el cual se despacha el medicamento (si es una salida por paciente o por servicio) o almacén al cual se devuelve el medicamento (si es una devolución por paciente o por servicio).
- Clase de movimiento (951, 952, 201, 202): Las clases de movimiento 951 y 201 son salidas de medicamento del almacén a las salas donde se aplica el medicamento al paciente, mientras que 952 y 202 son devoluciones desde las salas al almacén.
- Documento de material: Código del documento de material que se genera por cada transacción de despacho/devolución de medicamento.

Campo	Selección	Código
Transacción	Movimiento de Material	mb51
Material	Medicamentos	1000000000 a 1999999999
Centro	Rionegro	5000
Almacén	Almacén General	5100
	Quirófano y Proc	5200
	Control Rio	5302
	Torre B - Piso 2	5303
	Torre B - Piso 3	5304
	Torre B - Piso 4	5305
	Torre 2 - Piso 1	5306
	Torre 2 - Piso 2	5307
	Central de mezclas	5308
	Uci Rionegro	5309
	Cardiovascular	5310
	Hospital Día	5311
	Rehabilitación	5312
	Radiología	5400
Almacen devoluciones	V151	
Clase de movimiento	Salida por paciente	951
	Devolución por paciente	952
	Salida por servicio	201
	Devolución por servicio	202
Fecha contabilización	Enero 2018 a Diciembre de 2019	

Tabla 5-1.: Criterios para la generación de la base de datos

- Pos: Posición en el documento de material en el que se encuentra un registro de despacho/devolución de medicamento. En un mismo documento de material pueden haber varias posiciones y para cada posición se indica la cantidad de medicamento despachado/devuelto.
- Fecha de contabilización: Fecha en la que se genera el despacho/devolución de medicamento.
- Cantidad de medicamento despachado o devuelto: La cantidad de medicamento despachado es negativa dado que es una salida del inventario del almacén a las salas donde se aplica el medicamento al paciente, mientras que la cantidad de medicamento devuelto desde las salas es positiva dado que es un ingreso al inventario del almacén.
- Unidad de manejo del medicamento: Forma en la que se maneja el medicamento físico.

Para que la base de datos que arroja SAP quede organizada de forma adecuada para su análisis, es necesario ejecutar una macro, cuyo código se presenta en el Anexo A. La lectura de la base de datos se realiza en R Core Team (2022), al hacer la lectura, el sistema arroja un mensaje advirtiendo sobre datos NA en la columna cantidad de medicamento, por lo cual después de verificar que no fueran datos mal digitados, se procede a eliminar estos registros de la base de datos y se consolidan todos los archivos por mes en un único archivo que contiene toda la información de los años a analizar.

El análisis del consumo de medicamentos es preciso hacerlo por semana, por lo cual es necesario hacer uso de un calendario en el cual se asocie a cada día del año el número de la semana al cual corresponde. El año tiene 52 semanas completas, por lo cual los días que quedan en la semana 53

de un determinado año se adicionan a la primera semana del año siguiente, de tal forma que todos los años queden con 52 semanas completas. Finalmente, se realiza un cruce entre la fecha de contabilización de la base de datos y las fechas del calendario, de tal manera que se pueda identificar el número de la semana que le corresponde a cada registro de la base de datos.

El consumo de cada tipo de medicamento por semana corresponde a la suma de los despachos y las devoluciones por semana. Así mismo, el consumo de cada tipo de medicamento por día y mes corresponde a la suma de los despachos y devoluciones por día y mes.

Para definir los medicamentos objeto de estudio, se determinó la cantidad de consumo para todos los medicamentos durante los dos años de análisis y se seleccionaron los dos medicamentos con mayores volúmenes de consumo que son sodio cloruro con código 1000000598 y de manejo en bolsa y dipirona con código 1000000473 y unidad de manejo en ampolla.

5.2. Análisis descriptivo

Para el análisis descriptivo de los datos se tienen en cuenta las siguientes variables:

- Cantidad de medicamento despachado: Unidades de medicamento despachado por semana desde el almacén a las salas donde se aplica el medicamento al paciente, es una cantidad negativa por ser una salida del inventario del almacén. Denotado por D_t : Cantidad de medicamento despachado en la semana t .
- Cantidad de medicamento devuelto: Unidades de medicamento devuelto por semana desde las salas donde se aplica el medicamento al almacén, es una cantidad positiva por ser una entrada al inventario del almacén. Denotado por V_t : Cantidad de medicamento devuelto en la semana t .
- Consumo de medicamento: Corresponde a la suma de la cantidad despachada desde el almacén (negativa) y la cantidad devuelta al almacén (positiva); debido a que la cantidad de medicamento despachado puede ser mayor o igual que el medicamento devuelto, el consumo de medicamento es una cantidad negativa. Esta es la variable de interés ya que el objetivo es hacer pronóstico de la demanda semanal de medicamentos en el hospital. Denotado por $X_t = D_t + V_t$: Consumo de medicamento en la semana t .

Se identifican datos atípicos en la serie de consumo semanal (X_t) discriminado por día de la semana y en la serie de consumo semanal sin discriminar por día de la semana para cada medicamento, se revisa la base de datos original para hallar la causa de los puntos atípicos (semanas que no tienen información de consumo para todos los días) y se realizan los ajustes correspondientes a la serie de acuerdo a la causa (imputación, eliminación).

5.3. Definición de modelos para el pronóstico de consumo

A continuación se describen los pasos a seguir para la definición de los diferentes modelos de suavizamiento que se aplicarán en el pronóstico de la demanda de medicamentos.

5.3.1. Separación de los datos en conjuntos de entrenamiento y prueba

Los datos de entrenamiento para los modelos de suavizamiento corresponden a las 47 semanas del año 2018 de las cuales se tiene información y las primeras 48 semanas del año 2019, y los datos de prueba corresponden a las últimas cuatro semanas del año 2019.

Los datos de entrenamiento para el modelo del hospital corresponden a los meses 9, 10 y 11 del año 2019, y el dato de prueba corresponde al mes 12 del año 2019.

5.3.2. Ajuste, evaluación y selección de los modelos de suavizamiento

- Promedio móvil simple: El modelo se representa de la forma indicada en la ecuación (4-2). Se ajustan 10 modelos de promedio móvil simple con un número de valores incluidos en el promedio desde 1 hasta 10, al número de valores que se utilizan en el promedio se le denomina orden del promedio móvil simple. Para cada uno de los modelos ajustados, se hace el pronóstico de las últimas cuatro semanas, se compara con los datos de prueba y se calculan las métricas de precisión de pronóstico, finalmente, se selecciona el modelo del orden que presenta el menor valor en las métricas.
- Suavizamiento exponencial único: El modelo se representa de la forma indicada en la ecuación (4-3). Se ajustan modelos de suavizamiento exponencial único con α desde 0,01 hasta 0,99 con incremento de 0,01. Para cada uno de los modelos ajustados, se hace el pronóstico de las últimas cuatro semanas, se compara con los datos de prueba y se calculan las métricas de precisión de pronóstico, finalmente, se selecciona el modelo con el valor α que presenta el menor valor de las métricas.
- Suavizamiento Exponencial de Holt Original: El modelo se representa de la forma indicada en las ecuaciones (4-5), (4-6) y (4-7). Se ajusta el modelo de suavizamiento exponencial de Holt, se pronostican las últimas cuatro semanas del año 2019, se comparan con los datos de prueba y se calculan las métricas de precisión de pronóstico. Los parámetros α , β y los valores iniciales l_0 y b_0 del modelo se estiman minimizando el SSE para los errores de entrenamiento, ver ecuación (4-8).
- Suavizamiento exponencial de Holt Optimizado: El modelo se representa de la forma indicada en las ecuaciones (4-5), (4-6) y (4-7). Se ajustan modelos de suavizamiento exponencial de

Holt original con α variando desde 0,01 hasta 0,99 con incremento de 0,01 y β variando desde 0,0001 hasta 0,005 con incremento de 0,0001 y para cada uno de los modelos ajustados, se hace el pronóstico de las últimas cuatro semanas del año 2019, se compara con los datos de prueba y se calculan las medidas de error de pronóstico, finalmente, se estima el valor de los parámetros α y β del modelo que presenta el menor valor de cada una de las medidas de error de pronóstico. A diferencia del modelo Holt original donde los parámetros α y β y valores iniciales l_0 y b_0 se estiman minimizando el SSE para los errores de entrenamiento, en el modelo Holt optimizado, se estiman minimizando medidas para los errores de prueba.

- Método de pronóstico del hospital: El modelo de pronóstico que aplica actualmente el Hospital consiste en promediar los datos de consumo de los últimos tres meses para pronosticar el consumo del siguiente mes, lo cual es equivalente al modelo de promedio móvil simple de orden tres y horizonte de pronóstico uno. Se separan los datos de entrenamiento y prueba, tomando como dato de prueba el último mes del año 2019 y se ajusta un modelo de promedio móvil simple de orden tres, con horizonte de pronóstico uno, con los datos de entrenamiento.

Para hacer comparable el pronóstico mensual que aplica el hospital con el pronóstico semanal que se ha aplicado con los demás métodos de suavizamiento presentados, se divide el pronóstico del último mes de 2019 entre 4,33 y de esta forma se obtiene una estimación del pronóstico de las últimas cuatro semanas.

5.4. Comparación de las métricas de precisión del pronóstico de los modelos

Se realiza comparación de las métricas de precisión de pronóstico de cada modelo de suavizamiento y del modelo que aplica actualmente el hospital y se selecciona el modelo con mejores métricas.

6. Resultados

6.1. Análisis descriptivo para el sodio cloruro

En la **Figura 6-1** se muestra el comportamiento de los despachos, las devoluciones y el consumo semanal de sodio cloruro durante 2018 y 2019. Los despachos y el consumo representados por las series en color rojo y azul respectivamente, son cantidades negativas, mientras las devoluciones en color verde son cantidades positivas.

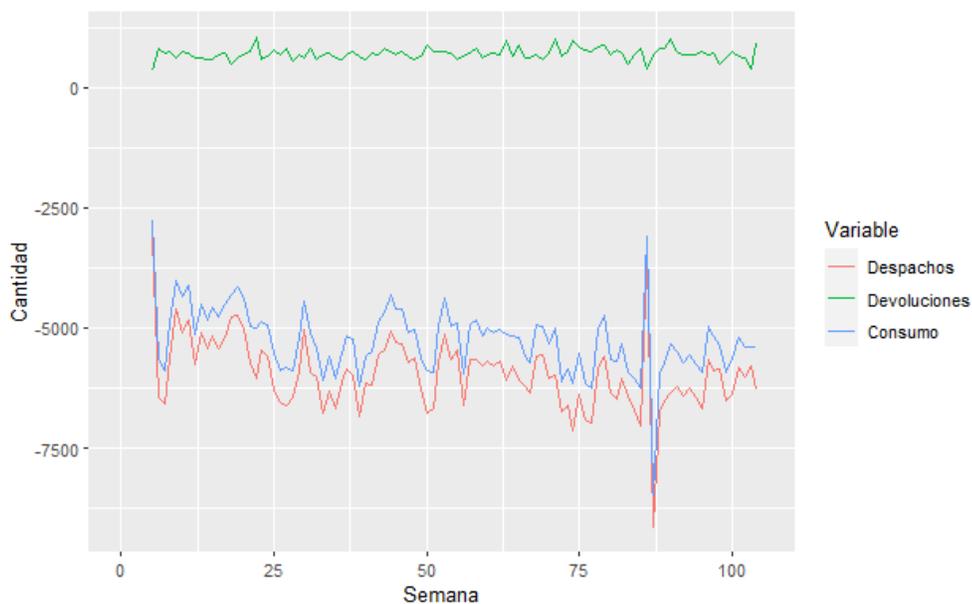


Figura 6-1.: Despachos, devoluciones y consumo semanal de sodio cloruro

En la **Figura 6-2** se muestra el comportamiento del consumo semanal de sodio cloruro. Se observan datos atípicos de consumo en la semana 5, 86 y 87.

