

# Proyecto Fin de Carrera

## Ingeniería de las Teconolgías Industriales

### Estudio de los Efectos de una Interrupción de Capacidad en la Dinámica de una Cadena de Suministro

Autor: Laura Tobajas Machín

Tutores: Roberto Domínguez Cañizares

Salvatore Cannella

**Dpto. Departamento de Organización Industrial  
y Gestión de Empresas I**

**Escuela Técnica Superior de Ingeniería**

Sevilla, 2020





Proyecto Fin de Carrera  
Ingeniería de las Tecnologías Industriales

# **Estudio de los Efectos de una Interrupción de Capacidad en la Dinámica de una Cadena de Suministro**

Autor:

Laura Tobajas Machín

Tutores:

Roberto Domínguez Cañizares

Salvatore Cannella

Profesor titular

Dpto. de Organización Industrial y Gestión de Empresas I

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2020



Proyecto Fin de Carrera: Estudio de los Efectos de una Interrupción de Capacidad en la Dinámica de una Cadena de Suministro

Autor: Laura Tobajas Machín

Tutores: Roberto Domínguez Cañizares,  
Salvatore Cannella

El tribunal nombrado para juzgar el Proyecto arriba indicado, compuesto por los siguientes miembros:

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2020

El Secretario del Tribunal

*A mi familia*

*A la escuela, en especial al  
departamento de Organización I.*



# Agradecimientos

---

Me gustaría mostrar todo mi agradecimiento al Departamento de Organización Industrial y Gestión de Empresas I por incorporarme ofreciéndome la posibilidad de desarrollar mi trabajo de fin de carrera con ellos e incorporarme a su equipo de investigación. Gracias en especial a mis tutores Roberto Domínguez Cañizares y Salvatore Cannella por guiarme en este terreno nuevo para mí.

Gracias también a todos los profesores de la Escuela Técnica Superior de Ingeniería de Sevilla, sin los cuales no habría podido llegar a este momento.

Por último, quiero agradecer a mi familia y a mis amigos por acompañarme y apoyarme en estos cuatro años de carrera.

*Laura Tobajas Machín*  
*Alumna de la Escuela Técnica Superior de Ingeniería*  
*Sevilla, 2020*



# Resumen

---

Estamos en un período de globalización en el que se entablan relaciones comerciales desde distintos puntos del mundo. Esto provoca que las cadenas de suministro sean cada vez más grandes y complejas y resulte crucial la figura del gestor de la cadena para tomar decisiones importantes.

Estas decisiones se vuelven muy complejas cuando la cadena está siendo afectada por fenómenos como el “Efecto cascada” y/o el “Efecto látigo”, también conocidos como “*Ripple effect*” y “*Bullwhip effect*”, que perjudican notablemente su rendimiento. En este trabajo dedicamos una sección a ofrecer una visión general del funcionamiento de las cadenas de suministro, y posteriormente una definición para ambos fenómenos, ya que, como veremos más adelante, están relacionados.

Este trabajo se centra en el “Efecto Cascada”, el cual es un fenómeno relativamente nuevo en la literatura. Sin embargo, existen ya bastantes estudios cuyo análisis resulta interesante. Dedicaremos una sección a conocer en líneas generales la literatura existente relativa a este fenómeno. Además, podremos ver específicamente cómo es posible ayudar al gestor de la cadena, es decir, el interés productivo existente en el estudio del “Efecto cascada” y el “Efecto látigo”, haciendo énfasis en el primero.

Para ayudar a la asimilación de conceptos, se dicutirá un caso práctico en el que podremos ejemplarizar la definición de ambos fenómenos. El ejemplo utilizado es la catástrofe sanitaria provocada por el Covid-19 y sus consecuencias en cadenas de suministro globales.

Tras habernos acercado a ambos conceptos de forma teórica, se analizan ahora con ayuda de diferentes métricas. Se desarrolla de un modelo de cadena de suministro creado con el software *Matlab* que servirá para poder estudiar el mencionado “Efecto cascada” y su relación con el “Efecto látigo”. Para modelar este fenómeno se realizarán interrupciones repentinas de tiempo variable de la capacidad productiva de un nodo de la cadena. Analizaremos distintos escenarios que darán lugar al “Efecto cascada”, analizando los resultados obtenidos sobre el rendimiento de la cadena y sacando diferentes conclusiones que pueden ser de interés para la gestión de la cadena en estas circunstancias.

Finalmente, concluiremos el trabajo ofreciendo aquellas limitaciones del modelo creado y las futuras líneas de investigación que podrían abrirse en caso de continuación del trabajo.



# Abstract

---

We are in a period of globalization in which commercial relations are established from different parts of the world. This causes supply chains to become larger and more complex and existence of the supply chain manager becomes crucial to make important decisions.

These decisions become extraordinarily complex when the chain is being affected by phenomena such as the "*Ripple effect*" and / or the "*Bullwhip effect*", which significantly impacts its performance. In this paper we dedicate a section to offer an overview of the dynamics of supply chains, and later a definition for both phenomena, since, as we will see later, they are related.

This work focuses on the "*Ripple effect*", which is a relatively new phenomenon in the literature. However, there are already quite a few studies whose analysis is interesting. We will dedicate a section to inquire about the existing literature related to this phenomenon. In addition, we will be able to know how it is possible to help the supply chain manager, that is, the managerial implications in the study of the "*Ripple effect*" and the "*Bulwhip effect*", emphasizing the former.

To help the assimilation of concepts, a practical case will be discussed in which we can exemplify the definition of both phenomena. The example used is the health catastrophe caused by Covid-19 and its consequences on global supply chains.

After having approached both concepts theoretically, they are now analyzed with the help of different metrics. It has been developed a supply chain model, with the help of the Matlab software, that will serve to study the aforementioned "*Ripple effect*" and its relationship with the "*Bullwhip effect*". To simulate this phenomenon, sudden interruptions with variable time of the productive capacity of a node of the chain will be carried out. We will analyze different scenarios that will give rise to the "*Ripple effect*", analyzing the results obtained on the performance of the chain and drawing different conclusions that may be of interest to the Supply Chain Management in these circumstances.

Finally, we will conclude the paper by offering those limitations of the created model and the future research lines that could be opened in case of the continuation of this paper.



# Índice

---

<b>Agradecimientos</b>	<b>x</b>
<b>Resumen</b>	<b>xii</b>
<b>Abstract</b>	<b>xiv</b>
<b>Índice</b>	<b>xvi</b>
<b>Índice de Tablas</b>	<b>xviii</b>
<b>Índice de Ilustraciones</b>	<b>xx</b>
<b>Índice de Ecuaciones</b>	<b>xxii</b>
<b>1 Introducción</b>	<b>23</b>
1.1 <i>Importancia del “Efecto cascada” en cadenas de suministro</i>	23
1.2 <i>Objetivos específicos del trabajo</i>	25
1.3 <i>Estructura del trabajo</i>	25
<b>2 Fenómeno “Efecto Cascada”</b>	<b>27</b>
2.1 <i>Conceptos básicos de la cadena de suministro</i>	27
2.2 <i>Historia</i>	28
2.3 <i>Definición</i>	29
2.4 <i>Literatura anterior</i>	31
2.5 <i>Interés productivo</i>	32
2.6 <i>Caso práctico: Covid-19</i>	32
<b>3 Modelo</b>	<b>35</b>
3.1 <i>Introducción al modelo</i>	35
3.2 <i>Variables del modelo</i>	35
3.3 <i>Dinámica y funcionamiento del modelo</i>	37
<b>4 Simulación y Resultados</b>	<b>41</b>
4.1 <i>Diseño de experimentos</i>	41
4.2 <i>Resultados</i>	43
4.3 <i>Discusión de resultados</i>	43
<b>5 Conclusiones</b>	<b>49</b>
5.1 <i>Limitaciones del modelo</i>	49
5.2 <i>Futuras líneas de investigación</i>	51
<b>Referencias Y Bibliografía</b>	<b>53</b>
<b>Anexo A</b>	<b>lv</b>
<b>Anexo B</b>	<b>lxxv</b>



# ÍNDICE DE TABLAS

---

Tabla 1. Ejemplos de rupturas y sus consecuencias en las cadenas de suministro (traducido de Dolgui et al., 2018)	24
Tabla 2. Variables principales del modelo.	37
Tabla 3. Resumen métricas utilizadas.	42
Tabla 4. Valores de los factores utilizados en la simulación	43
Tabla 5. Valores de los parámetros utilizados en los ensayos	43
Tabla 6. Resumen de resultados	48



# ÍNDICE DE ILUSTRACIONES

---

Ilustración 1. Fenómenos látigo y cascada. Traducido de Dolgui et al. 2018	29
Ilustración 2. Resultados del <i>NNS</i> obtenido en los ensayos con parámetro $H=0,5$ .	44
Ilustración 3. Resultados del <i>NNS</i> obtenido en ensayos con <i>Lead Time 2</i> y <i>Lead Time 4</i>	44
Ilustración 4. Resultados del <i>NNS</i> obtenido en los ensayos con $TIEMPO\_H=50, 30$ Y $10$	45
Ilustración 5. Diferencias entre el Order Rate posterior y anterior en el ensayo cuyos parámetros son: $TIEMPO\_H=50, LD\_transansporte=2, H=0, M=14$ y $Z=2$ .	46
Ilustración 6 . Diferencias entre el Order Rate posterior y anterior en los ensayos realizados con $TIEMPO\_H=50, 30$ Y $10$ , y parámetros: $LD\_transansporte=4, H=0, M=14$ y $Z=1,5$ .	46
Ilustración 7. Diferencias entre el OR posterior y anterior en los ensayos realizados con $M=7$ y $14$ , en el nodo 3 y con $TIEMPO\_H=50$ .	47
Ilustración 8. Gráficas del inventario y de los pedidos del nodo 3 (distribuidor)	50
Ilustración 9. Gráfica de pedidos del nodo 4 (fábrica) y del nodo 3 (distribuidor)	50



# ÍNDICE DE ECUACIONES

---

Ecuación 1	37
Ecuación 2	37
Ecuación 3	37
Ecuación 4.	37
Ecuación 5	38
Ecuación 6	38
Ecuación 7.	38
Ecuación 8.	38
Ecuación 9	38
Ecuación 10	38
Ecuación 11	38
Ecuación 12	38
Ecuación 13	39

# 1 INTRODUCCIÓN

---

En el presente trabajo analizaré los efectos de un fenómeno conocido como “efecto cascada” que se produce en las cadenas de suministro, pero cuya definición más adelante abordaremos. A modo de introducción, explicaré la importancia de este efecto en las cadenas de suministro, enunciaré los objetivos específicos de este trabajo y expondré su estructura.

## 1.1 Importancia del “Efecto cascada” en cadenas de suministro

En 2011, tras el terremoto y el posterior tsunami que afectaron a Japón, numerosas cadenas de suministro automovilísticas y de productos electrónicos se vieron enormemente afectadas. Las fábricas japonesas, fuertemente golpeadas por la catástrofe natural, fueron incapaces de cubrir la demanda que recibían, y las empresas que se abastecían de su producción se quedaron sin aprovisionamiento. Se produjo así un efecto cascada o efecto dominó que se originó con la incapacidad de producción de las fábricas japonesas y que derivó en un desabastecimiento de la cadena de suministro propagándose en todos sus escalones.

En el caso concreto de la empresa Toyota, ésta perdió su posición de liderazgo en el mercado tras la pérdida de ventas por la falta de inventario (coches de marca Toyota) en concesionarios de todo el mundo (Dolgui et al., 2018).

Existen numerosos ejemplos de situaciones en las que la producción se paraliza o se produce algún tipo de rotura en la cadena de suministro que origina un desajuste similar al ocurrido en Japón. En la Tabla 1 podemos observar diferentes orígenes del “efecto cascada” que ya han sucedido en la historia y sus consecuencias.

Durante el período de tiempo en el que la cadena se ve fuertemente influenciada por situaciones similares, las pérdidas son de una magnitud enorme y cada decisión que se toma es crucial para minimizarlas. Por tanto, el análisis de este efecto y sus impactos en la cadena de suministro ayudarían a mejorar las respuestas futuras de dichas cadenas, y a pesar de que aún estemos lejos de una definición exhaustiva de lo que es el “efecto cascada”, es fácil comprender que su estudio resulta una clara línea de interés en el ámbito de la producción.