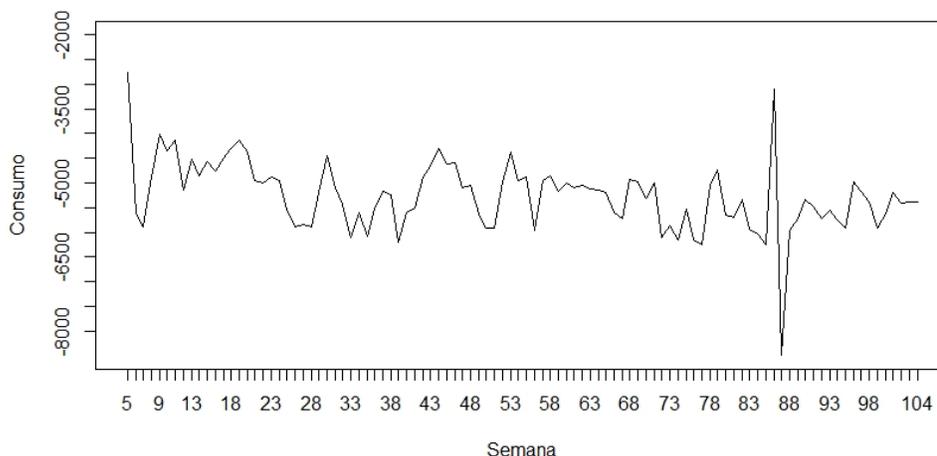


Figura 6-2.: Consumo semanal de sodio cloruro

Para analizar los datos atípicos observados en la semana 5, 86 y 87, se hizo una revisión de la base de datos, encontrando que en la semana cinco sólo se tiene información de cuatro días y adicionalmente que para los días 20 y 21 de agosto de 2019, que hacen parte de la semana 86, no hay información de despachos y devoluciones para ningún medicamento del hospital. Por lo tanto, en la semana 86 se visualiza una disminución considerable en el consumo de medicamentos y en la semana 87 un aumento considerable en el consumo, lo que nos permite considerar que durante el 20 y 21 de agosto ocurrieron fallas en el sistema que no permitió hacer el registro de los despachos y devoluciones de medicamentos en el hospital, los cuales fueron ingresados al sistema posteriormente en la semana 87. Por lo anterior, se toma la decisión de eliminar la semana cinco del análisis, y promediar el consumo de la semana 86 y 87 e imputarlo a ambas semanas.

En la **Figura 6-3** se muestra el comportamiento de consumo de sodio cloruro de acuerdo al día de la semana sólo para aquellas semanas que tienen información de consumo para todos los días, por lo cual se excluyen las semanas 5, 86 y 87 por no contar con la información completa de consumo para todos los días. Se observa que en general durante el 2018 hay mayor variabilidad del consumo por día de la semana que en el 2019, y adicionalmente que el consumo los días viernes en el 2018 es mucho mayor que el resto de los días. También se observa un incremento considerable en el consumo de la semana 45 en la **Figura 6-3**, debido a que el día sábado de esa semana se realizó un proceso de depuración de la bodega virtual, el cual consiste en que aquellos medicamentos que han sido devueltos en el sistema pero que nunca llegaron físicos al almacén sean descontados del inventario del almacén y cargados contablemente a las salas donde se administra el medicamento. A partir de ese momento se observa que el comportamiento de consumo por día de la semana tiene menor dispersión debido a la implementación de políticas de mayor control sobre el despacho y devolución de medicamentos. Por lo anterior, se toma la decisión de eliminar los despachos asociados al documento de material donde ocurrió la depuración de la bodega virtual, lo cual corresponde a 782 bolsas de sodio cloruro.

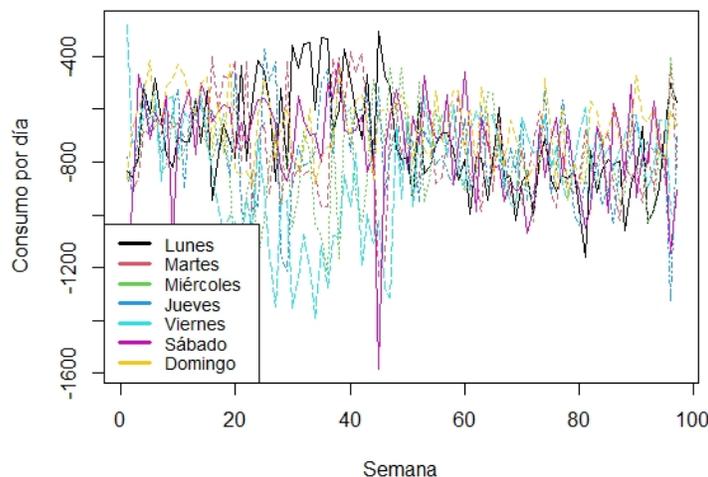


Figura 6-3.: Comportamiento de consumo de sodio cloruro por día de la semana

En la Tabla 6-1 se observa que existe mayor desviación de los datos de consumo de cloruro de sodio por día de la semana en 2018 que en 2019, sin embargo, como el objetivo no es hacer pronóstico de consumo diario sino semanal debido al tiempo de antelación con el cual se deben realizar los pedidos, el análisis por tanto se realizará a la serie de datos de consumo semanales.

Día	Media (2018)	Media (2019)	Media (2018-2019)	Desviación estándar (2018)	Desviación estándar (2019)	Desviación estándar (2018-2019)
Lunes	-605.36	-826.62	-719.41	173.38	130.89	188.42
Martes	-705.62	-790.22	-749.23	205.49	131.06	175.52
Miércoles	-809.6	-790.26	-799.63	197.64	144.72	171.76
Jueves	-710.81	-809.06	-761.45	201.06	139.59	178.19
Viernes	-928.74	-753.04	-838.18	265.19	124.43	222.24
Sábado	-693.26	-774.52	-735.14	197.82	162.22	183.98
Domingo	-648.64	-696.02	-673.06	137.14	118.58	129.44

Tabla 6-1.: Comparativo media y desviación estándar de consumo de sodio cloruro por día de la semana para los datos de 2018, 2019 y 2018-2019

A continuación en la **Figura 6-4**, se observa la serie de datos de consumo semanal de sodio cloruro eliminando la semana cinco, imputando a la semana 86 y 87 el promedio de consumo de estas dos semanas y eliminando los despachos asociados al documento de material donde ocurrió la depuración de la bodega virtual de acuerdo al análisis descriptivo realizado anteriormente.

El consumo promedio semanal de sodio cloruro es de $-5278,657$ y la desviación estándar es de $545,7229$.

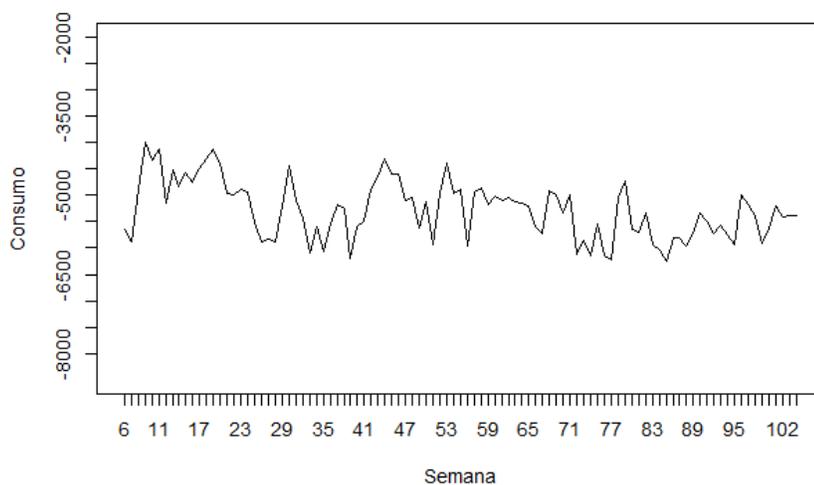


Figura 6-4.: Consumo semanal de sodio cloruro

No hay un comportamiento que se repita en la serie de consumo mensual en los años 2018 y 2019, ver **Figura 6-5**, ni en la serie de consumo semanal en los años 2018 y 2019, ver **Figura 6-6**. En la **Figura 6-7** y **Figura 6-8** podemos observar en el comportamiento de la función de autocorrelación (ACF) y función de autocorrelación parcial (PACF) que la serie no presenta correlación con los retrasos estacionales.

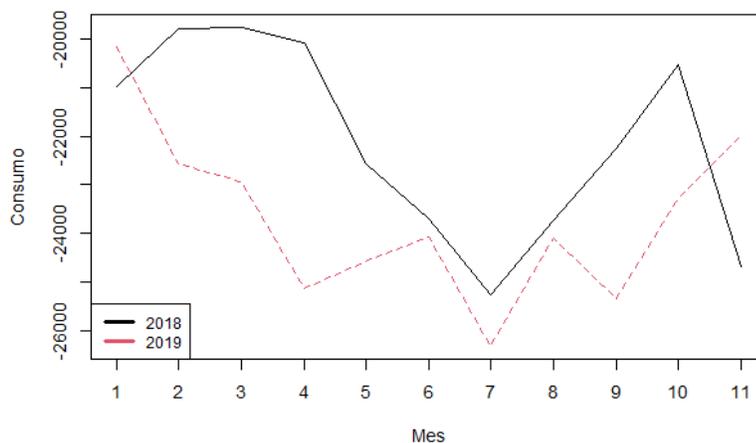


Figura 6-5.: Consumo mensual de sodio cloruro 2018 y 2019

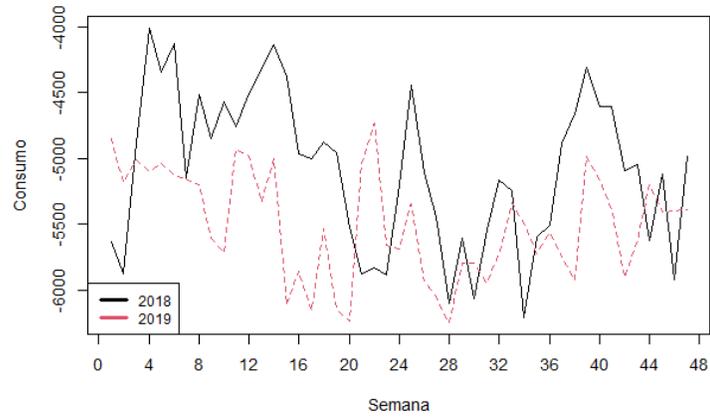


Figura 6-6.: Consumo semanal de sodio cloruro 2018 y 2019

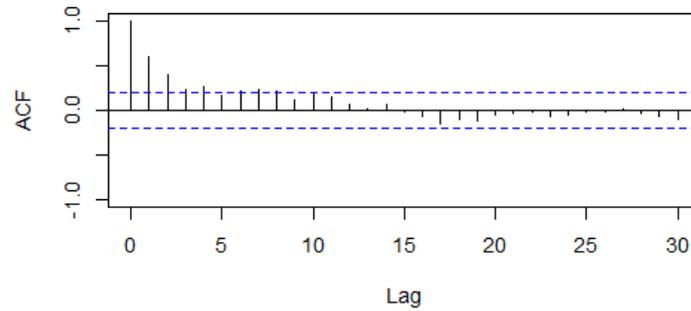


Figura 6-7.: ACF sodio cloruro

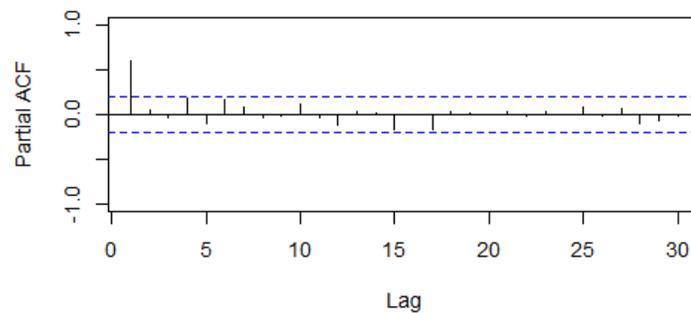


Figura 6-8.: PACF sodio cloruro

6.2. Análisis descriptivo para la dipirona

En la **Figura 6-13** se muestra en la línea de color rojo el comportamiento de los despachos, en la línea de color verde las devoluciones y en la línea de color azul el consumo semanal de dipirona durante 2018 y 2019.

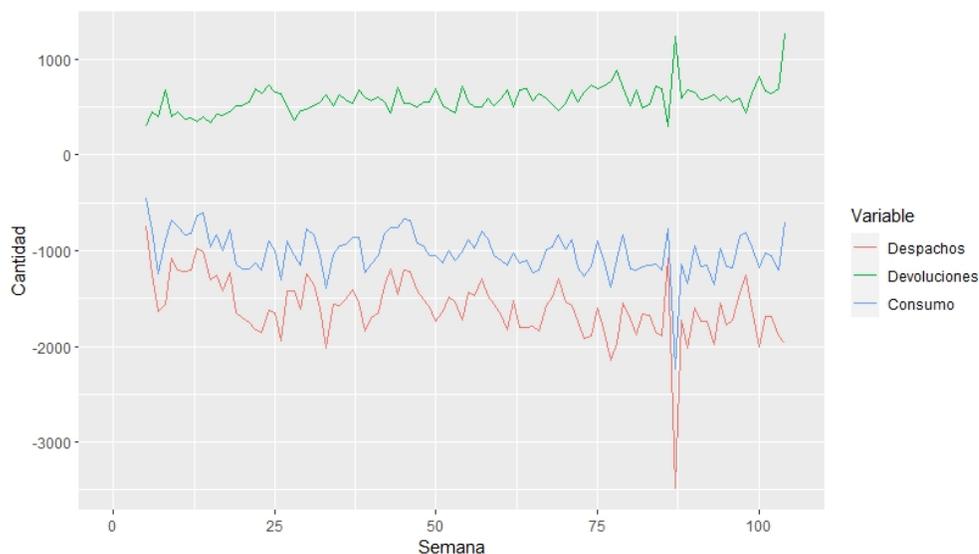


Figura 6-9.: Despachos, devoluciones y consumo semanal de dipirona

En la **Figura 6-14** se muestra el comportamiento del consumo semanal de dipirona. Se observan puntos atípicos de consumo en la semana 5, 86 y 87.

Para analizar el comportamiento de los datos de consumo del medicamento debido a los puntos atípicos observados en la semana 5, 86 y 87, se revisó la base de datos, encontrando que en la semana 5 sólo se tiene información de cuatro días y adicionalmente que para los días 20 y 21 de agosto de 2019, que hacen parte de la semana 86, no hay información de despachos y devoluciones para ningún medicamento del hospital. Por lo tanto, en la semana 86 se visualiza una disminución considerable en el consumo de medicamentos y en la semana 87 un aumento considerable en el consumo, lo que nos permite considerar que durante el 20 y 21 de agosto ocurrieron fallas en el sistema que no permitió hacer el registro de los despachos y devoluciones de medicamentos en el hospital, los cuales fueron ingresados al sistema posteriormente en la semana 87. Por lo anterior se toma la decisión de eliminar la semana 5 del análisis, y promediar el consumo de la semana 86 y 87 e imputarlo a ambas semanas.

En la **Figura 6-11**, se presenta el comportamiento de consumo de dipirona de acuerdo al día de la semana, solamente para aquellas semanas que tienen información para todos los días, por lo cual se excluyen las semanas 5, 86 y 87 por no contar con la información completa de consumo para todos los días.

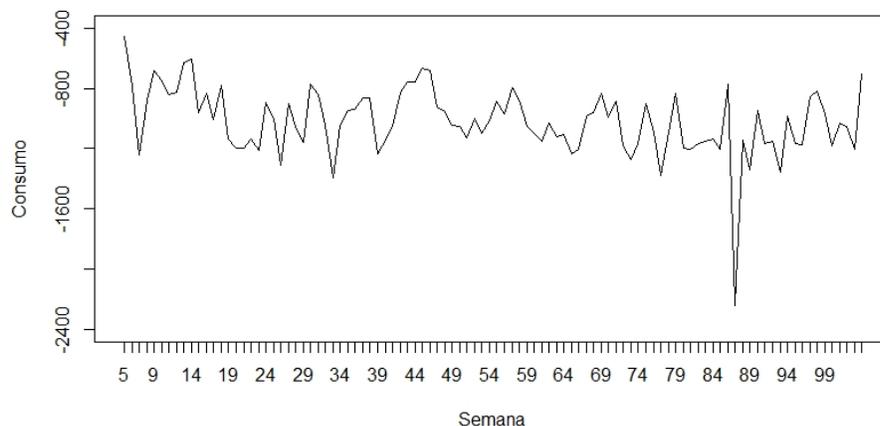


Figura 6-10.: Consumo semanal de dipirona

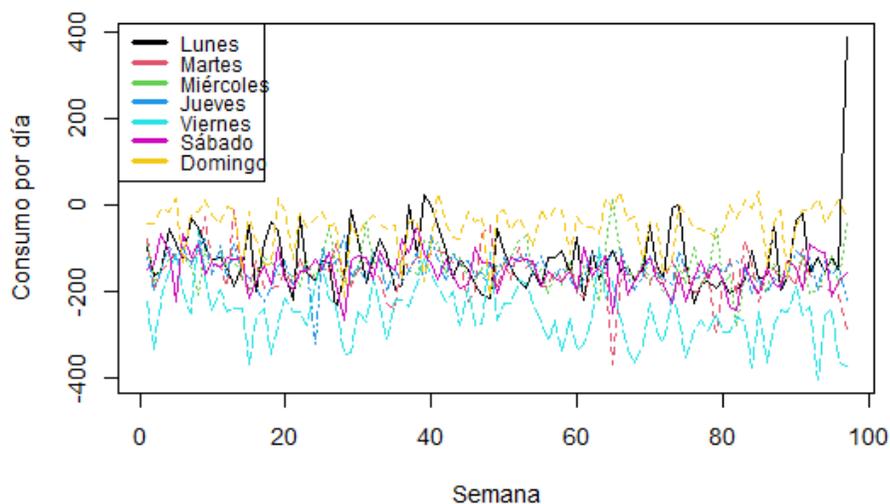


Figura 6-11.: Comportamiento de consumo de dipirona por día de la semana

Se observa que la variabilidad del consumo por día de la semana es similar en 2018 y 2019, el consumo los días viernes es mayor que los otros días de la semana y el consumo los días domingo es menor que los otros días de la semana. Adicionalmente el día lunes de la semana 97 se observa una disminución considerable en el consumo debido a la devolución de 546 ampollas de dipirona que estaban en las salas y era necesario tenerlas en inventario para el cierre contable de final de año, adicionalmente el día martes de la semana 65, se observa un consumo mayor que los martes de otras semanas, sin embargo, no se encuentran datos atípicos de despachos o devolución de dipirona ese día particular.

En la **Tabla 6-2** se observa un comparativo de la media y la desviación estándar de los datos de dipirona por día de la semana, para los años 2018 y 2019, sin embargo, como el objetivo no es hacer pronóstico de consumo diario si no semanal debido al tiempo de antelación con el cual se deben realizar los pedidos, el análisis por tanto se realizará a la serie de datos de consumo semanales.

Día	Media (2018)	Media (2019)	Media (2018-2019)	Desviación estándar (2018)	Desviación estándar (2019)	Desviación estándar (2018-2019)
Lunes	-114.6	-126.7	-120.84	64.01	92.96	80.07
Martes	-142.74	-169.38	-156.47	47.23	51.81	51.16
Miércoles	-138.32	-150.88	-144.79	36.44	50.98	44.75
Jueves	-143.51	-151.44	-147.6	44.08	29.81	37.42
Viernes	-227.98	-268.1	-248.66	63.63	64.68	66.95
Sábado	-138.32	-161.8	-150.42	42.1	38.91	41.96
Domingo	-51.13	-42.1	-46.47	54.15	51.95	52.94

Tabla 6-2.: Comparativo media y desviación estándar de consumo de dipirona por día de la semana para los datos de 2018, 2019 y 2018-2019

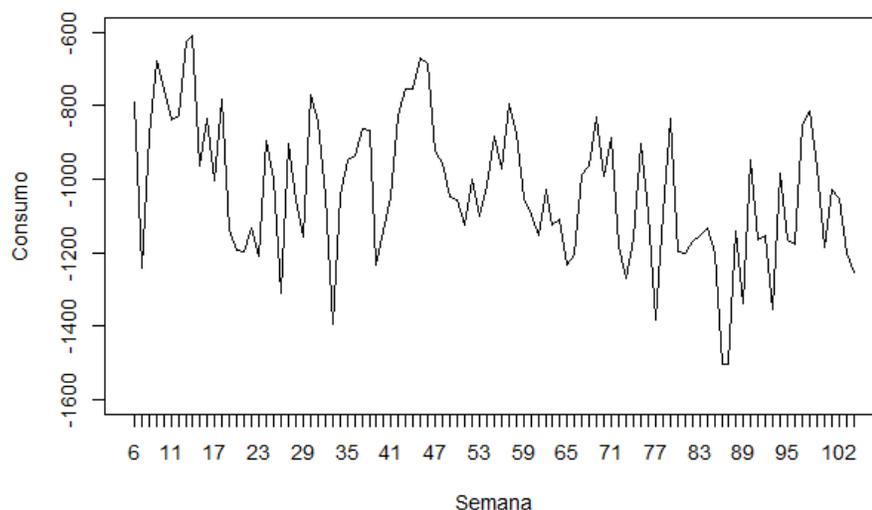


Figura 6-12.: Consumo semanal de dipirona

En la **Figura 6-12**, se observa la serie de datos de consumo semanal de dipirona eliminando la semana 5, imputando a la semana 86 y 87 el promedio de consumo de estas dos semanas y eliminando los registros asociados al documento de material donde se reportó la devolución de 546 ampollas de dipirona para el cierre contable del año, de acuerdo al análisis descriptivo realizado anteriormente.

La media de la serie de datos de consumo semanal de dipirona es de $-1030,677$ y la desviación estándar es de $190,2872$.

No hay un comportamiento que se repita en la serie de consumo mensual en los años 2018 y 2019, ver **Figura 6-13**, ni tampoco en la serie de consumo semanal en los años 2018 y 2019, ver **Figura 6-14**. En la **Figura 6-15** y **Figura 6-16** podemos observar en el comportamiento de la función de autocorrelación (ACF) y función de autocorrelación parcial (PACF) que la serie no presenta correlación con los retrasos estacionales.

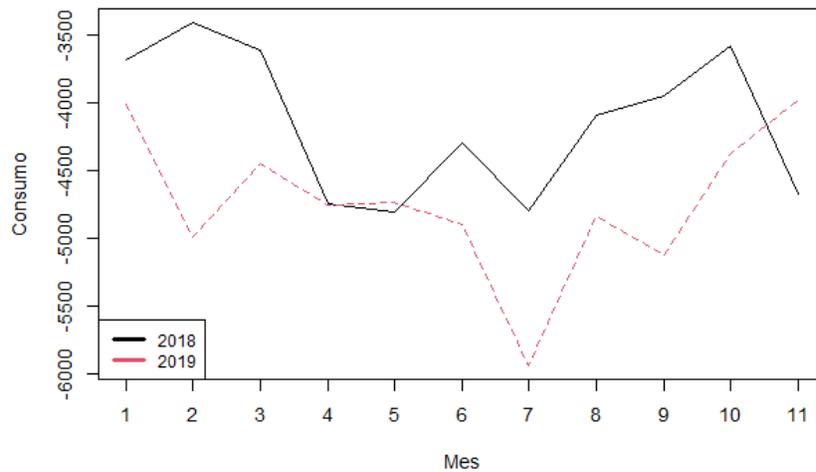


Figura 6-13.: Consumo mensual de dipirona 2018 y 2019

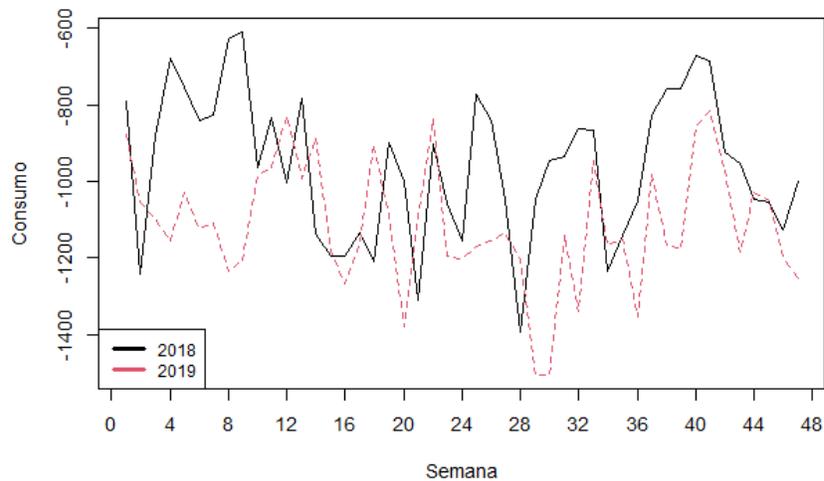


Figura 6-14.: Consumo semanal de dipirona 2018 y 2019

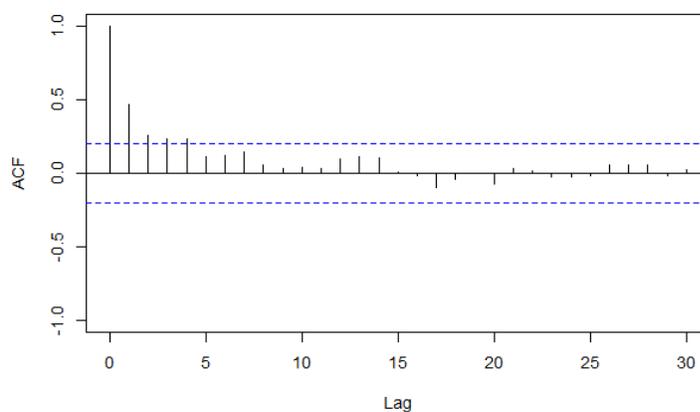


Figura 6-15.: ACF sodio cloruro

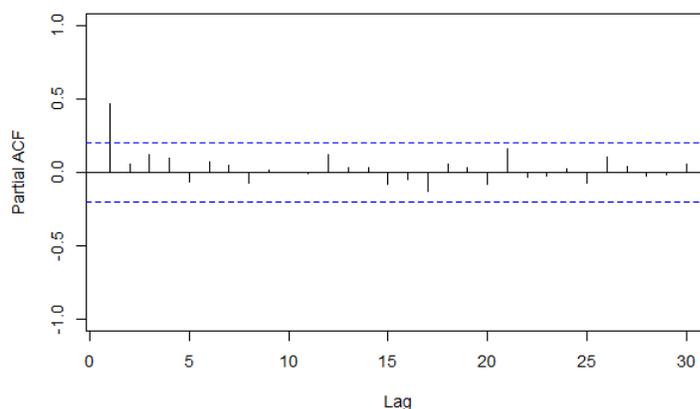


Figura 6-16.: PACF sodio cloruro

6.3. Definición de modelos para el pronóstico de consumo de sodio cloruro

6.3.1. Promedio móvil simple

Se ajustaron 10 modelos de promedio móvil simple con orden desde 1 hasta 10, para cada modelo se hace el pronóstico de las últimas cuatro semanas del año 2019, se calculan las medidas de error de pronóstico y se determina el orden del modelo que presenta el menor valor de las medidas de error de pronóstico.