Factor	Ejemplo	Impactos
Terrorismo	11 de septiembre	Cinco plantas de la marca Ford cerraron durante un tiempo.
Piratería	Somalia, 2008	Rupturas en muchas cadenas de suministro
Desastres naturales	Terremoto en Tailandia, 1999	La producción de ordenadores de Apple en Asia se paralizó
	Inundación en Sajonia, 2002	Se redujo considerablemente la producción en VW, Dresde
	Terremoto en Japón, 2007	Una paralización en la cadena de producción de Toyota afectó a 55000 coches
	Huracán Katrina, 2006	Esta tormenta detuvo entre el 10% y 15% de la producción de gasolina en EEUU, provocando una subida de precios nacional y en el extranjero
Fibra óptica	Terremoto y tsunami en Japón, 2011	Hubo colapsos masivos en las cadenas de suministro automovilísticas y electrónicas globales; Toyota perdió su posición de liderazgo en el mercado
	Inundaciones en Chennai, India 2015	La producción de literatura académica se paralizó en varias editoriales internacionales
Desastres derivados del hombre	Explosión en la planta BASF en Ludwigshafen, 2016	El 15% de las materias primas desapareció en toda la cadena de suministro
	Incendio en un centro de distribución de la empresa de comercio electrónico ASOS, 2005	Las entregas se suspendieron durante un mes
	Incendio en la planta de Phillips Semiconductor en Albuquerque, Nuevo Méjico, 2000	El mayor cliente de Phillips, Ericsson, perdió \$400 millones de ingresos potenciales
Crisis políticas	La “crisis del gas” de 2009	Interrupciones en el suministro de gas de Rusia a Europa. Miles de millones de pérdidas para GAZPROM y sus clientes
Crisis financieras	Otoño de 2008	Se redujo o se paralizó la producción en numerosas cadenas de suministro
Huelgas	Huelgas en la planta de Hyundai en 2016	Afectó a la producción de 130000 coches
Disputas legales	La disputa legal entre Volkswagen y el grupo Prevent en el verano de 2016	Seis fábricas alemanas vieron afectada su producción por escasez de piezas; fueron afectados 27700 empleados, algunos enviados a casa y otros con turnos reducidos

Tabla 1. Ejemplos de rupturas y sus consecuencias en las cadenas de suministro (traducido de Dolgui et al., 2018)

## 1.2 Objetivos específicos del trabajo

Tras conocer brevemente las razones del estudio del “Efecto cascada”, es importante fijar los objetivos concretos de este trabajo.

- Definir y diferenciar los conceptos de “Efecto cascada” y “Efecto látigo”.
- Realizar una retrospectiva de los estudios más relevantes realizados sobre el “Efecto cascada”.
- Desarrollar un modelo de simulación de una cadena de suministro serial, de 4 escalones, que permita obtener información relevante para el estudio del “Efecto cascada”.
- Modelar interrupciones de capacidad de duración e impacto variable.
- Analizar el “Efecto cascada” consecuencia de dichas interrupciones de capacidad para distintas configuraciones de la cadena, en función del inventario de seguridad, de la previsión del *lead time*, del *lead time* medio, del alcance de esta ruptura y de la duración de ésta.
- Ofrecer líneas de investigación futuras para una posterior continuación del trabajo.

## 1.3 Estructura del trabajo

Tras esta breve introducción, nos centraremos en el “Efecto cascada” en la sección II de este trabajo. A lo largo de dicha sección definiremos en primer lugar algunos conceptos claves para su entendimiento. En segundo lugar, indagaremos en su historia. Posteriormente, otorgaremos una definición concisa. En cuarto lugar, analizaremos de forma resumida la literatura anterior sobre el tema. En quinto lugar, explicaremos el interés productivo que conlleva. Y finalmente, expondremos un caso real aplicado del “efecto cascada”.

En la sección III cobra interés el modelo utilizado. Explicaremos las variables y la dinámica de la cadena de suministro empleada, así como las medidas de rendimiento de ésta.

Posteriormente, en la sección IV simularemos el modelo, y analizaremos los resultados obtenidos, tras la realización de distintos experimentos.

En la sección V nos centraremos en las conclusiones. Analizaremos primero las limitaciones del modelo, y abriremos más tarde, futuras líneas de investigación.

Finalmente, en la sección VI enunciaremos la bibliografía utilizada durante la realización del trabajo.



## 2 FENÓMENO “EFECTO CASCADA”

---

Como he mencionado anteriormente, el fenómeno que analizaré en este trabajo está presente en las cadenas de producción o cadenas de suministro. Por tanto, antes de explicar en detalle en qué consiste dicho fenómeno, definiré algunos conceptos clave. A continuación, indagaré en su historia y posteriormente, otorgaré una definición. Además, a modo de apoyo a dicha definición, incluiré dos secciones específicas, el interés productivo y el análisis de un caso real, como es el Covid-19.

### 2.1 Conceptos básicos de la cadena de suministro

En primer lugar, definiremos el concepto de cadena de suministro, el cual resulta trivial para entender esta sección.

Una cadena de suministro es una cadena formada por una serie de operaciones o actividades involucradas en el abastecimiento de un producto a un cliente final. Una definición más completa podría ser, “conjunto de actividades, instalaciones y medios de distribución necesarios para llevar a cabo el proceso de venta de un producto en su totalidad. Esto es, desde la búsqueda de materias primas, su posterior transformación y hasta la fabricación, transporte y entrega al consumidor final”, Nicole, 2017. Cada uno de esos puntos intermedios por los que pasa el producto, se denomina escalón de la cadena.

Dentro de una cadena, nos podemos encontrar una cantidad inmensa de escalones, pero en el presente trabajo utilizaremos el concepto de cadena de suministro serial formada por únicamente cuatro. A continuación, nos centraremos en analizar los escalones que conforman nuestra cadena.

Para que un cliente pueda disponer de un producto en un establecimiento o portal web orientado al público, necesitamos la existencia de un escalón básico, el minorista. Éste a su vez, necesita comprar esos productos a otro escalón anterior que es llamado mayorista, y así sucesivamente hasta llegar a un escalón final, la fábrica. En la cadena simple con la que estamos trabajando, hablamos de 4 escalones principales: minorista, mayorista, distribuidor y fábrica.

Así pues, para nosotros, una cadena de suministro está formada por los diferentes escalones que consiguen que un producto viaje desde una fábrica hasta el cliente final.

En una cadena de suministro puede haber más de un nodo en cada escalón. Un nodo es un punto de paso del producto dentro de la cadena de suministro, y la diferencia con respecto al escalón, es que el escalón engloba todos los nodos del mismo tipo. Por ejemplo, los minoristas son un escalón dentro de una cadena de suministro, y si en dicha cadena trabajan 3 minoristas diferentes, tendríamos 3 nodos distintos en ese mismo escalón.

La cadena de suministro de la que hemos hablado antes, con un único nodo en cada escalón, se conoce como cadena de suministro serial. Aunque esta cadena es muy simple, hay que tener en cuenta que la complejidad de una cadena puede incrementarse tanto en número de escalones como en nodos en cada escalón, llegando a formar redes muy grandes y complejas.

Otro concepto importante relacionado con este trabajo es la capacidad. “La capacidad de producción es el volumen de productos que puede generar una planta o empresa de manufactura en un período determinado, utilizando los recursos existentes actuales”, Helmut, 2019.

En una cadena de producción simple y serial, solo existe un nodo en el cual se genera o transforma un producto, la fábrica. Por tanto, la capacidad de producción será una consideración para tener en cuenta únicamente en este

último escalón.

Modelar reducciones de capacidad programadas, nos ayudaría a simular situaciones en las que el nodo con capacidad productiva sufre algún tipo de infortunio que desemboca en la paralización completa o parcial de la producción. Por ejemplo, una catástrofe natural, como un terremoto o una pandemia, podría destruir o paralizar completa o parcialmente una fábrica, que verá interrumpida o aminorada su capacidad de producción durante un cierto tiempo. El tiempo en el que el nodo se ve afectado por esta interrupción, así como la magnitud de dicha interrupción, serán puntos clave de este análisis, como veremos más adelante.

## 2.2 Historia

Como ya hemos visto anteriormente, una cadena de suministro está formada por una serie de escalones que dependen unos de otros. Esta dependencia es la culpable de que un suceso aguas arriba de la cadena (llamaremos de ahora en adelante aguas arriba a los escalones cercanos a la fábrica, o a la fábrica en sí misma) repercuta en la dinámica de los escalones inferiores o aguas abajo (llamaremos así a los escalones inferiores de la cadena).

Entendido el funcionamiento de una cadena y su dependencia entre escalones es fácil darse cuenta de que las cadenas son muy sensibles a las variaciones de la demanda. Introducimos así un fenómeno llamado “Efecto látigo” o en inglés *“Bullwhip effect”*. Lee et al. (1997) escribió que la varianza de los pedidos suele ser más alta que la de las ventas y que esa distorsión tiende a incrementarse según se mueve uno hacia aguas arriba de la cadena. Esto es lo que se llamaría posteriormente en la literatura, el *“Bullwhip effect”*. Este fenómeno ocurre debido a la dinámica de funcionamiento de las cadenas, pues con el fin de poder cubrir posibles incrementos en la demanda, los nodos se sobreaprovisionan. Por ejemplo, si la demanda de un determinado producto aumenta, el punto de venta generará una demanda mayor a su proveedor. Escalón tras escalón, los pedidos se irán viendo incrementados generando una discrepancia muy alta entre la variación real de la primera demanda y la variación aguas arriba de la cadena. Este desajuste genera una gran cantidad de inventario que no será absorbido y supondrá sobrecostes para las empresas. Además, supone la aparición de un *backlog* (pedidos atrasados) que podría acarrear enormes costes de oportunidad y penalización.

Si eliminamos el sobreaprovisionamiento de la dinámica de funcionamiento de las cadenas el *“Bullwhip effect”* desaparecería, sin embargo, estaríamos condenados a un coste de oportunidad constante y perderíamos numerosas ventas. Así pues, los distintos nodos de la cadena intentan buscar el máximo beneficio encontrando en cada situación el equilibrio entre afrontar costes de inventario para poder absorber posibles aumentos de demanda y afrontar costes de oportunidad para disminuir los de inventario.

El proceso de toma de decisiones en la gestión de inventarios en las empresas está basado en el aplazamiento o en la especulación de operaciones comerciales. En algunas circunstancias una compañía mantiene altos niveles de inventario (especulación), mientras que en otras mantiene niveles más bajos (aplazamiento) (Göran, 2005).

Entendiendo que el “Efecto látigo” es un fenómeno muy común en las cadenas de suministro, su ocurrencia es frecuente y va ligada a la propia dinámica de funcionamiento de la cadena, cabe decir que también es posible reducir sus efectos.

Hoy en día es muy común que los distintos nodos de la cadena cooperen entre ellos compartiendo información. Así, se consigue reducir la incertumbre que lleva a los nodos de aguas arriba de la cadena a sobreaprovisionarse en exceso. Por ejemplo, si bajo ninguna razón aparente un producto aumenta su demanda ocasionalmente, el punto de venta realizará un pedido mayor en vistas a que la tendencia siga al alza, pero compartirá la información real de sus ventas con el siguiente escalón de la cadena para que el sobreaprovisionamiento se realice sobre la demanda real y no sobre otro sobreaprovisionamiento. Con esta cooperación entre nodos se consigue disminuir los sobrecostes propios del “Efecto látigo”.

Por otro lado, un buen seguimiento del mercado permite a las empresas predecir el comportamiento de la gráfica de demanda de un producto. Por ejemplo, si tras realizar ciertos estudios de mercado se concluye que un producto (p.ej. el helado) es demandado en mayor medida en un cierto período del año (p.ej. los meses de calor), es fácil no caer en un sobreaprovisionamiento infundado cuando comienza a subir su demanda.

Además de las mencionadas, es posible paliar las consecuencias del *“Bullwhip effect”* con otro tipo de medidas, sin embargo, profundizar en estas medidas no son motivo de discusión en este trabajo.