El orden del modelo con ME mínimo es 6 (**Figura 6-17**), el orden del modelo con RMSE mínimo es 5 (**Figura 6-18**), el orden del modelo con MAE mínimo es 6 (**Figura 6-19**), el orden del modelo

6.3 Definición de modelos para el pronóstico de consumo de sodio cloruro 27

con MPE mínimo es 2 (**Figura 6-20**), el orden del modelo MAPE mínimo es 6 (**Figura 6-21**). Las medidas mínimas que coinciden en el orden del modelo son ME, MAE y MAPE (**Figura 6-22**).

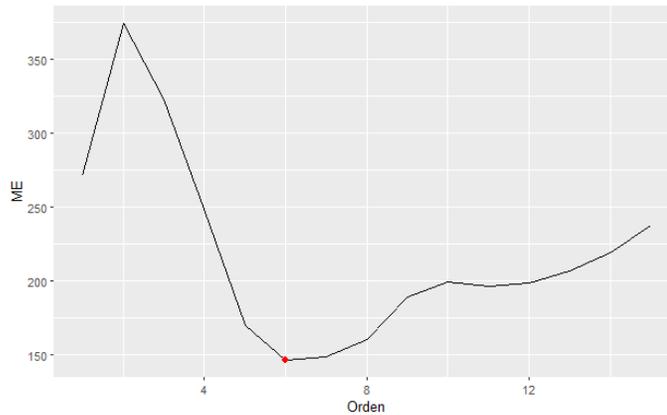


Figura 6-17.: ME de los pronósticos de sodio cloruro para diferentes valores del orden en el promedio móvil simple

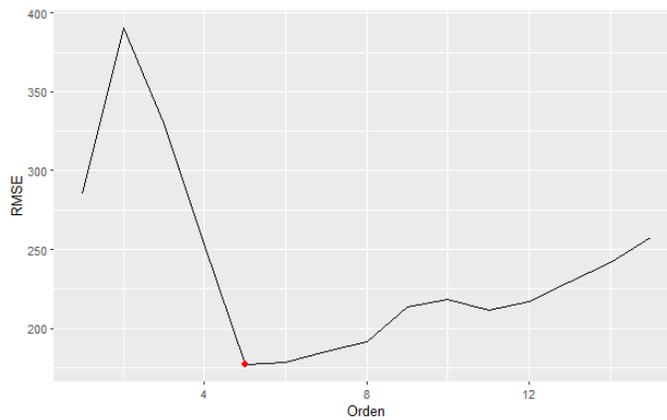


Figura 6-18.: RMSE de los pronósticos de sodio cloruro para diferentes valores del orden en el promedio móvil simple

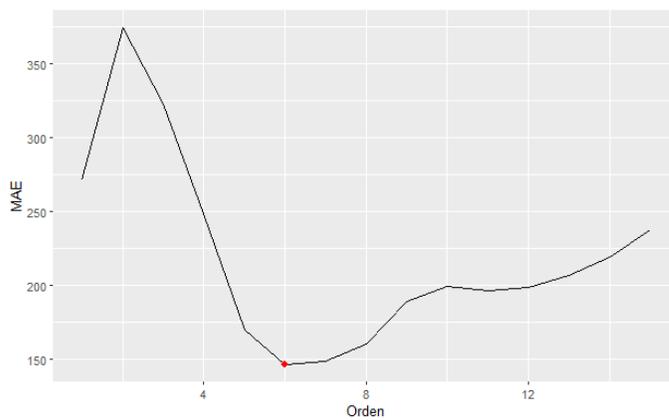


Figura 6-19.: MAE de los pronósticos de sodio cloruro para diferentes valores del orden en el promedio móvil simple

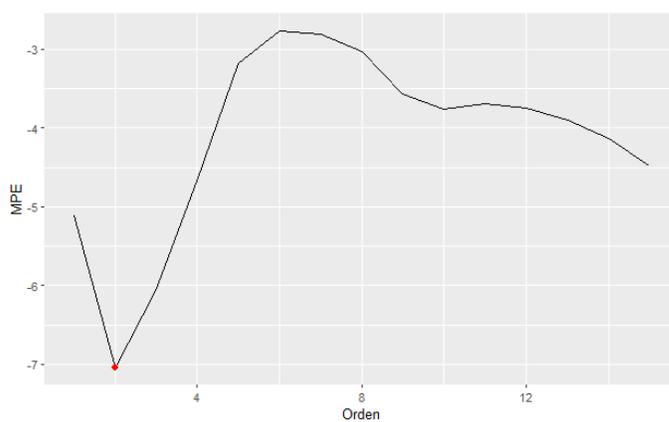


Figura 6-20.: MPE de los pronósticos de sodio cloruro para diferentes valores del orden en el promedio móvil simple

6.3 Definición de modelos para el pronóstico de consumo de sodio cloruro

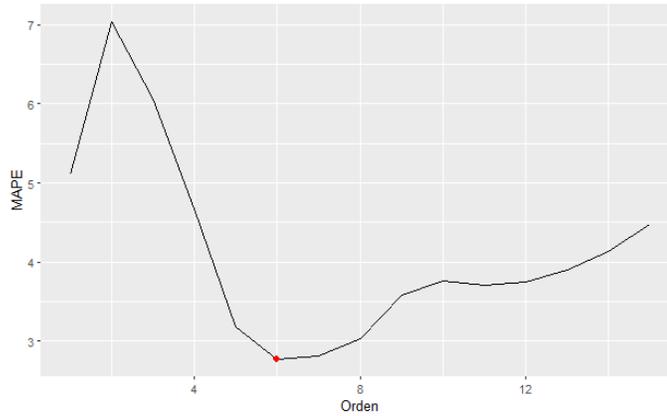


Figura 6-21.: MAPE de los pronósticos de sodio cloruro para diferentes valores del orden en el promedio móvil simple

Luego de evaluar los resultados obtenidos, se selecciona el modelo de promedio móvil simple que tiene ME, MAE y MAPE mínimo, es decir de orden 6. Las medidas de calidad de pronóstico del modelo de promedio móvil simple de orden 6 se observan en la **Tabla 6-3**.

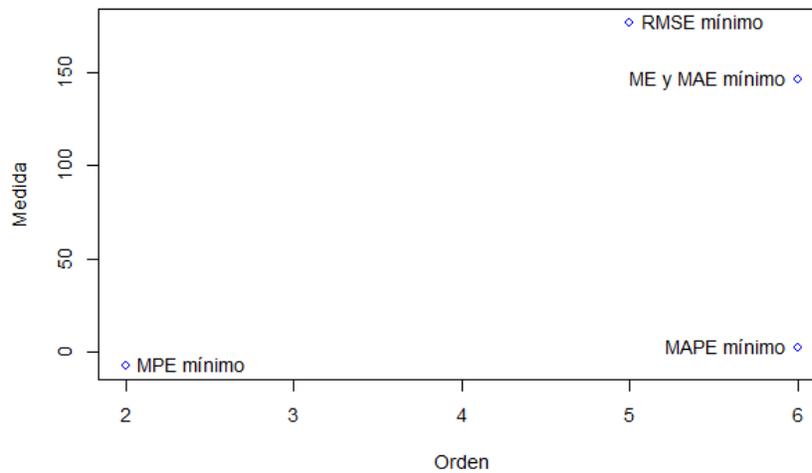


Figura 6-22.: Orden del modelo con medidas de calidad de pronóstico mínimas

ME	RMSE	MAE	MPE	MAPE
146.23	178.19	146.23	-2.76	2.76

Tabla 6-3.: Métricas de precisión del pronóstico del modelo de promedio móvil simple de orden 6

6.3.2. Suavizamiento exponencial único

Se ajustan modelos de suavizamiento exponencial único con valores de α variando desde 0,01 hasta 0,99 con incremento de 0,01, para cada modelo se hace el pronóstico de las últimas cuatro semanas del año 2019, se calculan las métricas de precisión de pronóstico, y se determina el valor α del modelo que presenta el menor valor de las métricas.

El valor de α con ME mínimo es 0,01 (**Figura 6-23**), el valor de α con RMSE mínimo es 0,02 (**Figura 6-24**), el valor de α con MAE mínimo es 0,02 (**Figura 6-25**), el valor de α con MPE mínimo es 0,76 (**Figura 6-26**), el valor de α con MAPE mínimo es 0,02 (**Figura 6-27**). Las únicas medidas mínimas que coinciden en el valor de α son MAE y MAPE, el resto de medidas arrojan valores de α diferentes (**Figura 6-28**).

Luego de evaluar los resultados obtenidos, se selecciona el modelo de suavizamiento exponencial único que tiene RMSE, MAE y MAPE mínimo, es decir el modelo con un valor de α de 0.02.

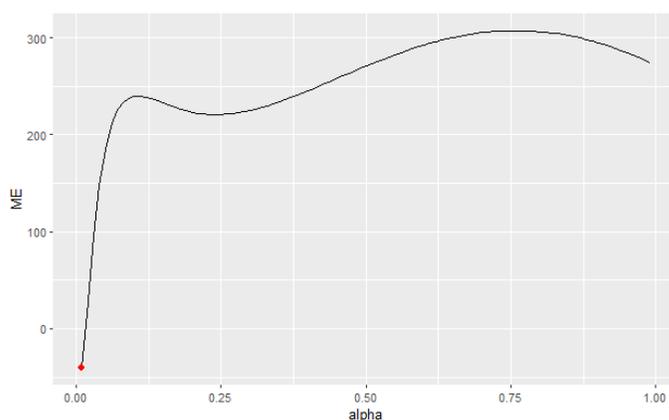


Figura 6-23.: ME de los pronósticos de sodio cloruro para diferentes valores de α en el suavizamiento exponencial único

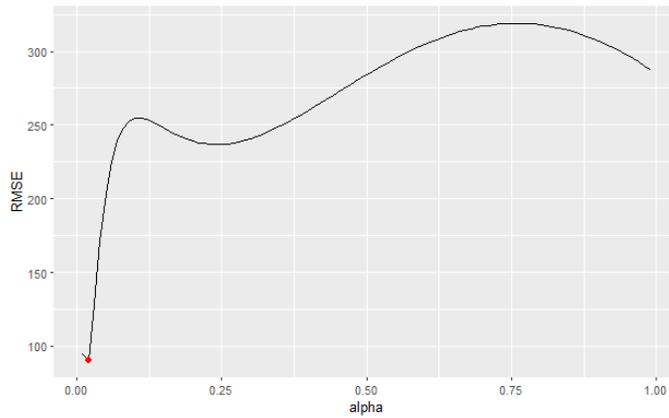


Figura 6-24.: RMSE de los pronósticos de sodio cloruro para diferentes valores de α en el suavizamiento exponencial único

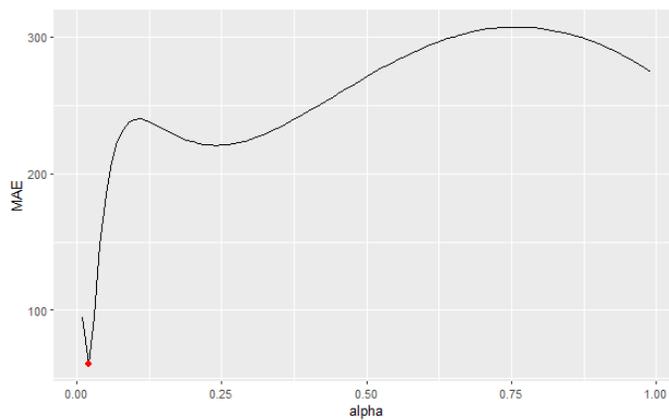


Figura 6-25.: MAE de los pronósticos de sodio cloruro para diferentes valores de α en el suavizamiento exponencial único

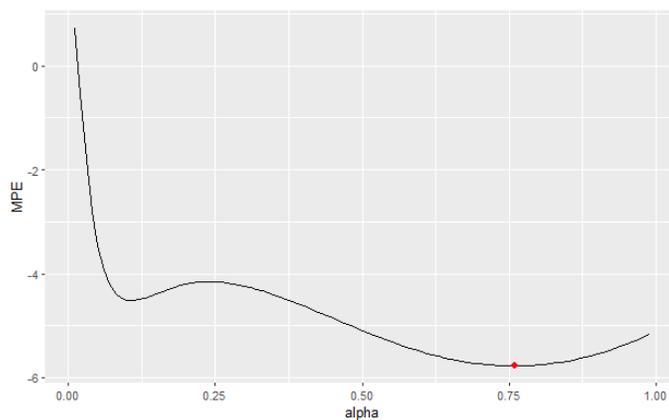


Figura 6-26.: MPE de los pronósticos de sodio cloruro para diferentes valores de α en el suavizamiento exponencial único

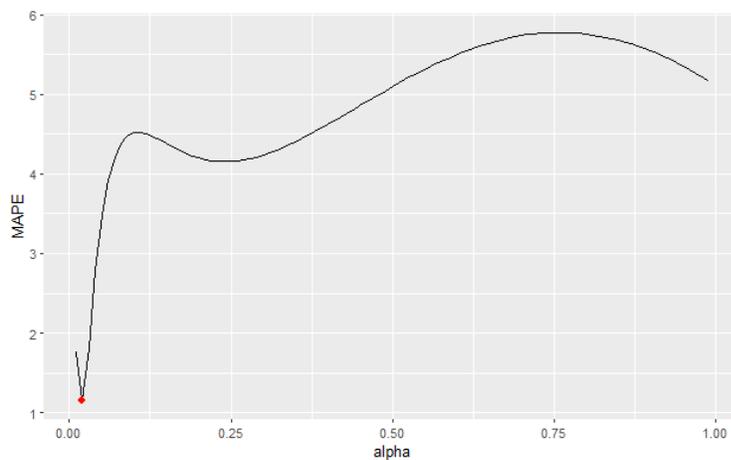


Figura 6-27.: MAPE de los pronósticos de sodio cloruro para diferentes valores de α en el suavizamiento exponencial único

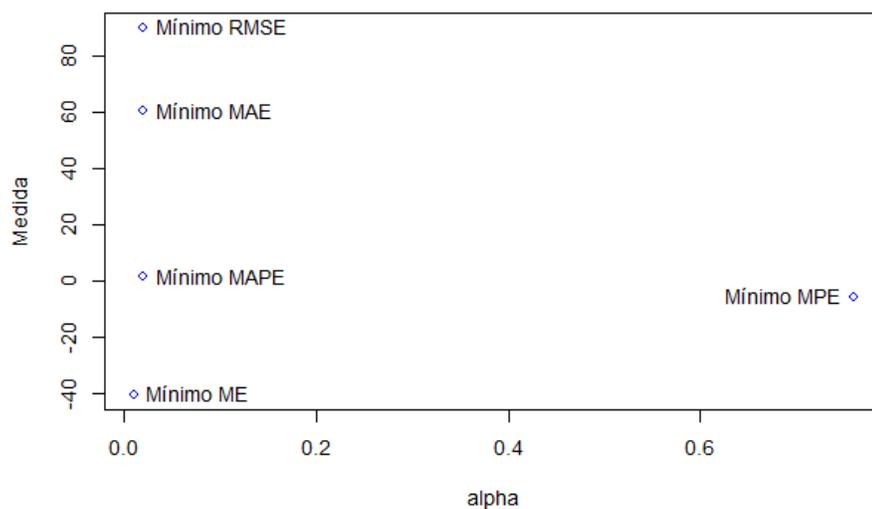


Figura 6-28.: Valores de α con métricas de precisión del pronóstico mínimas

Las medidas de calidad de pronóstico del modelo de suavizamiento exponencial único con un valor α de 0.02 se observan en la **Tabla 6-4**.

ME	RMSE	MAE	MPE	MAPE
27.49	90.16	60.38	-0.54	1.15

Tabla 6-4.: Métricas de precisión del pronóstico del modelo de suavizamiento exponencial único con $\alpha = 0.02$

A continuación en la **Figura 6-29** se observa al lado izquierdo la serie del consumo de sodio cloruro para el conjunto de datos de entrenamiento y el pronóstico realizado con el método de suavizamiento exponencial único y al lado derecho la comparación entre el pronóstico (línea de color azul) y los datos reales del conjunto de datos de prueba (línea de color gris).

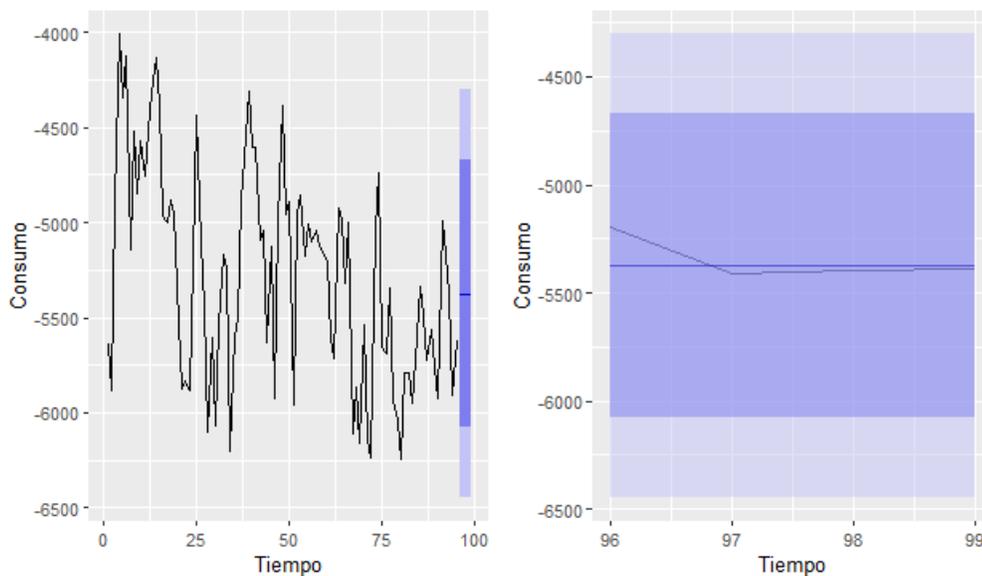


Figura 6-29.: Pronóstico con el método de suavizamiento exponencial Único

6.3.3. Suavizamiento exponencial de Holt

Modelo Holt Original

Se ajusta el modelo de suavizamiento exponencial de Holt, se pronostican las últimas cuatro semanas del año 2019, y se calculan las medidas de calidad de pronóstico. A partir de la función holt del software R se obtienen para los parámetros α y β los valores: 0,4879 y 0,0001 respectivamente; y como valores iniciales para l y b de $-4769,5157$ y $-4,153$ respectivamente.

Las medidas de calidad de pronóstico del modelo de suavizamiento exponencial de Holt Original estimado se presentan en la **Tabla 6-5**.

ME	RMSE	MAE	MPE	MAPE
282.92	294.70	282.92	-5.32	5.32

Tabla 6-5.: Métricas de precisión del pronóstico del modelo de suavizamiento exponencial de Holt Original

En la **Figura 6-30** se presenta la serie del consumo de sodio cloruro para el conjunto de datos de entrenamiento (línea de color negro) y la serie de valores ajustados con el modelo Holt Original (línea de color rojo), observando que el modelo ajusta la serie de datos.

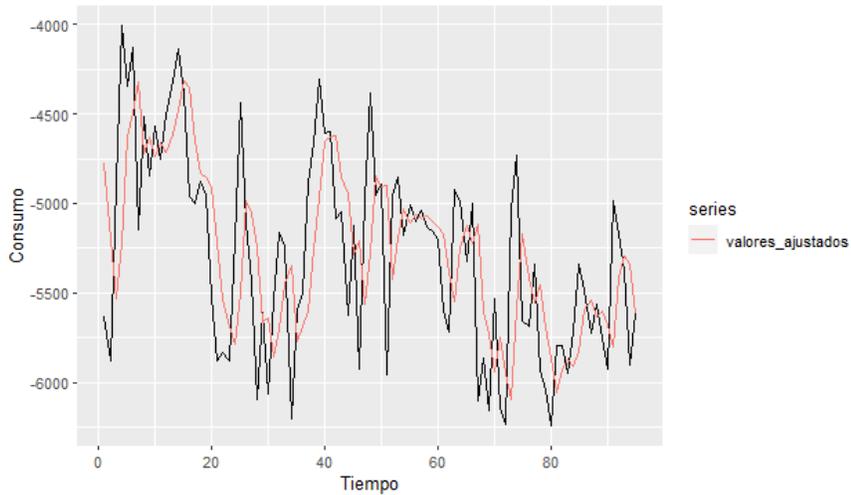


Figura 6-30.: Serie de consumo de sodio cloruro para el conjunto de datos de entrenamiento vs serie de valores ajustados con el modelo Holt Original

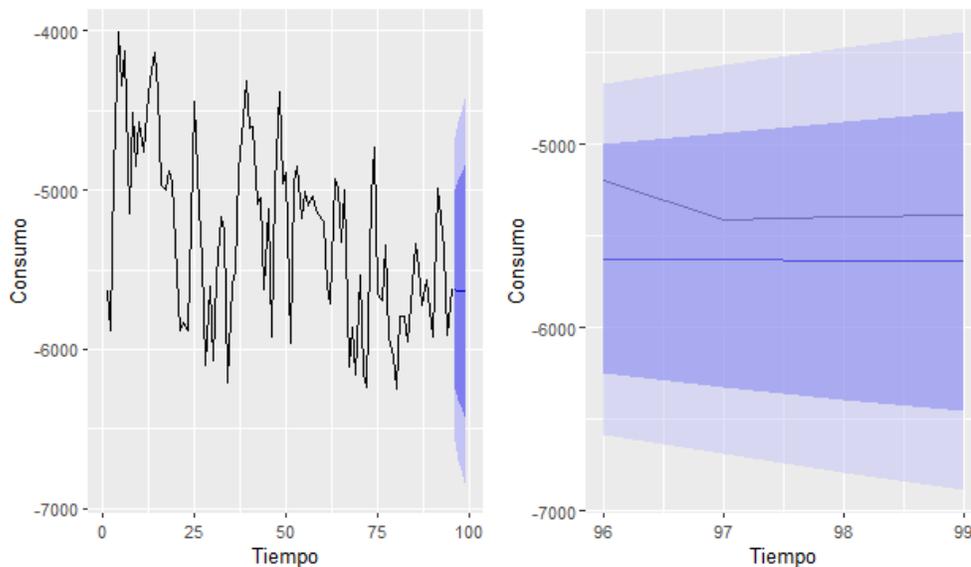


Figura 6-31.: Pronóstico con el método de suavizamiento exponencial de Holt Original

En la **Figura 6-31** se observa al lado izquierdo la serie del consumo de sodio cloruro para el conjunto de datos de entrenamiento y el pronóstico realizado con el método de suavizamiento exponencial

de Holt Original y al lado derecho la comparación entre el pronóstico (línea de color azul) y los datos reales del conjunto de datos de prueba (línea de color gris).

Modelo Holt Optimizado

Se ajustan modelos Holt Original con α variando desde 0,01 hasta 0,99 con incremento de 0,01 y β variando desde 0,0001 hasta 0,005 con incremento de 0,0001. Para cada modelo se hace el pronóstico de las últimas cuatro semanas del año 2019, se calculan las medidas de error de pronóstico y se selecciona el valor de los parámetros α y β del modelo que presenta el menor valor de las medidas de error de pronóstico como se muestra a continuación en la **Tabla 6-6**.

Medida	Valor mínimo	α	β
ME	247.92	0.3	0.005
RMSE	261.13	0.3	0.005
MAE	247.92	0.3	0.005
MPE	-8.89	0.01	0.005
MAPE	4.66	0.3	0.005

Tabla 6-6.: α y β del modelo con medidas de calidad de pronóstico mínimas

Se selecciona el modelo de suavizamiento exponencial de Holt Original que tiene ME, MAE, RMSE y MAPE mínimo, es decir, con un valor de $\alpha = 0,3$ y $\beta = 0,005$, los valores iniciales $l_0 = -5108,3108$ y $b_0 = -3,1469$. Las medidas de calidad de pronóstico de este modelo se observan en la **Tabla 6-7**.

ME	RMSE	MAE	MPE	MAPE
247.92	261.13	247.92	-4.66	4.66

Tabla 6-7.: Métricas de precisión del pronóstico del modelo de suavizamiento exponencial de Holt Optimizado

En la **Figura 6-32** se observa al lado izquierdo la serie del consumo de sodio cloruro para el conjunto de datos de entrenamiento y el pronóstico realizado con el método de suavizamiento exponencial de Holt Optimizado y al lado derecho la comparación entre el pronóstico (línea de color azul) y los datos reales del conjunto de datos de prueba (línea de color gris).