En conclusión, el *“Bullwhip effect”* indica que la variabilidad del nivel de inventario en las cadenas de suministro

tiende a ser más alta aguasarriba que aguasabajo y es causada por factores como intercambio de información deficiente, insuficientes datos del mercado, pronósticos deficientes y otras incertidumbres. (Göran,2005)

Es importante destacar que se habló de este efecto por primera vez en 1961 en una publicación del Massachusetts Institute of Technology (MIT), en el libro “*Industrial Dynamics*” (Forrester, 1961). Desde entonces se han publicado numerosos estudios muy relevantes al respecto. Sin embargo, este trabajo pretende centrarse en un concepto mucho más reciente, como es el “*Ripple effect*”, el cual comienza a despertar interés tras observarse el descontrol que han experimentado las cadenas de suministro a raíz de sucesos poco predecibles y cuya repercusión en la cadena ha resultado muy significativa, no siendo el “Efecto látigo” suficiente para explicar su comportamiento.

## 2.3 Definición

En este apartado intentaré diferenciar el “Efecto cascada” del “Efecto látigo”, otorgando finalmente una definición para el primero. Me gustaría aclarar que, al ser un concepto relativamente nuevo, no existe una definición universal aprobada por la comunidad científica y que, por tanto, ofreceré una visión personal de su significado.

El llamado “efecto cascada” se podría diferenciar del “Efecto látigo”, en primer lugar, debido a su impacto en la cadena. Mientras que el “*Bullwhipp effect*” es fácilmente controlable y reducible tomando medidas como el estudio del mercado o la puesta en común de información, es posible que surjan otros fenómenos perjudiciales para la cadena cuya reducción no es trivial. Es el caso del “Efecto cascada”.

Este fenómeno explica los escenarios resultantes tras la ocurrencia de un suceso considerado poco frecuente y poco predecible, pero con un gran impacto en la dinámica de la cadena. El “Efecto cascada”, que lidia con interrupciones de baja frecuencia y alto impacto o con riesgos excepcionales representa una inversión del “efecto látigo”, que considera riesgos de alta frecuencia y bajo impacto, que son operacionales y recurrentes (Dolgui et al., 2018).

En este estudio se desarrolló un esquema muy interesante sobre algunas diferencias entre un efecto y otro, como puede verse en la Ilustración 1.

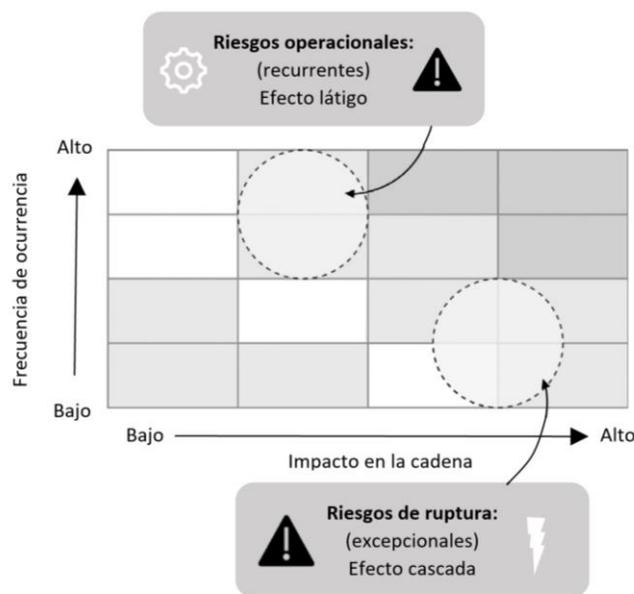


Ilustración 1. Fenómenos látigo y cascada. Traducido de Dolgui et al., 2018

En dicha ilustración podemos apreciar una gráfica cuyos ejes de ordenadas y eje de abscisas son el impacto en la cadena y la frecuencia de ocurrencia. Se sitúa el el “Efecto cascada” en la parte derecha inferior de la gráfica y

al “Efecto látigo” en la parte superior izquierda. En otras palabras, el “Efecto cascada” produce un impacto en la cadena superior al “Efecto látigo”, pero la frecuencia de ocurrencia es mayor en este último.

Se consideran riesgos operacionales aquellos propios de la aleatoriedad de la dinámica de la cadena, por ejemplo, variaciones en la demanda. Así pues, otra diferencia evidente entre el “Efecto látigo” y el “Efecto cascada” reside en el origen. El primero deriva de riesgos operacionales, en cambio, el segundo lidia con riesgos no operacionales y en concreto, estructurales de gran impacto. Los riesgos estructurales son aquellos que pueden afectar de forma directa a la estructura de funcionamiento de la cadena, la cual funciona gracias a la existencia de los distintos escalones con sus correspondientes nodos, a la logística y comunicación entre ellos, los suministros que cada nodo necesite para su funcionamiento...etc. Así pues, una ruptura en algún eslabón clave de la cadena implica la existencia de un riesgo estructural que podría derivar en el “*Ripple effect*”.

Una paralización de la producción a causa de una catástrofe natural es un claro ejemplo de riesgo estructural en la cadena. Si esa ruptura, en lugar de permanecer localizada o estar contenida en una parte de la cadena, cae aguas abajo e influye en el funcionamiento de esta, podríamos concretar que se ha producido el llamado “*Ripple effect*”.

Puesto que este fenómeno describe el escenario que se produce tras una interrupción o ruptura grave cabe mencionar que la literatura considera tres tipos básicos de rupturas que deben ser considerados: (Ivanov et al., 2017)

- Producción
- Suministro
- Transporte

Así pues, si se produce una ruptura en alguno de los apartados anteriores se puede producir el llamado “Efecto cascada”, el cual describe el impacto de la propagación de esa ruptura en el funcionamiento de la cadena (Dolgui et al., 2018).

En este trabajo esta ruptura se produce en la producción, por tanto, hemos de considerar que la interrupción solo puede ocurrir en la fábrica (único nodo con capacidad productiva de nuestra cadena). Tras dicha ruptura, la fábrica verá interrumpida su producción parcial o totalmente y no podrá seguir abasteciendo aguas abajo con la misma capacidad. Puesto que la demanda del cliente final de la cadena no tiene por qué verse alterada, los pedidos se irán produciendo de escalón en escalón y llegarán a la fábrica, que no podrá suministrarlos. Todo ello provocará que poco a poco los nodos pierdan su inventario de seguridad hasta llegar a generar un “*backlog*” o retraso en las entregas. Se produce así una propagación de pérdida de inventario e incapacidad para abastecer al escalón anterior de la cadena desde aguas arriba hasta aguas abajo de la misma. Por tanto, encontramos de nuevo distinciones evidentes entre el “Efecto látigo” y el “Efecto cascada”: se propagan en direcciones opuestas, desde aguas abajo hasta aguas arriba y desde aguas arriba hasta aguas abajo respectivamente, y el contenido de propagación es distinto. Mientras que en el “Efecto cascada” se propaga una disminución del suministro, en el “Efecto látigo” se propaga un aumento de la cantidad en cada pedido.

Los sucesos esporádicos con gran impacto en la cadena de suministro, como los que podemos encontrar en la Tabla 1 ofrecida en el apartado 1.1, no solo son el detonante de rupturas en alguno de los departamentos (producción, suministro y transporte), si no que además pueden derivar en el aumento repentino de la demanda de ciertos productos y ese riesgo existente es importante que se tenga en cuenta en la gestión de la cadena.

Por otro lado, existen indicios de una relación existente entre el “Efecto cascada” y el “Efecto látigo” que resulta de interés para la realización de este trabajo. Un reciente estudio de Alexandre Dolgui, Dmitry Ivanov & Maxim Rozhkov dice que el “Efecto cascada” influye en el “Efecto látigo” a través de la acumulación de atrasos durante el tiempo de interrupción como consecuencia de políticas de planificación de producción y pedidos no coordinados. Esto quiere decir, que tras una ruptura en la producción y el posterior “*Ripple effect*” ocasionado, es posible que surja un “*bullwhip effect*” a consecuencia de una falta de comunicación entre nodos para que los pedidos dejen de producirse (Dolgui et al., 2020). En este trabajo analizaremos también esta posible influencia entre el “Efecto cascada” con ruptura en la producción sobre el “Efecto látigo”.

A modo de resumen de esta sección concretamos que la diferencia entonces entre el “Efecto látigo” y el “Efecto cascada” responde a la dirección de propagación (ascendente según sea “Efecto látigo” o descendente si es “Efecto cascada”) y magnitud de impacto en la cadena (suave o brusco), al origen de esta (operacional o no operacional), al contenido de propagación y a la frecuencia de ocurrencia.

Finalmente, podemos concluir que el “*Ripple effect*” describe el impacto en el funcionamiento de la cadena de suministro de la propagación de una ruptura y los cambios en el diseño estructural de la cadena y en los parámetros de planificación que deben hacerse tras dicha ruptura (Dolgui et al., 2018).

## 2.4 Literatura anterior

A pesar de que el comienzo del estudio de este fenómeno se remonta sólo dos décadas atrás, existen bastantes publicaciones dedicadas a ello. Uno de los autores más conocido es Dimitry Ivanov, que ha redactado numerosos documentos referentes al “*Ripple effect*” y ha liderado o co-liderado muchas investigaciones.

Dentro de la literatura anterior encontramos numerosos estudios que se centran en conseguir el mínimo impacto posible en la cadena tras una ruptura. Así pues, podemos encontrar dos grandes grupos diferenciados: estudios enfocados a interrupciones en la cadena con o sin medidas de recuperación previas. Esto ha provocado que aparezcan dos enfoques diferentes, análisis reactivo y proactivo, y ambos pretenden proteger la cadena ante una ruptura. El enfoque proactivo se ocupa de la creación de políticas de protección sin tener en cuenta las medidas de recuperación en el diseño de la cadena. Por otro lado, las estrategias reactivas se centran en diseñar procesos y estructuras de cadenas que pueden ser ajustadas cuando ocurra la ruptura (Dolgui et al., 2018). Así pues, podemos encontrar estudios orientados a la búsqueda de cadenas resistentes capaces de aguantar una ruptura, estrategias con el fin de crear una cadena robusta, y estudios orientados a encontrar las medidas más eficaces en caso de una ruptura, estrategias para crear una cadena resiliente.

En los últimos años están comenzando a aparecer estudios que utilizan ambos enfoques para minimizar el impacto negativo de las rupturas en las cadenas suministro. Considero clave que se tengan en cuenta ambos criterios puesto que, aunque es posible que pocos gestores de cadenas decidan reforzarlas aumentando su resistencia para aminorar costes en caso de rupturas (recordemos que son sucesos poco probables, pero con gran impacto), una cierta flexibilidad en la cadena que otorgue un mínimo de capacidad de adaptación aminoraría costes futuros.

Además de esta clasificación, podemos diferenciar la literatura según el tipo de resolución empleada: optimización matemática, simulación, teoría de control, y teoría de la complejidad y fiabilidad.

Dentro de la optimización matemática encontramos en primer lugar el MIP (mixed-integer-programming). La programación de enteros mixtos se ha aplicado ampliamente para el desarrollo del diseño de la cadena, desde que Snyder y Daskin (2005) comenzaran a aplicarlo. Además del MIP, destaca la programación estocástica. Las funciones objetivo en la programación estocástica contienen la suma de la medida de actuación de la primera etapa y la que se espera en la segunda etapa. Los modelos se basan en escenarios y los parámetros están representados por un conjunto de escenarios discretos con una probabilidad de ocurrencia determinada (Ivanov et al., 2017).

Por otro lado, la simulación resulta clave para el análisis de riesgos, el impacto del modo de actuación en la cadena y la evaluación de la resiliencia. En la literatura existente el “*Ripple effect*” se ha analizado desde tres puntos de vista dentro de la simulación: sistemas dinámicos, modelado basado en agentes y simulación de eventos discretos (Dolgui et al., 2018). Los estudios de simulación en torno al “Efecto cascada” se han ganado un papel importante en la investigación debido a que trabajan con interrupciones graduales y dependientes del tiempo, con la duración de las medidas de recuperación y con la degradación y recuperación de la capacidad (Dolgui et al., 2018).