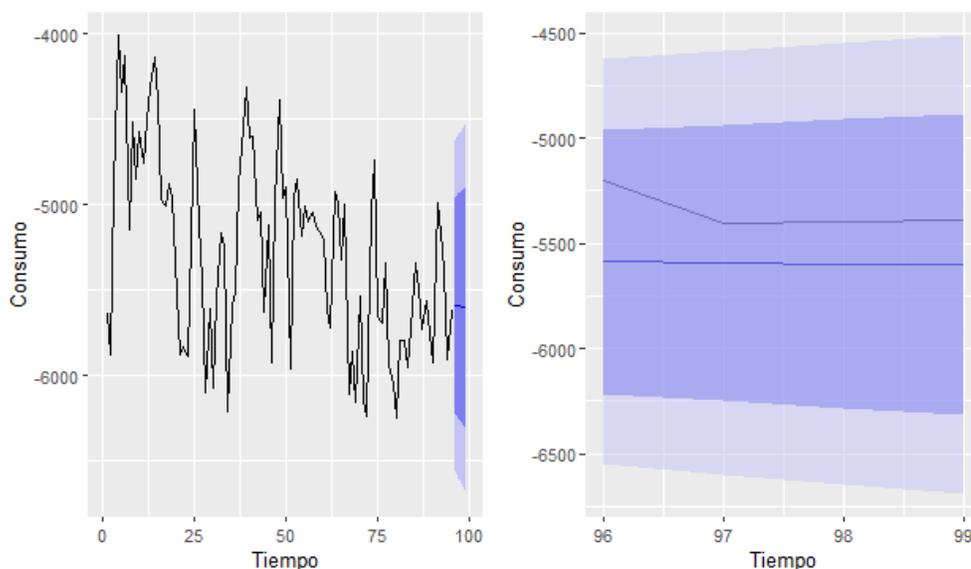


Figura 6-32.: Pronóstico con el método de suavizamiento exponencial de Holt Optimizado

6.3.4. Suavizamiento Exponencial Lineal y Estacional de Winters, versión multiplicativa

Este método se descarta debido a que la serie no presenta componente estacional, de todas maneras, usar series negativas impide usar este método multiplicativo.

6.3.5. Modelo de pronóstico del Hospital

Las medidas de calidad de pronóstico del modelo de pronóstico del Hospital se observan en la **Tabla 6-8**.

ME	RMSE	MAE	MPE	MAPE
506.77	513.99	506.77	-9.51	9.51

Tabla 6-8.: Métricas de precisión del pronóstico del modelo del Hospital

A continuación se presenta un análisis similar para el otro medicamento seleccionado, dipirona. En el siguiente capítulo se presenta un análisis de los resultados obtenidos para cada uno de los dos medicamentos al compararlos con el pronóstico que usa el hospital.

6.4. Definición de modelos para el pronóstico de consumo de dipirona

6.4.1. Promedio móvil simple

Se ajustaron 10 modelos de promedio móvil simple con orden desde 1 hasta 10, para cada modelo se hace el pronóstico de las últimas cuatro semanas del año 2019, se calculan las medidas de error de pronóstico y se determina el orden del modelo que presenta el menor valor de las métricas de precisión del pronóstico como se muestra a continuación:

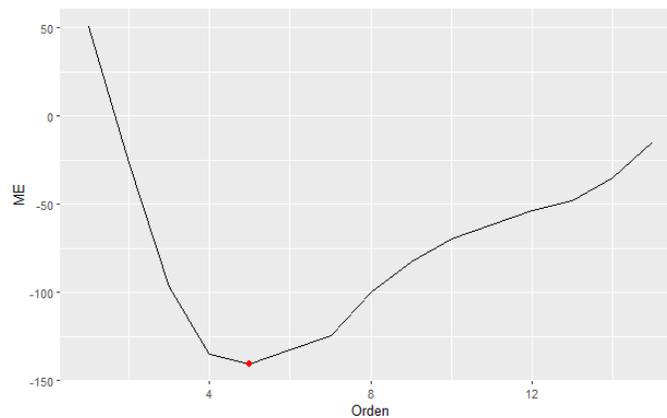


Figura 6-33.: ME de los pronósticos de la dipirona para diferentes valores del orden en el promedio móvil simple

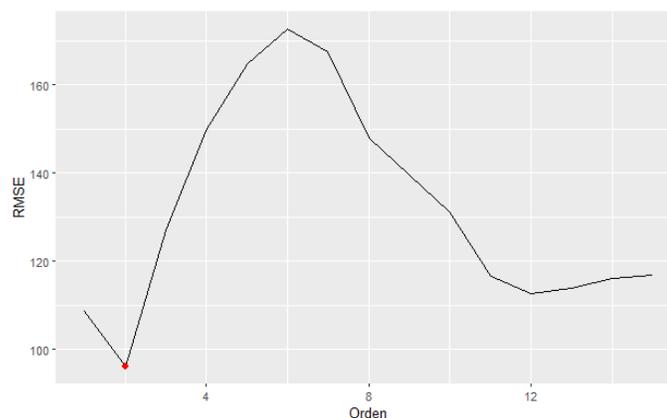


Figura 6-34.: RMSE de los pronósticos de la dipirona para diferentes valores del orden en el promedio móvil simple

El orden del modelo con ME mínimo es 5 (**Figura 6-33**), el orden del modelo con RMSE mínimo es 2 (**Figura 6-34**), el orden del modelo con MAE mínimo es 2 (**Figura 6-35**), el orden del modelo con MPE mínimo es 1 (**Figura 6-36**), el orden del modelo con MAPE mínimo es 2 (**Figura 6-37**).

Las medidas mínimas que coinciden en el orden del modelo son ME, RMSE, MAE y MAPE, la única medida que arroja un orden diferente es el MPE (**Figura 6-38**).

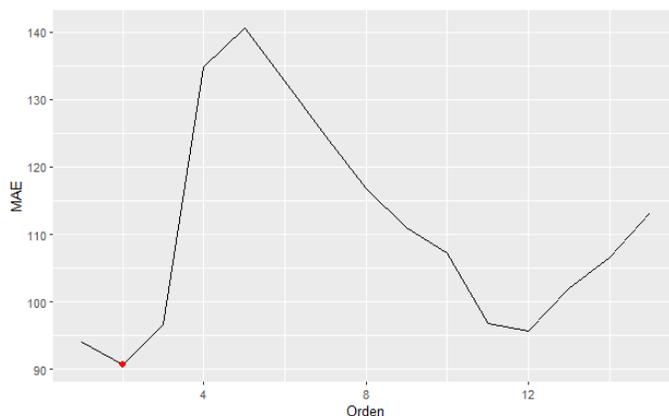


Figura 6-35.: MAE de los pronósticos de la dipirona para diferentes valores del orden en el promedio móvil simple

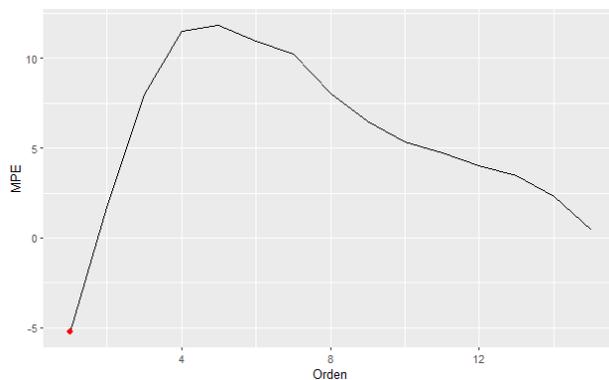


Figura 6-36.: MPE de los pronósticos de la dipirona para diferentes valores del orden en el promedio móvil simple

Luego de evaluar los resultados obtenidos, se selecciona el modelo de promedio móvil simple que tiene RMSE, MAE y MAPE mínimo, es decir de orden 2. Las métricas de precisión del pronóstico del modelo de promedio móvil simple de orden 2 se observan en la **Tabla 6-9**.

ME	RMSE	MAE	MPE	MAPE
-26.62	96.00	90.62	1.69	7.83

Tabla 6-9.: Métricas de precisión del pronóstico del modelo de promedio móvil simple de orden 2

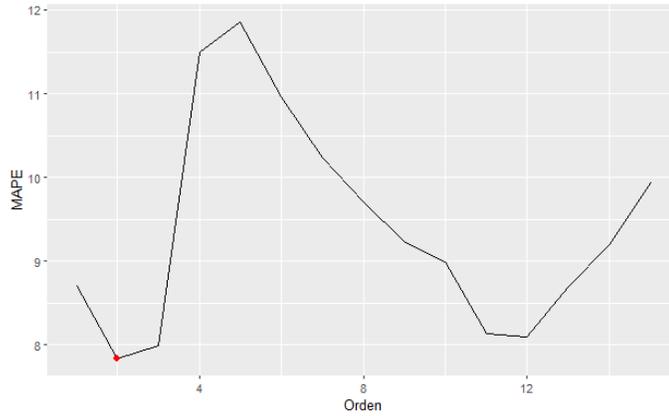


Figura 6-37.: MAPE de los pronósticos de la dipirona para diferentes valores del orden en el promedio móvil simple

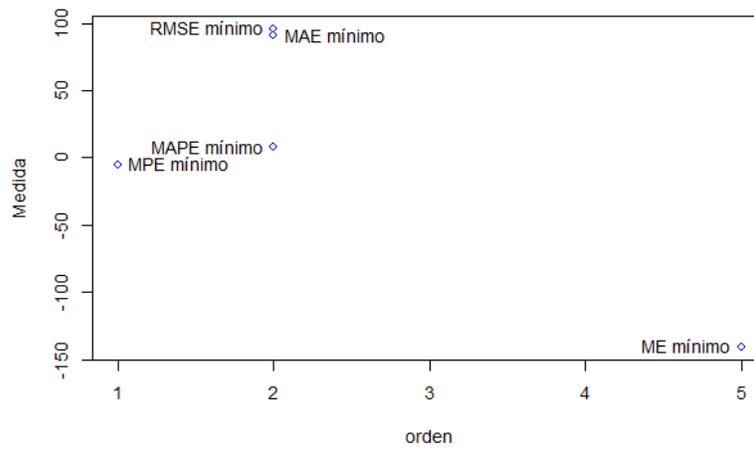


Figura 6-38.: Orden del modelo con métricas de precisión del pronóstico mínimas

6.4.2. Suavizamiento exponencial único

Se ajustan modelos de suavizamiento exponencial único con α desde 0,01 hasta 0,99 con incremento de 0,01. Para cada modelo se hace el pronóstico de las últimas cuatro semanas del año 2019, se calculan las métricas de precisión del pronóstico, y se determina el valor α del modelo que presenta el menor valor de las medidas de error de pronóstico como se muestra a continuación:

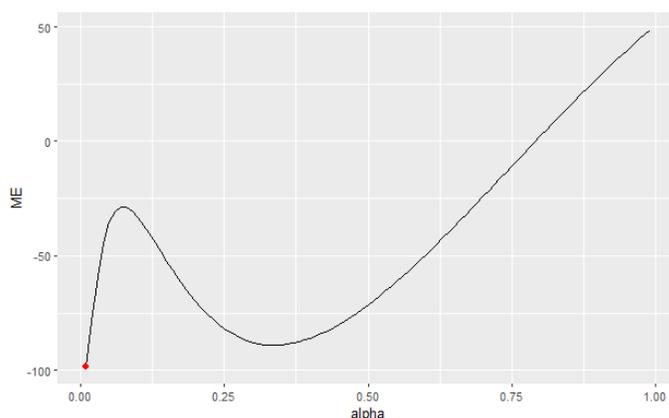


Figura 6-39.: ME de los pronósticos de la dipirona para diferentes valores del orden en el suavizamiento exponencial único

El valor de α con ME mínimo es 0,01 (**Figura 6-39**), el valor de α con RMSE mínimo es 0,79 (**Figura 6-40**), el valor de α con MAE mínimo no es un único valor si no un rango de valores que va desde 0.02 hasta 0.25 y desde 0.43 hasta 0.66, (**Figura 6-41**), el valor de α con MPE mínimo es 0,99 (**Figura 6-42**), el valor de α con MAPE mínimo es 0,43 (**Figura 6-43**).

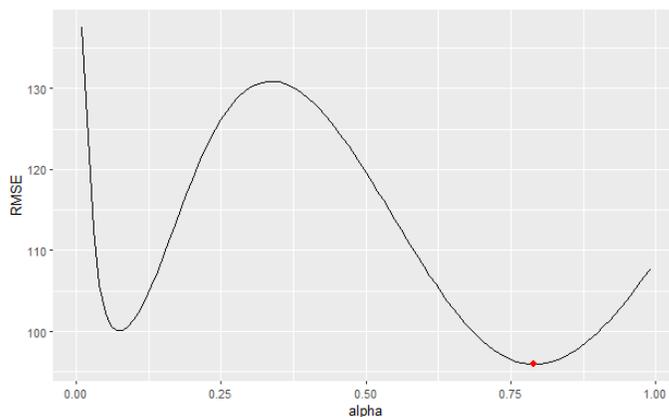


Figura 6-40.: RMSE de los pronósticos de la dipirona para diferentes valores del orden en el suavizamiento exponencial único

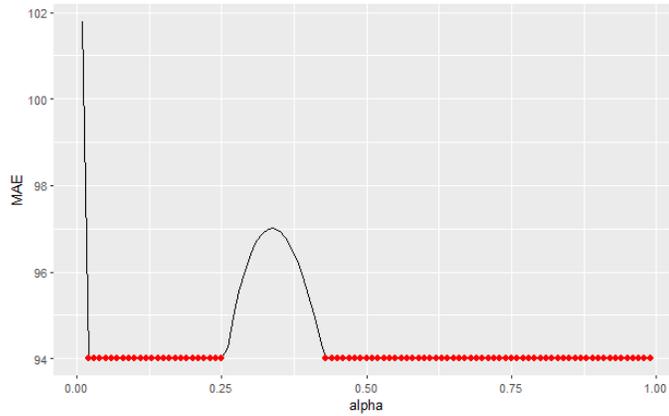


Figura 6-41.: MAE de los pronósticos de la dipirona para diferentes valores del orden en el suavizamiento exponencial único

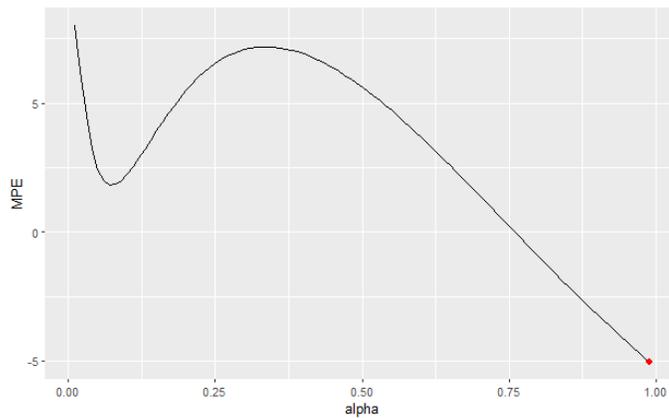


Figura 6-42.: MPE de los pronósticos de la dipirona para diferentes valores del orden en el suavizamiento exponencial único

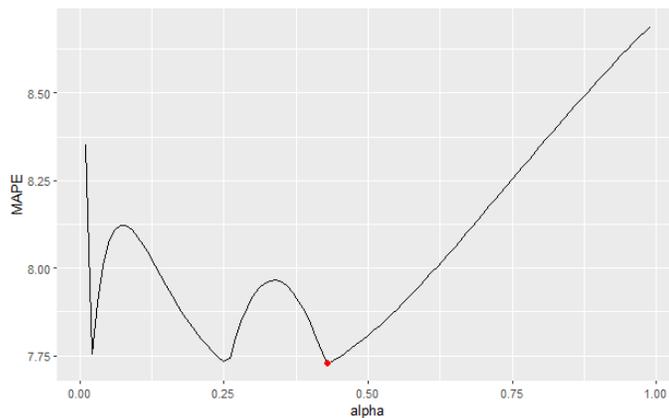


Figura 6-43.: MAPE de los pronósticos de la dipirona para diferentes valores del orden en el suavizamiento exponencial único

Luego de evaluar los resultados obtenidos, se selecciona el modelo de suavizamiento exponencial único que tiene MAE y MAPE mínimo, es decir con un valor de α de 0.43. Las medidas de calidad de pronóstico del modelo de suavizamiento exponencial único con un valor de α de 0.43 se observan en la **Tabla 6-10**.

ME	RMSE	MAE	MPE	MAPE
-82.63	126.63	94.00	6.62	7.73

Tabla 6-10.: Métricas de precisión del pronóstico del modelo de suavizamiento exponencial único con $\alpha = 0.43$

A continuación en la **Figura 6-44** se observa al lado izquierdo la serie del consumo de sodio cloruro para el conjunto de datos de entrenamiento y el pronóstico realizado con el método de suavizamiento exponencial único y al lado derecho la comparación entre el pronóstico (línea de color azul) y los datos reales del conjunto de datos de prueba (línea de color gris).

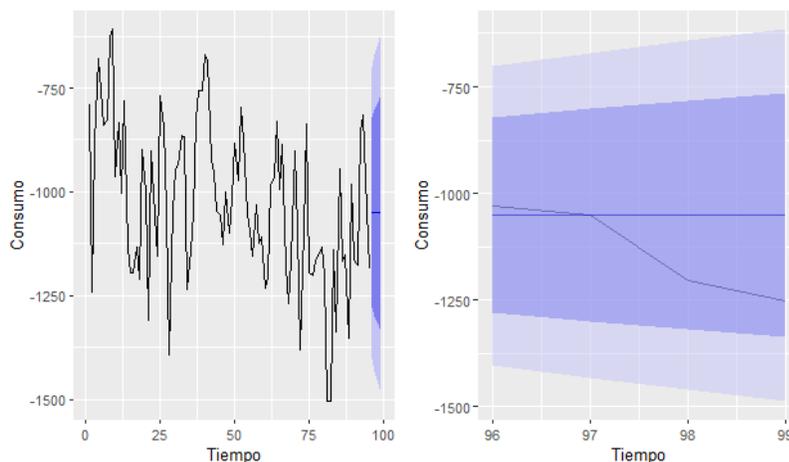


Figura 6-44.: Pronóstico con el método de suavizamiento exponencial Único

6.4.3. Suavizamiento exponencial de Holt

Modelo Holt Original

Se ajusta el modelo de suavizamiento exponencial de Holt, se pronostican las últimas cuatro semanas del año 2019 y se calculan las medidas de calidad de pronóstico. A partir de la función holt del software R se obtienen para los parámetros α y β los valores: 0,2669 y 0,0001 respectivamente; y como valores iniciales para l y b de $-850,09$ y $-2,0503$ respectivamente.

Las medidas de calidad de pronóstico del modelo de suavizamiento exponencial de Holt Original estimado se observan en la Tabla 6-11.

ME	RMSE	MAE	MPE	MAPE
-73.69	119.25	91.95	5.84	7.61

Tabla 6-11.: Métricas de precisión del pronóstico del modelo de suavizamiento exponencial de Holt Original

En la **Figura 6-45** se presenta la serie del consumo de dipirona para el conjunto de datos de entrenamiento (línea de color negro) y la serie de valores ajustados con el modelo Holt (línea de color rojo), observando que el modelo ajusta la serie de datos.

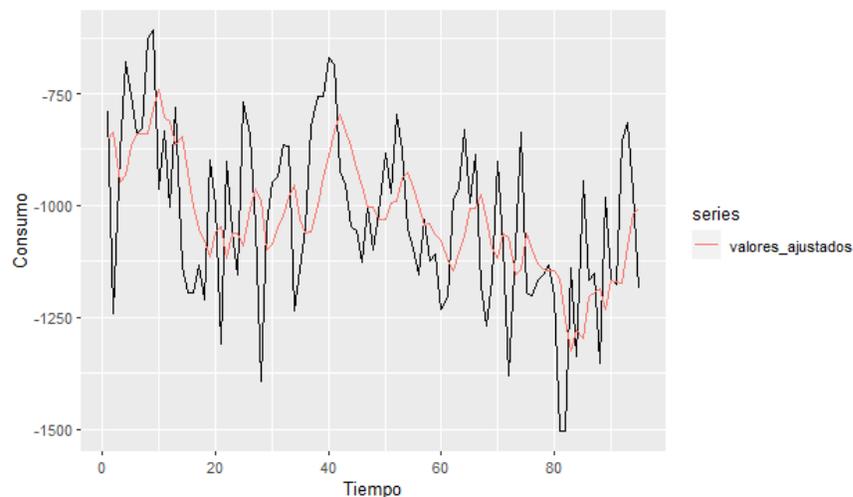


Figura 6-45.: Serie de consumo de dipirona para el conjunto de datos de entrenamiento vs serie de valores ajustados con el modelo Holt

En la **Figura 6-46** se observa al lado izquierdo la serie del consumo de sodio cloruro para el conjunto de datos de entrenamiento y el pronóstico realizado con el método de suavizamiento exponencial de Holt Original y al lado derecho la comparación entre el pronóstico (línea de color azul) y los datos reales del conjunto de datos de prueba (línea de color gris).

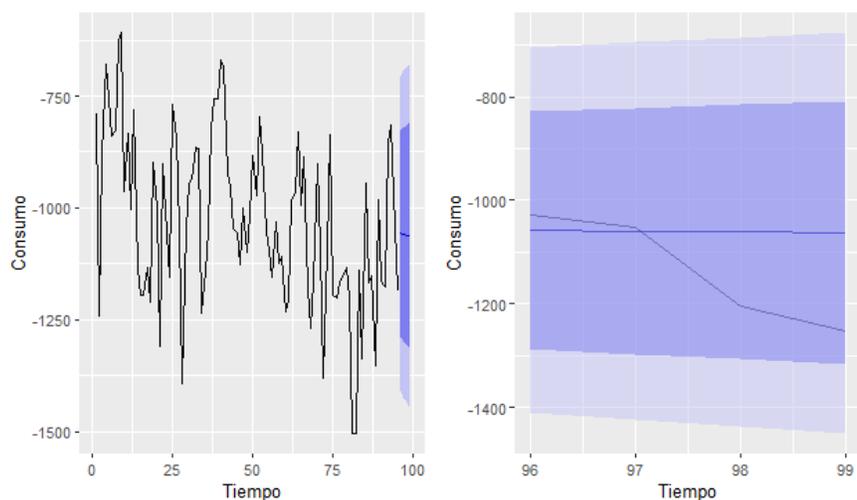


Figura 6-46.: Pronóstico con el método de suavizamiento exponencial de Holt Original

Modelo Holt Optimizado

Se ajustan modelos Holt Original con α variando desde 0,01 hasta 0,99 con incremento de 0,01 y β variando desde 0,0001 hasta 0,005 con incremento de 0,0001. Para cada modelo se hace el pronóstico de las últimas cuatro semanas del año 2019, se calculan las métricas de precisión del pronóstico, y se selecciona el valor de los parámetros α y β del modelo que presenta el menor valor de las métricas, como se muestra a continuación en la **Tabla 6-12**.

Medida	Valor mínimo	α	β
ME	-84.72	0.35	0.005
RMSE	93.06	0.77	0.0002
MAE	89.62	0.01	0.0033
MPE	-10.19	0.01	0.005
MAPE	7.59	0.34	0.0001

Tabla 6-12.: α y β del modelo con medidas de calidad de pronóstico mínimas

Se selecciona el modelo de suavizamiento exponencial de Holt Original que tiene MAPE mínimo, es decir con un valor de $\alpha = 0,34$, $\beta = 0,0001$, y los valores iniciales $l_0 = -889,1975$ y $b_0 = -1,679$. Las medidas de calidad de pronóstico de este modelo se observan en la **Tabla 6-13**.

ME	RMSE	MAE	MPE	MAPE
-81.56	124.58	92.32	6.54	7.59

Tabla 6-13.: Métricas de precisión del pronóstico del modelo de suavizamiento exponencial de Holt Optimizado

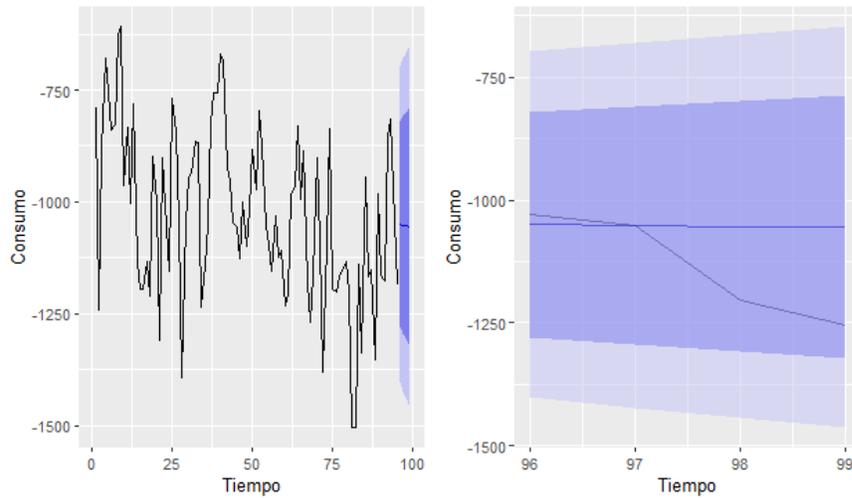


Figura 6-47.: Pronóstico con el método de suavizamiento exponencial de Holt Optimizado

En la **Figura 6-47** se observa al lado izquierdo la serie del consumo de dipirona para el conjunto de datos de entrenamiento y el pronóstico realizado con el método de suavizamiento exponencial de Holt Optimizado y al lado derecho la comparación entre el pronóstico (línea de color azul) y los datos reales del conjunto de datos de prueba (línea de color gris).

6.4.4. Suavizamiento Exponencial Lineal y Estacional de Winters, versión multiplicativa

Este método se descarta debido a que la serie no presenta componente estacional, de todas maneras, usar series negativas impide usar este método multiplicativo.