Los estudios realizados con teoría de control sobre el “*Ripple effect*” adoptan una perspectiva diferente a la del MIP o la programación estocástica, como es la introducción de políticas de producción, inventario y logística simultáneamente, y ciclos de retroalimentación. Se quiere utilizar la teoría de control como herramienta para combinar una resolución óptima de un problema y la simulación temporal. Por ejemplo, Ivanov, Sokolov y Pavlov (2013) incluyeron, en un modelo de cadena de suministro de varios períodos, una posible reconfiguración del transporte en caso de ocurrencia de una ruptura. El modelo combina programación lineal (LP) y control (Dolgui, 2018).

En el ámbito de la teoría de complejidad y fiabilidad encontramos, por ejemplo, un estudio de Nair y Vidal (2011) en el que se analiza la robustez de una cadena de suministro frente a interrupciones utilizando un análisis topológico de gráficos. Estudiaron 20 cadenas sujetas a demanda aleatoria. La resistencia de las cadenas se evaluó considerando probabilidades de fallo variables, ocasionando fallos tanto en nodos aleatorios como en

nodos concretos (Dolgui et al., 2018).

Lin et al. (2017) estudiaron la fiabilidad de una cadena multietapa como la probabilidad de que la cadena pueda satisfacer la demanda del mercado a través de múltiples estaciones de tránsito dentro de un tiempo apropiado. En este estudio la fiabilidad del sistema es el índice de actuación de la entrega y se evalúa como el total de trayectos mínimos encontrados (Dolgui et al., 2018).

Para estudiar el “Efecto cascada” es posible utilizar numerosos métodos de resolución válidos y no solo los vistos en este resumen. Además de las clasificaciones vistas, es posible diferenciar la literatura según otros criterios como puedan ser el tipo de cadenas analizadas (seriales, con múltiples nodos en cada escalón, con un solo producto o varios, de productos perecederos o no perecederos...) o el tipo de ruptura (en la logística, en la producción, en la información...) entre otros. Dedicaremos al final del proyecto, un pequeño apartado en el que hablaremos de futuras áreas de interés en relación con este fenómeno tanto para orientar una posible continuación de este trabajo como para abrir futuras líneas de investigación en el ámbito del “*Ripple effect*”.

## 2.5 Interés productivo

El interés que genera, en el ámbito de la gestión productiva, la capacidad de gestionar rupturas en las cadenas radica en la posibilidad de responder de la forma más eficaz posible ante una situación que genera un aumento de costes muy alto.

No es ignorado que cada vez más empresas recurren a la gestión total de la cadena para paliar entre otras cosas el “*Bullwhip effect*” (recordamos que se generaba, entre otras causas, debido a una comunicación ineficaz entre nodos). Es por eso por lo que ha surgido un nuevo ámbito en las empresas dedicado a la gestión de la cadena de suministro (*Supply Chain Management*), además de la figura de su máximo responsable, el gestor de la cadena (*supply manager*). El gestor debe tomar decisiones cuyo impacto en la cadena y en los costes es evidente, por tanto, necesitará conocer los riesgos a los que se enfrenta su cadena. Hemos hablado ya de los riesgos operacionales, que causan el “Efecto látigo”, pero no podemos olvidarnos de los riesgos estructurales como lo son las rupturas en la producción, en la logística o en los suministros. Es tarea del gestor aplicar unas medidas u otras según el tipo de ruptura, o incluso aumentar la resistencia de la cadena antes de que suceda la ruptura (recordamos los estudios reactivos). Por tanto, la realización de estudios o investigaciones cuyo objetivo sea otorgar luz a un fenómeno tan complejo como el “*Ripple effect*” es clave para apoyar las decisiones del gestor y abaratar los costes totales de las empresas en casos de ruptura.

## 2.6 Caso práctico: Covid-19

Como hemos visto, el “Efecto cascada” surge tras sucesos poco predecibles como puedan ser las catástrofes naturales. Sin embargo, otro tipo de sucesos hasta ahora no considerados en la literatura y cuyo impacto en la cadena es evidente son las catástrofes sanitarias como el Covid-19. Creo importante destacar que al comienzo de la realización de este trabajo estalló dicha pandemia mundial, por tanto, considero éste un buen ejemplo para explicar tanto el “*Ripple effect*” como el “*Bullwhip effect*”.

La pandemia comenzó en una región de China, Wuhan, y China es una productora mundial, por tanto, muchas de las fábricas que proveen a millones de empresa de todo el mundo, se sitúan allí. Aunque hay informaciones que apuntan a que los primeros casos de coronavirus en China se remontan a diciembre o incluso noviembre, no fue hasta finales de enero que empezó a cundir el pánico entre la sociedad, y comenzaron a paralizarse fábricas de forma masiva. Según lo que hemos explicado anteriormente, la paralización de una fábrica supondría una disminución a cero de su capacidad de producción, durante un cierto tiempo. Dicha paralización en China provocó el desabastecimiento de numerosas empresas por todo el mundo. Si este suceso se analiza más profundamente, podemos darnos cuenta de que el Covid-19 provocó un “Efecto cascada” muy claro, en las cadenas de suministro. Una reducción tan significativa de la producción supuso un desajuste de la cadena que se propagó desde las fábricas de China hasta los puntos de venta de muchas partes del mundo. Pero el Covid-19 en esta primera etapa que solo afectaba a China, no solo originó el “Efecto cascada”. La incapacidad de proveer de las fábricas chinas derivó en la búsqueda por parte de distribuidores de todo el mundo, de otros proveedores capaces de absorber esa demanda. Muchas fábricas y empresas vieron incrementada su fabricación tras recibir

aumentos de demanda derivados de la catástrofe sanitaria, lo cual podría ser analizado como un “Efecto látigo”.

Desgraciadamente, la extensión de la enfermedad por el resto del mundo no tardó. En poco más de 1 mes, se habían multiplicado los casos en diferentes países del territorio global, y cerraron fábricas de todo el mundo. Esta situación agravó el desabastecimiento general de las empresas provocado por un “Efecto cascada” en muchas cadenas de suministro globales. Pero quizás, bajo mi punto de vista, las situaciones más descontroladas se vivieron debido al “*Bullwhip effect*” de magnitudes desproporcionadas que se originó. El aumento repentino de la demanda de productos sanitarios como las mascarillas, gel desinfectante, equipos de protección individual... provocaron un desajuste inmenso entre la demanda y la oferta existente, que generó un *backlog* en un primer momento, pero que probablemente genere una sobreproducción de la que ya se están haciendo eco algunas empresas y que no será absorbida por una demanda que tiende a estabilizarse o incluso reducirse.



## 3 MODELO

---

En este capítulo veremos, en primer lugar, detalles específicos de la dinámica de la cadena en la introducción. Más adelante, ofreceremos una visión general de las variables que participan en el modelado de las operaciones de la cadena. Por último, explicaremos el funcionamiento de ésta, junto con las ecuaciones más importantes utilizadas.

### 3.1 Introducción al modelo

Para poder analizar el “Efecto cascada” y el posible “Efecto látigo” derivado de la ruptura, ha sido necesaria la creación de un modelo que simule el funcionamiento de una cadena de suministro durante  $n$  periodos. Este modelo se ha creado en el software Matlab, herramienta computacional ampliamente extendida en la ingeniería.

Se trata de una cadena de suministro serial de 4 escalones, es decir, un nodo en cada escalón: minorista, mayorista, distribuidor y fábrica. La demanda del cliente final se modela como función una de distribución normal de media 50 y desviación típica 20. Además, el modelo utiliza un tiempo de entrega (*lead time*) determinista.

El modelo realiza de forma automatizada las operaciones propias de los nodos que conforman la cadena, desde el cálculo del inventario de seguridad (*safety stock*) hasta la previsión (*forecast*) del *lead time* o la demanda. Estos resultados se guardan en vectores de  $n$  elementos para su posterior estudio.

Además de simular el comportamiento de la cadena, existen partes del código destinadas al análisis y al diseño de experimento, que no analizaremos en esta sección pero que se pueden ver en el Anexo A.

### 3.2 Variables del modelo

En este apartado se indican las variables, parámetros y constantes principales, claves para el entendimiento de la dinámica de la cadena explicado en el siguiente apartado.

Además de las presentes en **¡Error! No se encuentra el origen de la referencia.** Tabla 2, se han utilizado numerosas variables y ecuaciones auxiliares necesarias para el estudio de la cadena. Para una visión detallada del código utilizado acudir al Anexo A.

Puesto que la mayor parte de las variables presentes están definidas en todos los nodos, se utiliza el subíndice  $i$ , para facilitar su lectura.

$$i = 1,2,3,4$$

VARIABLES Y CONSTANTES PRICIPALES	DESCRIPCIÓN
$INV_i(T)$	Vector cuyos elementos indican el inventario que dispone el nodo $i$ en cada período de la simulación.
$WIP_i(T)$	Vector cuyos elementos indican la cantidad de unidades de producto pedidos por el nodo $i$ que aún no han llegado, en cada período. <i>Work in progress</i> .
$ENTREGA_i(T)$	Vector cuyos elementos indican la cantidad de unidades de producto entregados por el nodo $i$ , en cada período.
$ENTREGA5(T)$	Vector cuyos elementos indican la cantidad de unidades de producto entregados por el hipotético nodo 5 a la fábrica, en cada período.
$entrega1(T)$	Vector cuyos elementos indican la cantidad de unidades de producto entregados por el minorista al cliente final, sin tener en cuenta los pedidos atrasados, en cada período.
$B_i(T)$	Vector cuyos elementos indican la cantidad de unidades de producto que el nodo $i$ tiene atrasados, en cada período.
$ORDER_i(T)$	Vector cuyos elementos indican la cantidad de unidades de producto que el nodo $i$ pide al nodo $i+1$ , en cada período.
$S_i(T)$	Vector cuyos elementos indican el inventario de seguridad que pretende mantener el nodo $i$ , en cada período.
$MC_i$	Parámetro que indica la máxima capacidad del nodo $i$ .
$DEMANDA(T)$	Vector cuyos elementos indican la cantidad de unidades de producto demandadas por el cliente final, en cada período.
$LD\_TRANSPORTE$	Parámetro que indica el número de períodos mínimos necesarios para que el producto viaje de un nodo a otro. Se supone determinista.
$LD\_MEDIA_i(T)$	Vector cuyos elementos indican la media móvil del número de períodos reales utilizados para que el producto viaje del nodo $i+1$ al nodo $i$ , en cada período. ( <i>Lead Time</i> real). En el caso de $i=4$ , $i+1$ corresponde a un hipotético nodo 5.
$DEMANDAMEDIA_i(T)$	Vector cuyos elementos indican la media móvil de la cantidad de unidades de producto demandadas por el nodo $i-1$ , en cada período. En el caso de $i=1$ , la demanda corresponde al cliente final.
$R$	Constante de valor 1 empleada en el cálculo del Safety Stock.
$Z$	Parámetro que indica el factor de seguridad empleado en el cálculo del Safety Stock.
$FC$	Constante de valor 5 empleada en el cálculo de la máxima capacidad de la fábrica.
$H$	Parámetro que indica el grado de reducción en la capacidad productiva de la fábrica.
$M$	Parámetro que indica el número de períodos anteriores utilizados en el

	cálculo de la demanda móvil del Lead Time. La variable utilizada en la media móvil es $LD_{aprox}(t)$ y el resultado es la variable $LD_{media}(t)$ .
$LD\_APROX_i(T)$	Vector cuyos elementos indican la cantidad de períodos reales utilizados para que el producto viaje del nodo $i+1$ al nodo $i$ , en cada período. En el caso de $i=4$ , $i+1$ corresponde a un hipotético nodo 5.
$TIEMPO\_H$	Parámetro que indica la cantidad de períodos que dura la ruptura.
$\mu$	Demanda media utilizada para modelar la demanda.
$\Omega$	Desviación típica utilizada para modelar la demanda.
$R$	Constante para el cálculo del inventario de seguridad.

Tabla 2. Variables principales del modelo.

### 3.3 Dinámica y funcionamiento del modelo

A continuación, se detalla el funcionamiento y la estructura del modelo. En primer lugar, cabe mencionar que la parte del código que describe la dinámica de la cadena (la cual vamos a explicar en este apartado) está implementada como una función en Matlab cuyos argumentos de entrada son: el tiempo anterior a la ruptura, el tiempo posterior al comienzo de la ruptura, el grado de paralización de la fábrica, el tiempo de duración de la paralización, el *Lead Time*, el parámetro  $M$  y el parámetro  $Z$ . Y cuyos argumentos de salida son los Order Rate anteriores y posteriores a la ruptura, de los cuatro nodos que conforman la cadena. Los argumentos de salida son los datos que utilizaremos para analizar los resultados de los ensayos.

En cada período, se realizan distintas operaciones con un orden concreto en los nodos 1,2,3 y 4. Este proceso se repite durante  $n$  períodos. A continuación, se detallan las ecuaciones utilizadas con la ayuda del subíndice  $i$  para definir aquellas que se repiten en todos los nodos. Es importante mencionar que primero se realizan todas las operaciones pertinentes del nodo 1, luego del nodo 2, y así sucesivamente.

$$i = 1,2,3,4.$$

$$INV_i(t) = INV_i(t - 1) + ENTREGA_{i+1}(t - LD_{transporte})$$

Ecuación 1

$$WIP_i(t) = WIP_i(t - 1) + ENTREGA_{i+1}(t - LD_{transporte})$$

Ecuación 2

$$ENTREGA_1(t) = \min(INV_1(t), DEMANDA(t) + B_1(t - 1))$$

Ecuación 3

La ecuación 3 es específica para el nodo 1.

$$ENTREGA_i(t) = \min(INV_i(t), ORDER_{i-1}(t) + B_i(t - 1))$$

Ecuación 4.

La ecuación 4 es específica para los nodos 2,3 y 4.

$$entrega1(t) = \max(0, ENTREGA1(t) - B1(t - 1))$$

Ecuación 5

La ecuación 5 se aplica solo en el nodo 1.

$$INV_i(t) = INV_i(t) - ENTREGA_i(t)$$

Ecuación 6

$$B1(t) = B1(t - 1) + DEMANDA(t) - ENTREGA1(t)$$

Ecuación 7.

La ecuación 7 es específica del nodo 1.

$$B_i(t) = B_i(t - 1) + ORDER_{i-1}(t) - ENTREGA2_i(t)$$

Ecuación 8.

La ecuación 8 es específica para los nodos 2,3 y 4.

$$ORDER_i(t) = \min(\max(0, S1_i(t) - INV_i(t) + B_i(t) - WIP_i(t)), MC_i)$$

Ecuación 9

$$WIP_i(t) = WIP_i(t) + ORDER_i(t)$$

Ecuación 10

Donde  $S_i(t)$  ha sido previamente calculado como:

$$S_i(t) = (LD_{media_i(t)} + R) * DEMANDAMEDIA_i(t) + Z * \text{sqrt} \left( (LD_{media_i(t)} + R) * VARMEDIA_i(t) \right)$$

Ecuación 11

Y  $LD_{media_i}(t)$  como la media móvil de  $M$  períodos anteriores del  $LD_{aprox_i}(t)$ . Esta última variable responde al valor real del *Lead Time*, es decir, la cantidad de períodos que tarda un pedido en llegar desde que se envía la orden hasta que llega a las instalaciones. El  $LD_{aprox_i}(t)$  será mayor o igual que el tiempo de transporte ( $LD_{transporte}$ ).

Por otro lado, la máxima capacidad del nodo 1 ( $MCI$ ) se considera infinita. Ocurrirá lo mismo en los nodos 2 y 3. En cambio, la máxima capacidad del nodo 4 será:

$$MC4 = \mu * FC * H$$

Ecuación 12

Además, posteriormente a los cálculos del nodo 4 ha de crearse un nodo hipotético, inexistente (nodo 5) en el que se realiza la siguiente operación:

$$ENTREGA5(t) = ORDER4(t)$$

Ecuación 13



# 4 SIMULACIÓN Y RESULTADOS

En este capítulo encontramos, en primer lugar, el diseño de experimentos, donde se detallan los parámetros y las métricas utilizadas en los ensayos. Posteriormente, en la segunda sección se ofrece una breve explicación para acceder a la información completa de los resultados obtenidos. Finalmente, la última sección está dedicada a la discusión de los resultados.

## 4.1 Diseño de experimentos

En este apartado explicaremos los ensayos que se han realizado para el análisis del “Efecto cascada”. En primer lugar, para estudiar el comportamiento de la cadena ante una ruptura se ha decidido realizar una simulación de 1150 períodos. La simulación comienza con las variables a cero, por tanto, ha de pasar un cierto tiempo (período transitorio) hasta que se establezca el comportamiento de la cadena, que será de 300 (warm up period). La ruptura comienza en el período 1000 y durará lo que indique la variable denominada como *TIEMPO\_H*, es decir, este será un parámetro de nuestros ensayos y variará entre los valores 10,30 y 50. La ruptura puede ser total, transformando la máxima capacidad de la fábrica (*MC4*) a cero ( $H=0$ ), o parcial. Para el análisis de una ruptura parcial estableceremos un valor del 50% de la capacidad, lo cual implica un valor de *H* igual a 0,5. ( $MC4=\mu*FC*H$ ).

Puesto que el modelo simulado no comparte información entre sus nodos, es de esperar un “*Bullwhip effect*” que se ha medido con ratio extensamente utilizado en la literatura:

$$OR_i = \frac{\text{Varianza de los los pedidos del escalón } i}{\text{Varianza de la demanda del cliente final}}$$

Esta ratio se ha calculado para cada nodo de la cadena tanto antes como después de la ruptura. Hemos de tener en cuenta que el “*Bullwhip effect*” está presente en la cadena incluso antes de frozar una ruptura. Recordamos lo que Lee et al. (1997) escribió y que ya hemos comentado anteriormente: que la varianza de los pedidos suele ser más alta que la de las ventas y que esa distorsión tiende a incrementarse según se mueve uno hacia aguas arriba de la cadena. Así pues, con este ratio mediremos la propagación entre los nodos de la cadena tanto antes de la ruptura como después. El objetivo es cuantificar el cambio entre los Order Rate anteriores y posteriores a la cadena para comprobar si existe un empeoramiento tras una ruptura. Recordamos que Dolgui e Ivanov (2020) apuntaban a la existencia de un “*Bullwhip effect*” derivado de una ruptura. No existe una métrica aceptada por la literatura para medir este “*Bullwhip effect*”, por tanto, hemos optado por utilizar como métrica la variación existente entre el Order Rate anterior a la ruptura y el Order rate posterior. Usaremos esa diferencia existente entre el Order Rate posterior y el Order Rate anterior de cada nodo y de cada ensayo para cuantificar la influencia del “*Bullwhip effect*” derivado, en la cadena.

Hemos visto cómo analizaremos el “*Bullwhip effect*” derivado, cuyo estudio ha sido prácticamente olvidado en la literatura anterior existente. Sin embargo, el análisis del “*Ripple effect*”, a pesar de la existencia de numerosos estudios, no resulta más sencillo de cuantificar. Los diferentes investigadores han utilizado métricas distintas para medir el “Efecto cascada” y no existe un consenso entre la comunidad científica. Además, se suele trabajar con medidas que analizan el aguante de la cadena a la ruptura, y no con métricas que midan específicamente la propagación de esa ruptura (“*Ripple effect*”). En este trabajo, analizaremos los efectos de una ruptura comprobando las veces que el nivel de servicio desciende del 100% desde que comienza la paralización de la producción. Elegimos el valor del 100% como comparativa porque los resultados del nivel de servicio sin la existencia de una ruptura son del 100% de media. El nivel de servicio responde a la siguiente ecuación:

$$NS(\%) = \left( \frac{\text{Entrega a los clientes}}{\text{Demanda de los clientes}} \right) * 100$$

He de destacar que la entrega a los clientes no debe incluir los pedidos atrasados (en el modelo esta variable se denota como *entrega(t)*). Demás, este ratio solo se calcula en el nodo 1, y mide la capacidad de la cadena de cumplir con la demanda existente.

Por tanto, utilizando este parámetro veremos si la incapacidad de suministro se ha propagado desde la fábrica hasta el minorista (nodo 1), lo cual resultaría en niveles de servicio por debajo del 100%, y en qué medida, comparando el número de veces que este nivel de servicio desciende.

	“Efecto látigo” resultante de una ruptura	“Efecto cascada”
Métrica	Diferencia entre el Order Rate sin ruptura y el Order Rate con ruptura	NNS (Número de veces que el Nivel de Servicio desciende del 100%)
Métrica basada en:	Order Rate. $= \frac{OR_i \text{ Varianza de los los pedidos del escalón } i}{\text{Varianza de la demanda del cliente final}}$	Nivel de Servicio. $= \left( \frac{NS(\%) \text{ Entrega a los clientes}}{\text{Demanda de los clientes}} \right) * 100$

Tabla 3. Resumen métricas utilizadas.

Realizaremos ensayos modificando los parámetros: *Z*, *TIEMPO\_H*, *H*, *LD\_transporte* y *M*. El parámetro *Z* es una constante que participa en el cálculo del *safety stock* de cada nodo.

$$S(t) = (LD\_media(t) + R) * DEMANDAMEDIA(t) + Z * sqrt((LD\_media(t) + R) * VARMEDIA(t))$$

El parámetro *H*, recordamos que hacía referencia al tipo de paralización, completa (*H=0*) o parcial (*H=0,5*), en la capacidad de producción.

$$MC4 = \mu * FC * H$$

El *TIEMPO\_H* indica el número de períodos que se ejecuta la paralización, oscila entre 50, 30 y 10.

El parámetro *M* corresponde al alcance de la previsión del tiempo de entrega o *lead time*.

Por último, el parámetro *LD\_transporte* indica el *lead time* mínimo o tiempo de espera mínimo del producto, que oscilará entre 4 y 2.

A continuación, se ofrece un breve resumen de los factores utilizados, en la Tabla 4. Y en la Tabla 5, Tabla 5. Valores de los parámetros utilizados en los ensayos se pueden encontrar los parámetros y sus valores correspondientes elegidos para la realización de los ensayos.

Factores utilizados	$\mu$	$\Omega$	TIEMPO DE DURACIÓN DE LA SIMULACIÓN	PERÍODO EN EL QUE COMIENZA LA RUPTURA	PERÍODO DE TRANSICIÓN INICIAL ( <i>WARM UP PERIOD</i> )	R	FC
Valor	50	20	1150 (períodos)	1000	300	1	5

Tabla 4. Valores de los factores utilizados en la simulación

Parámetros utilizados	M	TIEMPO_H	Z	H	LD_transporte
Valores ensayados	7 y 14	10, 30 y 50	1,5 y 2	0 y 0,5	2 y 4

Tabla 5. Valores de los parámetros utilizados en los ensayos

Así pues, se han realizado ensayos de los 48 escenarios posibles variando los citados cinco parámetros. Para agrupar de una forma más clara los resultados, se han realizado 16 análisis en los que en cada uno varía únicamente el TIEMPO\_H

## 4.2 Resultados

Los resultados obtenidos de los 48 escenarios están recogidos en el Anexo B, en las diferentes tablas. A la izquierda de cada tabla encontraremos los parámetros utilizados en cada escenario, y a continuación a su derecha, una columna indicando el Order Rate posterior y otra columna indicando el Order Rate anterior de los 4 nodos existentes en la cadena serial. Se han realizado 10 simulaciones con semillas distintas que afectan a la variabilidad de la demanda. Además, a la derecha de esta tabla podemos encontrar una columna que indica la cantidad de veces que el Nivel de Servicio desciende el 100% (*NNS*). La última fila de todas las columnas hace referencia a la media de los 10 supuestos de cada ensayo.

## 4.3 Discusión de resultados

Tras la realización de los distintos ensayos hemos obtenido 48 datos referentes a las medias de 10 semillas distintas en cada ensayo.