6.4.5. Método de pronóstico del Hospital

Las medidas de calidad de pronóstico del modelo de pronóstico del Hospital se observan en la **Tabla 6-14**.

ME	RMSE	MAE	MPE	MAPE
20.032	98.03	94.00	-2.50	8.48

Tabla 6-14.: Métricas de precisión del pronóstico del modelo del Hospital

7. Análisis de Resultados

En este capítulo se presenta una consolidación de los resultados obtenidos para cada medicamento de las métricas de precisión del pronóstico de la demanda para cada uno de los modelos evaluados, se selecciona el modelo que mejor pronostica y se compara con el modelo de pronóstico del Hospital, de tal manera que se pueda cuantificar en términos de unidades de medicamento, cual es el ahorro por hacer la estimación con el mejor de los modelos.

7.1. Métricas de precisión del pronóstico de la demanda de sodio cloruro para los modelos evaluados

A continuación en la Tabla 7-1 se presentan las métricas de precisión del pronóstico de la demanda de sodio cloruro para los modelos evaluados incluido el modelo que aplica actualmente el Hospital con un rango de pronóstico de cuatro semanas.

Modelo	ME	RMSE	MAE	MPE	MAPE
Promedio móvil simple	146.23	178.19	146.23	-2.76	2.76
Suavizamiento exponencial único	27.49	90.16	60.38	-0.54	1.15
Suavizamiento exponencial de Holt Original	282.92	294.70	282.92	-5.32	5.32
Suavizamiento exponencial de Holt Optimizado	247.92	261.13	247.92	-4.66	4.66
Hospital	506.77	513.99	506.77	-9.51	9.51

Tabla 7-1.: Comparativo de métricas de precisión del pronóstico de los modelos evaluados

El modelo que presenta mejores métricas de precisión del pronóstico de demanda de sodio cloruro es el suavizamiento exponencial único con $\alpha = 0,43$.

7.1.1. Comparación del modelo seleccionado vs modelo de pronóstico del Hospital

Modelo	Semana 101	Semana 102	Semana 103	Semana 104
Hospital	-5854.0	-5854.0	-5854.0	-5854.0
Suavizamiento exponencial Único	-5374.7	-5374.7	-5374.7	-5374.7
Diferencia	-479.3	-479.3	-479.3	-479.3

Tabla 7-2.: Comparativo de cantidad de bolsas de sodio cloruro pronosticadas por el modelo del hospital y el modelo de suavizamiento exponencial único

Con el pronóstico de suavizamiento exponencial único se tendría un ahorro mensual de 1917 bolsas de sodio cloruro para cubrir la demanda de este medicamento en el hospital, este valor se obtiene al sumar las diferencias entre las cantidades pronosticadas con el modelo del Hospital y las cantidades pronosticadas con el modelo de suavizamiento exponencial único para las últimas cuatro semanas del año 2019 (**Tabla 7-2**).

Como ejercicio adicional se realizó el pronóstico de suavizamiento exponencial único para ocho semanas correspondientes a los meses de noviembre y diciembre de 2019, se tendría un ahorro mensual de 1845 bolsas de sodio cloruro para cubrir la demanda de este medicamento en el hospital.

7.2. Métricas de precisión del pronóstico de la demanda de dipirona para los modelos evaluados

Modelo	ME	RMSE	MAE	MPE	MAPE
Promedio móvil simple	-26.62	96.00	90.62	1.69	7.83
Suavizamiento exponencial único	-82.63	126.63	94.00	6.62	7.73
Suavizamiento exponencial de Holt Original	-73.69	119.25	91.95	5.84	7.61
Suavizamiento exponencial de Holt Optimizado	-81.56	124.58	92.32	6.54	7.59
Hospital	20.032	98.03	94.00	-2.50	8.48

Tabla 7-3.: Comparativo de métricas de precisión del pronóstico de los modelos evaluados

El modelo que presenta mejores métricas de precisión del pronóstico de demanda de dipirona es el promedio móvil simple de orden 2.

7.2.1. Comparación del modelo seleccionado vs modelo de pronóstico del Hospital

Modelo	Semana 101	Semana 102	Semana 103	Semana 104
Hospital	-1154.0	-1154.0	-1154.0	-1154.0
Promedio móvil simple	-1077.0	-1131.0	-1104.0	-1117.5
Diferencia	-77	-23	-50	-36.5

Tabla 7-4.: Comparativo de cantidad de ampollas de dipirona pronosticadas por el modelo del hospital y el modelo de promedio móvil simple

Con el pronóstico de media móvil simple se tendría un ahorro mensual de 186,5 ampollas de dipirona para cubrir la demanda de este medicamento, este valor se obtiene al sumar las diferencias entre las cantidades pronosticadas con el modelo del Hospital y las cantidades pronosticadas con el modelo de media móvil simple para las últimas cuatro semanas del año 2019 (**Tabla 7-4**).

8. Conclusiones y recomendaciones

8.1. Conclusiones

- Entre los modelos estadísticos propuestos en la literatura para la estimación de la demanda de medicamentos en los Hospitales y en el sector farmacéutico en general, se seleccionaron los métodos de suavizamiento debido a su aplicación en el pronóstico de la demanda de grandes volúmenes de medicamentos, proporcionando pronósticos buenos en el corto plazo. El análisis se realizó para los dos medicamentos de mayor consumo en el hospital que son el sodio cloruro y la dipirona, sin embargo, la metodología puede ser aplicada a todos los medicamentos del hospital.
- El análisis descriptivo realizado de la base de datos de consumo tanto para el sodio cloruro como para la dipirona, permitió identificar datos atípicos en la serie de consumo semanal sin discriminar por día de la semana y en la serie de consumo discriminado por día de la semana, que de otra forma no se habrían podido identificar.
- En la serie de consumo semanal sin discriminar por día de la semana para ambos medicamentos, se observan datos atípicos en la semana 5, 86 y 87 debido a que en la semana cinco sólo se tiene información de consumo de cuatro días y adicionalmente los días 20 y 21 de agosto de 2019, que hacen parte de la semana 86, no hay información de despachos y devoluciones para ningún medicamento del hospital, por lo cual se concluye que durante el 20 y 21 de agosto ocurrieron fallas en el sistema y por lo tanto no se registró información de despachos y devoluciones si no posteriormente en la semana 87.
- En la serie de consumo semanal discriminado por día semana, la cual incluye sólo semanas que tienen información de consumo para todos los días, se observa un incremento considerable en el consumo de sodio cloruro el día sábado de la semana 45 por un proceso de depuración de la bodega virtual, y el día lunes de la semana 97 ocurrió una disminución considerable del consumo de dipirona debido a la devolución de ampollas que estaban en las salas y era necesario tenerlas en inventario para el cierre contable del año. Una vez identificada la causa del punto atípico se procedió a hacer los ajustes correspondientes en la serie de datos.
- Tanto para el caso del sodio cloruro como el de la dipirona se ajustaron modelos de promedio móvil simple, suavizamiento exponencial único, suavizamiento exponencial de Holt Original, suavizamiento exponencial de Holt optimizado y el modelo que aplica actualmente el Hospital. Para cada tipo se ajustaron varios modelos, variando sus parámetros de tal forma que se pudiera seleccionar aquel modelo que presentara el menor valor de las medidas de error de pronóstico, lo cual permite seleccionar los mejores modelos de pronóstico. En el caso del

sodio cloruro todos los modelos de suavizamiento evaluados presentan mejores valores en las métricas de precisión del pronóstico de la demanda que el método que aplica actualmente el Hospital, sin embargo, el mejor modelo es el de suavizamiento exponencial único con $\alpha = 0,43$, y para el caso de la dipirona el mejor modelo es el promedio móvil simple de orden dos. Esto permite concluir que los métodos de suavizamiento proporcionan mejores pronósticos para el consumo de sodio cloruro y dipirona que el método que aplica actualmente el Hospital.

- Con el pronóstico de suavizamiento exponencial único con $\alpha = 0,43$ para las últimas cuatro semanas del año 2019, se tendría un ahorro mensual de 1917 bolsas de sodio cloruro comparado con el método de pronóstico que aplica actualmente el Hospital para cubrir la demanda de este medicamento, mientras que con el pronóstico de media móvil simple de orden dos se tendría un ahorro mensual de 186,5 ampollas.

8.2. Recomendaciones

- Al generar la base de datos se recomienda revisar si existe información de despachos y devoluciones para todos los días de las semanas, ya que si se identifica que alguna semana tiene algún(os) día(s) sin información se debe revisar la causa y hacer el ajuste correspondiente en los datos.
- En el campo TxT.cab.doc en el módulo MM de SAP se puede identificar si hubo un proceso de depuración de la bodega virtual, ya que aparece “depuración bodega virtual”, se puede adicionar a la base de datos generada un campo con esta información para la identificación de puntos atípicos por esta causa.
- La metodología aplicada en este trabajo para la estimación de demanda semanal de sodio cloruro y dipirona puede hacerse extensivo al resto de medicamentos del Hospital, con el objetivo de identificar el mejor modelo de pronóstico que se podría aplicar.
- Los métodos Holt-Winters de suavizamiento fueron reconvertidos en modelos de espacio-estado, con errores aleatorios (Hyndman, Koehler, Ord, Snyder *et al.*, 2001), (R. J. Hyndman, Koehler, Snyder, y Grose, 2002), (R. Hyndman, Koehler, Ord, y Snyder, 2008), esto permitió aplicar estimación de Máxima Verosimilitud en el modelo Holt. Se podrían explorar también los potentes procedimientos de estimación Bayesiana (Brodersen, Gallusser, Koehler, Remy, y Scott, 2015), por ejemplo, la estimación Bayesiana del modelo Holt que se encuentra en la librería *bsts* de R, la cual permite graficar las distribuciones posteriores de los parámetros, lo cual mejoraría la interpretación de los parámetros del modelo.

A. Macro para organizar la base de datos que se extrae de SAP

```
Sub Macro()  
Columns("A:A").Select Selection.Insert Shift:=xlToRight, CopyOrigin:=xlFormatFromLeftOrAbove  
For i = 5 To fila último registro  
If Cells(i, 7) <> Then  
uno = Val(Cells(i, 3))  
dos = Cells(i, 7)  
Else  
If Cells(i, 4) <> Then  
Cells(i, 1) = uno  
Cells(i, 2) = dos  
Else  
Rows(i).Select  
Selection.Delete Shift:=xlUp  
End If  
End If  
Next i  
For i = 6 To fila último registro  
If Cells(i, 1) = Then Rows(i + 1).Delete Rows(i).Delete  
End If  
Next i End Sub
```

Referencias

- Brodersen, K. H., Gallusser, F., Koehler, J., Remy, N., y Scott, S. L. (2015). Inferring causal impact using bayesian structural time-series models. *The Annals of Applied Statistics*, 247–274.
- Correa Moreno, E. (2004). *Series de tiempo: conceptos básicos*. Universidad Nacional de Colombia.
- Fernández García, M. I. (2021). Optimización de la gestión del stock en farmacia hospitalaria.
- Hyndman, R., Koehler, A. B., Ord, J. K., y Snyder, R. D. (2008). *Forecasting with exponential smoothing: the state space approach*. Springer Science & Business Media.
- Hyndman, R. J., y Athanasopoulos, G. (2018). *Forecasting: principles and practice*. OTexts.
- Hyndman, R. J., Koehler, A. B., Snyder, R. D., y Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of forecasting*, 18(3), 439–454.
- Lakshmi Anusha, S., Alok, S., y Shaik, A. (2014). Demand forecasting for the indian pharmaceutical retail: A case study. *Journal of Supply Chain Management Systems*, 3(2), 1–8.
- Makridakis, S. G., y Wheelwright, S. C. (2007). *Métodos de pronósticos*. Limusa.
- Merkuryeva, G., Valberga, A., y Smirnov, A. (2019). Demand forecasting in pharmaceutical supply chains: A case study. *Procedia Computer Science*, 149, 3–10.
- Pratyaksa, H., Permanasari, A. E., Fauziati, S., y Fitriana, I. (2016). Arima implementation to predict the amount of antiseptic medicine usage in veterinary hospital. En *2016 1st international conference on biomedical engineering (ibiomed)* (pp. 1–4).
- R Core Team. (2022). R: A language and environment for statistical computing [Manual de software informático]. Vienna, Austria. Descargado de <https://www.R-project.org/>
- Riahi, N., Hosseini-Motlagh, S.-M., y Teimourpour, B. (2013). A three-phase hybrid times series modeling framework for improved hospital inventory demand forecast. *International Journal of Hospital Research*, 2(3), 133–142.
- Siddiqui, R., Azmat, M., Ahmed, S., y Kummer, S. (2021). A hybrid demand forecasting model for greater forecasting accuracy: the case of the pharmaceutical industry. En *Supply chain forum: An international journal* (pp. 1–11).
- Valencia-Cárdenas, M., Díaz-Serna, F. J., y Correa-Morales, J. C. (2015). Planeación de inventarios con demanda dinámica: Una revisión del estado del arte. *Dyna*, 82(190),

183–191.