En primer lugar, es notorio que los resultados obtenidos con una paralización del 50% y no del 100% reflejan un impacto nulo en la dinámica de la cadena de suministro. Con independencia de la variación entre los otros parámetros, los ensayos con  $H=0,5$  son todos similares con una media en bajadas del 100% de Nivel de Servicio cercana al 0. Esto se puede observar en la Ilustración 2. Es posible que la influencia de una ruptura sea nula, a pesar de encontrar resultados con una media en torno al 1, ya que la dinámica de la cadena y su aleatoriedad nos indican que en ocasiones puntuales pueda ser posible descender del 100%. Sin embargo, es posible realizar una distinción en base al *Lead Time* entre los ensayos con  $H=0,5$ . En estos casos encontramos que el *NNS* es siempre 0 si el *Lead Time* es 2, y variará entre 0 y 1 (de media) si es 4. En la Ilustración 2 podemos notar que existen 12 ensayos cuyo resultado es cero, y dichos ensayos corresponden con un *Lead Time* igual a 2. Así pues, podríamos asegurar que la dinámica de funcionamiento de la cadena garantiza que el Nivel de Servicio no baje del 100% cuando se trabaja con un *Lead Time* de 2 (dentro de los parámetros trabajados en los ensayos).

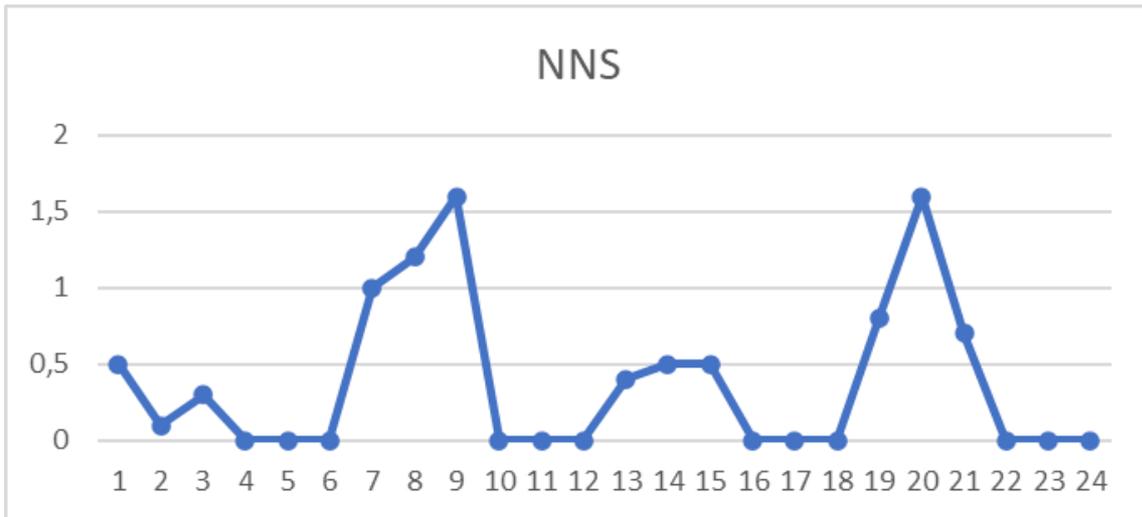


Ilustración 2. Resultados del NNS obtenido en los ensayos con parámetro  $H=0,5$ .

Como vemos, el *Lead Time* parece tener influencia en el NNS. Esta tendencia se corrobora cuando analizamos otros ejemplos en los que  $H=0$ , es decir, cuando se produce una paralización completa. Por ejemplo, comparando dos ensayos similares, en los que variamos únicamente el *Lead Time* (parámetros:  $H=0$ ,  $Z=2$ ,  $TIEMPO\_H=50$ ,  $M=14$ ,  $LD\_transporte=2$  o  $4$ ) nos damos cuenta de que el número de veces que el Nivel de Servicio desciende del 100% aumenta un 45 % (de 31,9 a 46,3 de media) cuando aumentamos el *Lead Time* de 2 a 4. Si esto ocurre durante un periodo de ruptura de 30, el NNS aumenta en menor medida, (un 25%, de 16,9 a 21,2 de media). En el caso de 10 periodos de ruptura el NNS pasa de 0 caídas 1,1 de media. Podemos apreciar esta incidencia tan alta entre el *Lead Time* y el “*Ripple effect*” en todos los ensayos realizados, como muestra la Ilustración 3. Por tanto, trabajar con *Lead Times* bajos es clave para combatir la propagación de una ruptura en las cadenas de suministro, y debe ser una prioridad para los gestores de la cadena.

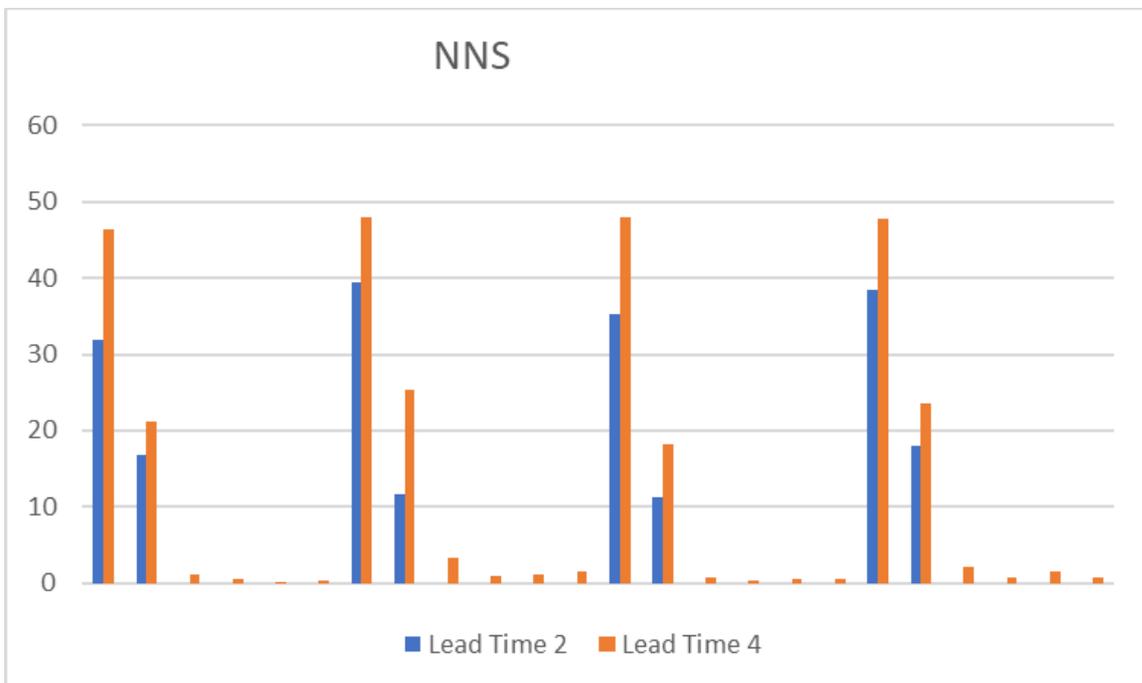


Ilustración 3. Resultados del NNS obtenido en ensayos con *Lead Time 2* y *Lead Time 4*

Por otro lado, es notoria también la disminución del NNS a medida que disminuimos el período de ruptura. Por ejemplo, en un ensayo con los parámetros:  $H=0$ ,  $Z=2$ ,  $M=14$ ,  $LD\_transporte=2$  en el que variamos el

$TIEMPO\_H$  entre los valores 50, 30 y 10, podemos encontrar que el  $NNS$  desciende de 39,5 a 11,6 y finalmente 0, respectivamente. Esta tendencia está presente en todos los ensayos realizados, excluyendo aquellos en los que la paralización no es completa ( $H=0,5$ ), como podemos ver en la Ilustración 4. Recordamos que los ensayos con  $H=0,5$  no indican una variación en la dinámica de la cadena a consecuencia de una ruptura, por tanto, los resultados no reflejan una relación existente entre el  $NNS$  y el  $TIEMPO\_H$ . Así pues, reducir el tiempo de paralización de la fábrica, como por ejemplo incrementando la mano de obra para una pronta reparación en caso de avería, resultaría en un “*Ripple effect*” menos perjudicial para la cadena.

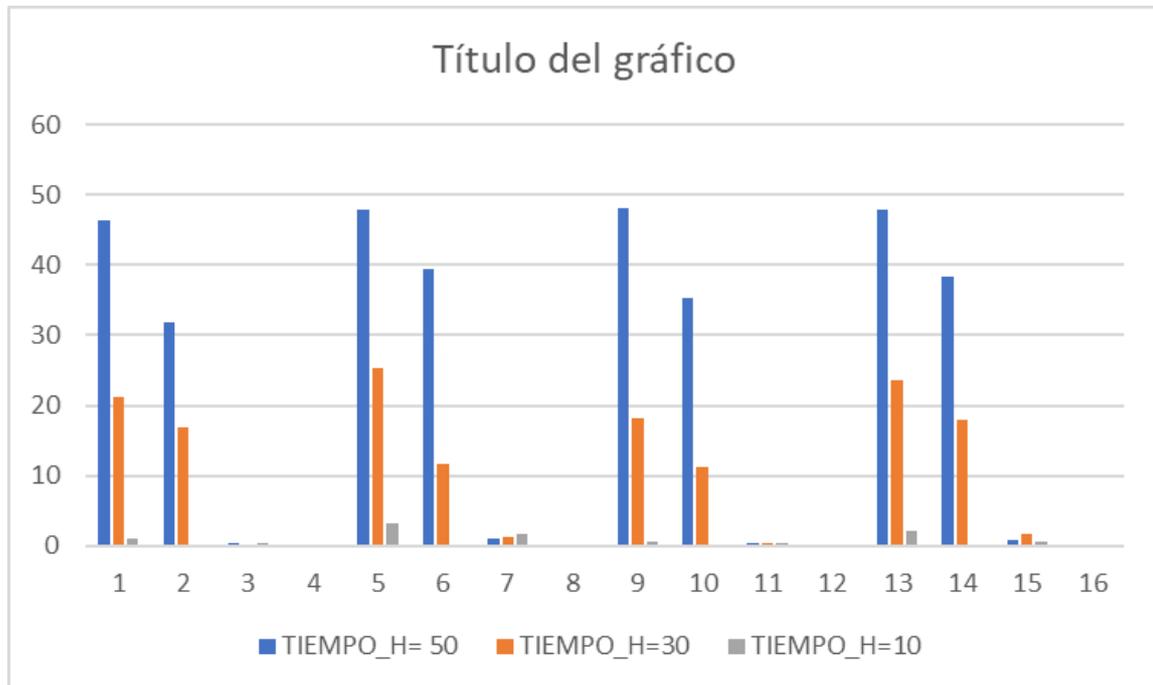


Ilustración 4. Resultados del NNS obtenido en los ensayos con  $TIEMPO\_H=50, 30$  Y  $10$

Además, de la Ilustración 4 es posible apreciar otra tendencia común en todos los ensayos, si el *Lead Time* es 2 y el tiempo de paralización es de 10 periodos, no se nota influencia en la cadena. Así pues, siguiendo la tendencia anterior podemos deducir que los ensayos con periodos de ruptura inferiores a 10 tampoco reflejarían la influencia del “*Ripple effect*”.

Por otro lado, si comparamos resultados variando únicamente el parámetro  $M$  no se encuentra relación alguna con el  $NNS$ . Se han obtenido resultados con un  $NNS$  menor, en algunos casos y con un  $NNS$  mayor, en otros. Además, las variaciones son poco significativas, por lo que se ha considerado, a priori, nula la capacidad de mejora del “*Ripple effect*” del parámetro  $M$ .

Por último, es importante destacar que con el parámetro  $Z$  sucede algo similar, no es posible encontrar una relación con el número de veces que el nivel de servicio desciende del 100%.

Para el análisis del “*Bullwhip Effect*” derivado del “*Ripple effect*” se ha utilizado la diferencia entre el Order Rate posterior a la ruptura y el Order Rate anterior. Cuanto mayor sea esta diferencia mayor será el “*Bullwhip effect*” generado derivado de una ruptura en la capacidad.

A primera vista, es fácil notar que la diferencia entre el Order Rate posterior y Order Rate anterior es más notoria cuanto más próximos estemos del último nodo, la fábrica. Por ejemplo, utilizando los parámetros:  $H=0, Z=2, TIEMPO\_H=50, M=14, LD\_transporte=2$ , encontramos que las diferencias en los Order Rate del minorista, mayorista, distribuidor y fábrica son 8,76, 6,2, 1,95 y 0,45, respectivamente. Podemos ver este ejemplo representado en la Ilustración 5.

Además, podemos notar que esta diferencia es más alta en tanto que el periodo de ruptura es más longevo, como puede apercibirse en la Ilustración 5.

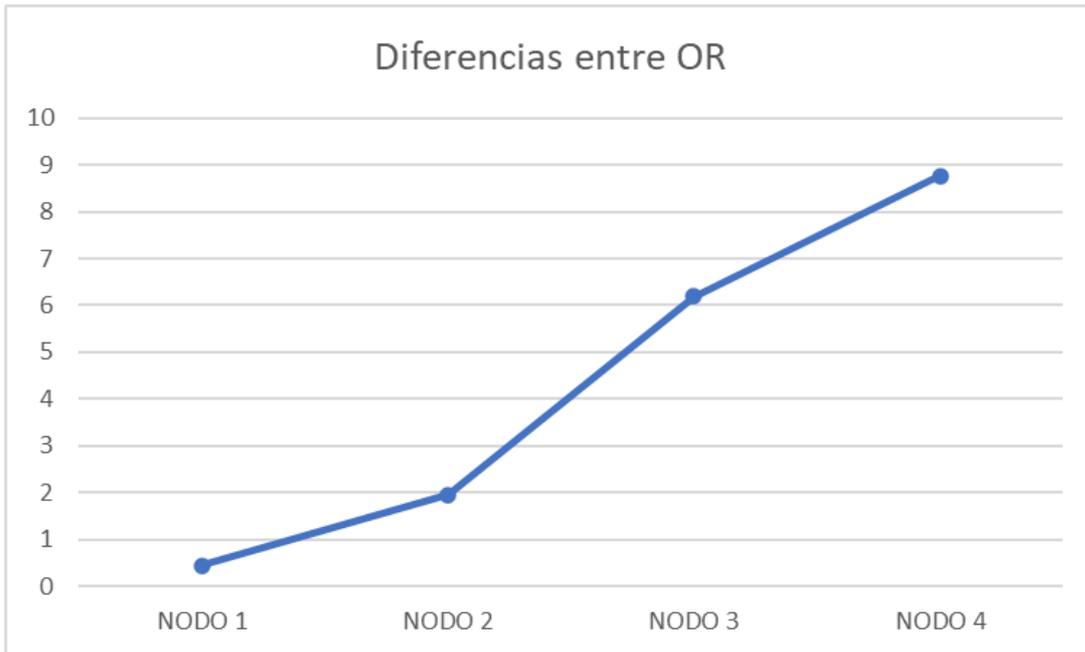


Ilustración 5. Diferencias entre el Order Rate posterior y anterior en el ensayo cuyos parámetros son:  $TIEMPO\_H=50, LD\_transansporte=2, H=0, M=14$  y  $Z=2$ .

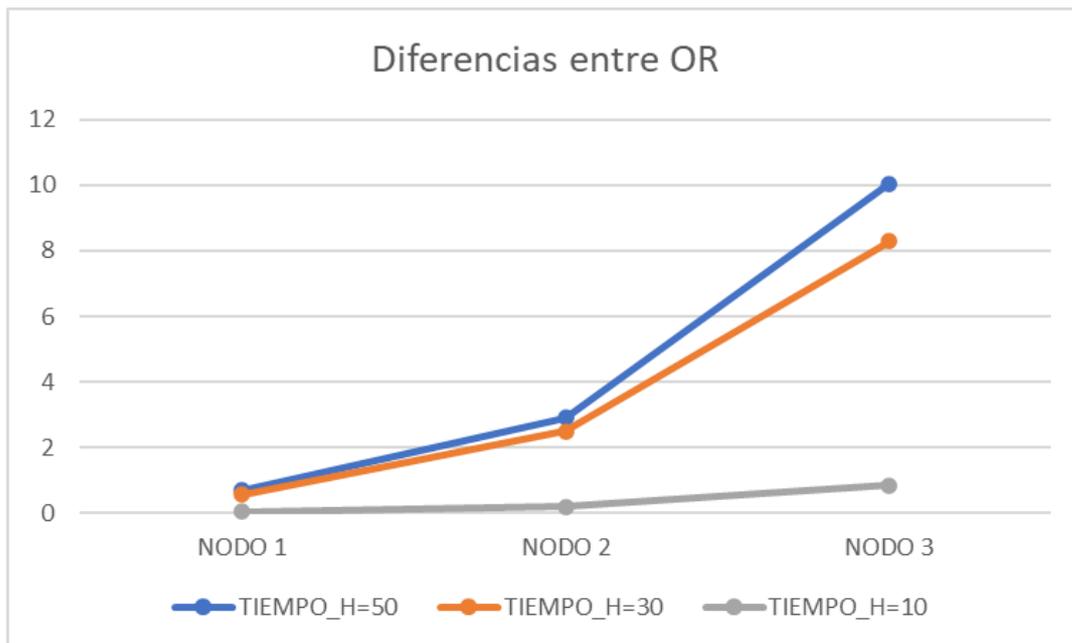


Ilustración 6 . Diferencias entre el Order Rate posterior y anterior en los ensayos realizados con  $TIEMPO\_H=50, 30$  Y  $10$ , y parámetros:  $LD\_transansporte=4, H=0, M=14$  y  $Z=1,5$ .

Así pues, tanto el “*Ripple effect*” como el “*Bullwhip effect*” generado aumentan a medida que la ruptura se mantiene durante más períodos. Es posible apreciar que la tendencia se repite en todos los casos ensayados en los que variamos el  $TIEMPO\_H$ , excluyendo los casos en los que la paralización no es completa. Si el “*Ripple effect*” no es notorio en los casos en los que la capacidad se reduce al 50%, el “*Bullwhip effect*” derivado tampoco.

Por otro lado, encontramos otro parámetro cuya variación repercute en el “*Bullwhip Effect*”, el parámetro  $M$ . Recordamos que este parámetro indicaba el número de períodos anteriores utilizados para el cálculo del *forecast* (media móvil) del *Lead Time* real. Encontramos que las diferencias entre los Order Rate posteriores y anteriores son mayores en caso en el que el parámetro  $M$  aumente. Podemos notar esta tendencia en la Ilustración 7. Por

tanto, mantener una  $M$  baja permite reducir el “*Ripple effect*” generado tras una ruptura.

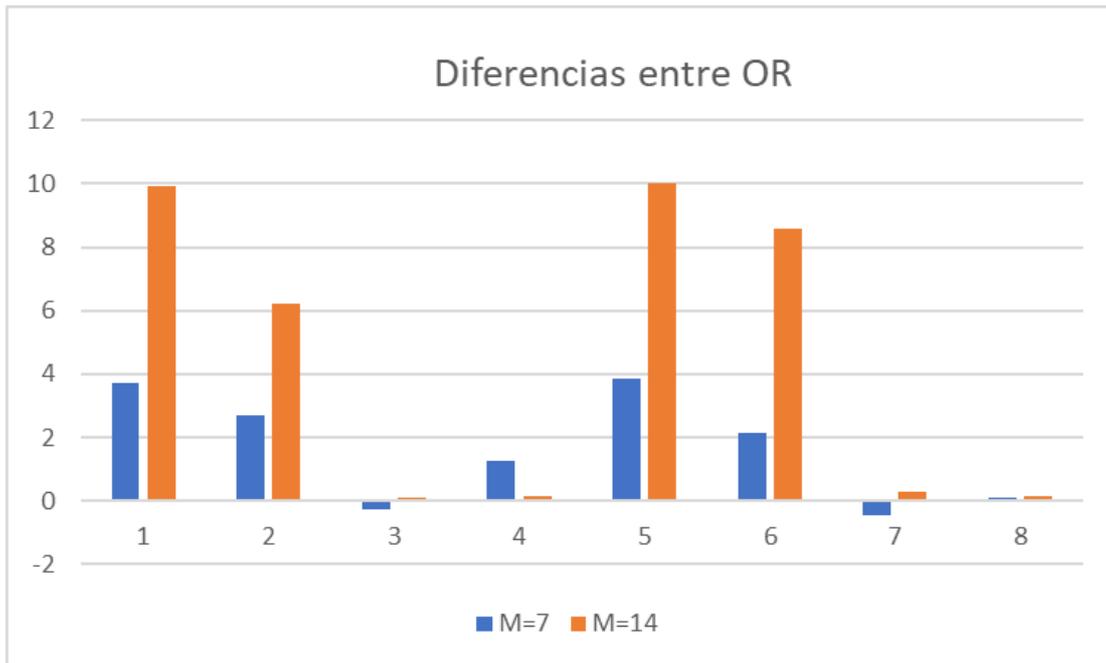


Ilustración 7. Diferencias entre el OR posterior y anterior en los ensayos realizados con  $M=7$  y  $14$ , en el nodo 3 y con  $TIEMPO_H=50$ .

Además, en contraste con lo que ocurría con el *NNS*, una disminución del *Lead Time* no implica una disminución de la diferencia entre Order Rates. Por tanto, el *Lead Time* no es un parámetro para tener en cuenta en caso de querer controlar el “*Bullwhip effect*” derivado de una ruptura.

Por otra parte, es importante destacar que el parámetro  $Z$ , que afectaba al cálculo del inventario de seguridad, no parece tener relación alguna con el “*Bullwhip effect*” derivado. Los resultados obtenidos en los casos en los que varía este parámetro son todos similares. Así pues, el parámetro  $Z$  no aporta datos interesantes para el control ni del “*Ripple effect*” (medido a través del *NNS*), ni del “*Bullwhip effect*” (medido a través de la diferencia entre Order Rates).

Finalmente, cabe añadir que tras evidencias encontradas en los resultados del Order Rate anterior y posterior a la ruptura podemos confirmar la existencia de un “*Bullwhip effect*” derivado, como ya adelantaban Dolgui e Ivanov.

En la **¡Error! No se encuentra el origen de la referencia.** Tabla 6 que encontramos a continuación, se resumen las relaciones encontradas tras los ensayos.

Fenómenos	“ <i>Ripple Effect</i> ”	“ <i>Bullwhip Effect</i> ” derivado
<b>Métrica</b>	<i>NNS</i> (Un mayor <i>NNS</i> implica un mayor “ <i>Ripple effect</i> ”)	Diferencia entre el Order Rate posterior y el Order Rate anterior (Una diferencia mayor implica un “ <i>Bullwhip effect</i> ” derivado mayor)
<b>Aumento del período de ruptura</b>	Aumento del <i>NNS</i>	Aumento de la diferencia
<b>Disminución del 50% de la capacidad</b>	No se producen cambios	No se producen cambios

---

<b>Aumento del Lead Time</b>	Aumento del <i>NVS</i>	No se producen cambios
<b>Aumento del parámetro M</b>	No se producen cambios	Aumento de la diferencia
<b>Aumento del parámetro Z</b>	No se producen cambios	No se producen cambios

---

Tabla 6. Resumen de resultados

# 5 CONCLUSIONES

---

Tras el desarrollo de un modelo capaz de simular una cadena serial de 4 escalones, hemos podido analizar los efectos en la cadena de una interrupción de la capacidad según los valores de los parámetros  $Z$ ,  $TIEMPO\_H$ ,  $LD\_transporte$ ,  $M$  y  $H$ . Para dicho análisis hemos utilizado dos métricas que miden el impacto del “Efecto cascada” y del “Efecto látigo” derivado del “Efecto cascada”: el  $NNS$  y la diferencia entre Order rates.

De los resultados obtenidos podemos concluir que el tiempo de paralización de la fábrica es un factor clave que ha de intentar reducirse para disminuir el impacto del “Efecto cascada” en la cadena. En otras palabras, durante un período de ruptura, los gestores de las cadenas deben centrarse en arreglar lo más pronto posible aquellos problemas que estén generando una paralización de la fábrica. Además del tiempo de ruptura, el tiempo de entrega de los productos es también un factor determinante para reducir el “Efecto cascada”. Las cadenas con tiempos de entrega o aprovisionamiento más bajos son más resistentes ante una ruptura.

Si el interés del gestor de la cadena está en controlar el impacto del “Efecto látigo” que se genera a causa del “Efecto cascada”, los parámetros clave son de nuevo el tiempo de ruptura (cuanto menos tiempo permanezca la fábrica afectada, el impacto será menos notorio) y la cantidad de períodos anteriores que se utilizan para hacer la previsión del tiempo de entrega real. Cuantos más períodos se utilicen, mayor será el impacto del “Efecto látigo” derivado. Es, por tanto, recomendable que la previsión del *Lead Time* se actualice con los datos cercanos al período actual, con el fin de que las variaciones en el período de entrega se tengan presentes lo antes posible.

En este capítulo se analizan las limitaciones del modelo creado y los ensayos realizados, y finalmente, se comentan algunas líneas futuras de investigación que pueden resultar interesantes para una continuación de este trabajo.

## 5.1 Limitaciones del modelo

En primer lugar, cabe destacar que el modelo creado representa un tipo muy concreto de cadena de suministro y los resultados obtenidos no se podrían generalizar para otras cadenas.

Por otro lado, es importante destacar que la diferencia entre Order Rates como medida del “*Bullwhip effect*” derivado de una ruptura puede no ser una buena métrica para medir su impacto. Es posible confirmar su existencia analizando las gráficas de pedidos y de inventario de los nodos, pero como veremos más adelante, el nodo 4 está condenado a una variabilidad diferente al resto y su comparación no es objetiva.

Si observamos la gráfica de pedidos de la Ilustración 8; **Error! No se encuentra el origen de la referencia.**, podemos apreciar como se produce un aumento en la cantidad de unidades de producto pedidas durante los primeros períodos de ruptura de la fábrica. Estas gráficas corresponden a un ensayo realizado con la demanda aleatoria y los parámetros:  $Z=2$ ,  $M=14$ ,  $LD\_transporte=4$ ,  $H=0$  y  $TIEMPO\_H=30$ .

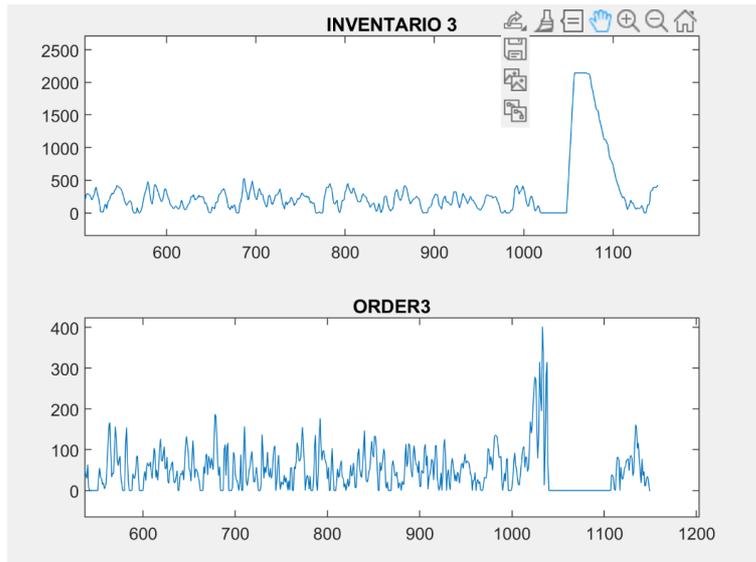


Ilustración 8. Gráficas del inventario y de los pedidos del nodo 3 (distribuidor)

Este aumento de pedidos que se produce durante el período de ruptura es consecuencia de una falta de coordinación entre nodos. Si el distribuidor no conoce la existencia de una ruptura, el forecast del lead time se irá recalculando, aumentando su valor y provocando que los pedidos se hagan de una mayor cantidad cada vez (Dolgui et al., 2020).

Así pues, tras la recuperación de la actividad en la fábrica, se producen envíos de cantidades inmensas desde la fábrica hasta el distribuidor, que desembocan en una acumulación de inventario en el nodo 3. Podemos apreciar como varía el inventario en la gráfica del inventario 3 de la **¡Error! No se encuentra el origen de la referencia..** Esto sucede en todos los nodos de la cadena, aunque en menor medida según nos acerquemos al primer escalón, el minorista.

Sin embargo, a pesar de poder confirmar la existencia del “*Bullwhip effect*” derivado, encontramos diferencias evidentes en las gráficas de pedidos de la fábrica y del distribuidor (nodos 4 y 3), Ilustración 9 Ilustración 9, que implican que el Order Rate posterior a la ruptura del nodo 4 presenta una variabilidad muy diferente al resto. Las gráficas de la Ilustración 9 corresponden a un ensayo realizado con la demanda aleatoria y los parámetros:  $Z=2$ ,  $M=14$ ,  $LD_{transporte}=4$ ,  $H=0$  y  $TIEMPO_H=30$ .

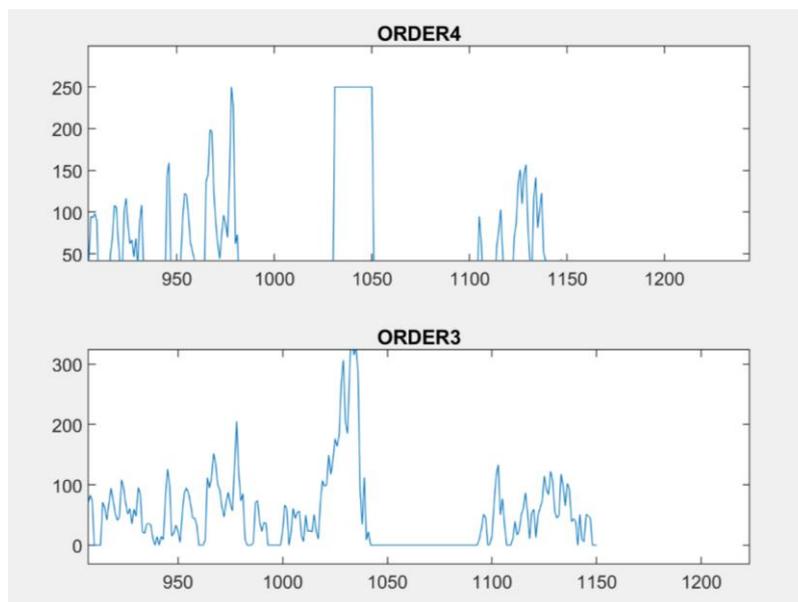


Ilustración 9. Gráfica de pedidos del nodo 4 (fábrica) y del nodo 3 (distribuidor)

El nodo 4 (la fábrica), responde a un caso muy particular puesto que está sujeto a realizar pedidos según la ecuación:

$$ORDER4(t) = \min(\max(0, S4(t) - INV4(t) + B4(t) - WIP4(t)), MC4)$$

Lo cual implica que, en el transcurso de la ruptura, la fábrica esté obligada a pedir  $MC4$  de unidades de producto, cuyo valor es 0 (o 0,5 según la simulación). Así pues, si comenzamos a medir la variabilidad de los pedidos en el mismo período que comienza la ruptura, los valores obtenidos no representarán la variabilidad del “*Bullwhip effect*”. Además, tras la ruptura, la fábrica pedirá como máximo la  $MC4$ , lo cual impedirá que se genere un “*Bullwhip effect*” comparable al generado en los nodos anteriores.

Por otro lado, los ensayos se han realizado eligiendo un valor arbitrario para su duración una vez comenzada la ruptura, 150 períodos adicionales a los 1000 ya existentes. Es decir, si la ruptura se ensaya con un valor de 50 períodos, se analizan 100 períodos más, a posteriori; si se ensaya con 30 se analizan 120 períodos, y así sucesivamente. El número de períodos analizados posteriores a la ruptura influye en el cálculo del Order Rate, que será más bajo en tanto que el sistema alcance antes la estabilidad propia del régimen permanente. Es por eso, que para un análisis más detallado sería necesario utilizar un tiempo posterior a la ruptura que englobe únicamente el régimen transitorio del sistema.

Otra limitación de nuestro modelo sería la métrica utilizada para el estudio del “Ripple Effect”. En este trabajo, no hemos usado una métrica capaz de medir la propagación como sí es capaz el Order Rate para el “Bullwhip Effect”, si no que hemos medido los efectos de esta propagación mediante el NNS.

Además, la utilización de algún análisis estadístico hubiera podido ayudar a sacar conclusiones con más detalle de los resultados.

Finalmente, cabe mencionar que se pueden realizar numerosos ensayos con este modelo, además de los realizados, y por tanto, resulta una herramienta muy útil para seguir analizando el “Ripple Effect” y sus fenómenos derivados.

## 5.2 Futuras líneas de investigación

Continuando con el final de la sección anterior, es posible realizar un gran número de ensayos adicionales con el modelo creado. Además, el uso de softwares estadísticos ayudaría a analizar de forma óptima los resultados.

Por otro lado, una investigación más exhaustiva de las métricas a utilizar para medir tanto el “Ripple Effect” como el “Bullwhip Effect” derivado resultarían muy útiles de cara al futuro. Podría comenzarse con el índice que proponen Dolgui et Al., (2020) para medir el “Bullwhip Effect” derivado de una ruptura.

Otra línea de investigación muy interesante sería conseguir aumentar la complejidad de la cadena para el estudio de otras cadenas y estructuras de cadenas. En este sentido sería muy útil la creación de un modelo capaz de modelar la dinámica de funcionamiento de cadenas a medida del investigador. Es decir, crear una herramienta capaz de originar cadenas de distintos tipos para su posterior análisis.

Además, no solo resulta interesante el estudio del “Ripple Effect”, si no también el estudio de la resistencia (robustez) de las cadenas ante rupturas y el estudio de la resiliencia (capacidad de recuperación).

Por otra parte, cabe mencionar que es posible el estudio del “Ripple Effect” utilizando otro tipo de herramientas que no son la simulación, como lo son la optimización matemática, la teoría de control...

Finalmente, una futura línea de interés sería el estudio de la implicación que tendría en las cadenas de suministro la Industria 4.0 tras una ruptura.



## REFERENCIAS Y BIBLIOGRAFÍA

---

- Behzadi, G., O'Sullivan, M. J., & Olsen, T. L. (2020). On Metrics for Supply Chain Resilience. *European Journal of Operational Research*.
- Dolgui, A., Ivanov, D., & Rozhkov, M. (2020). Does the ripple effect influence the bullwhip effect? An integrated analysis of structural and operational dynamics in the supply chain. *International Journal of Production Research*, 58(5), 1285-1301
- Dolgui, A., Ivanov, D., & Sokolov, B. (2018). Ripple effect in the supply chain: an analysis and recent literature. *International Journal of Production Research*, 56(1-2), 414-430.
- Forrester Jay, W. (1961). Industrial dynamics. *New York–London: Massachussets Institute of Technology and Jon Wiley and Sons*.
- Helmut Sy Corvo (2019). Capacidad de producción: tipos, cómo se calcula, ejemplos. Obtenido en <https://www.lifeder.com/capacidad-de-produccion/#:~:text=La%20capacidad%20de%20producci%C3%B3n%20es%20el%20rendimiento%20m%C3%A1ximo%20que%20se,empresa%20con%20los%20recursos%20disponibles.&text=No%20existe%20un%20t%C3%A9rmino%20tal,en%20cuenta%20los%20recursos%20disponibles>.
- Ivanov, D. (2017). Simulation-based ripple effect modelling in the supply chain. *International Journal of Production Research*, 55(7), 2083-2101.
- Ivanov, D., Dolgui, A., & Sokolov, B. (2015). Supply chain design with disruption considerations: Review of research streams on the ripple effect in the supply chain. *IFAC-PapersOnLine*, 48(3), 1700-1707.
- Ivanov, D., Dolgui, A., Sokolov, B., & Ivanova, M. (2017). Literature review on disruption recovery in the supply chain. *International Journal of Production Research*, 55(20), 6158-6174.
- Ivanov, D., Sokolov, B., & Pavlov, A. (2013). Dual problem formulation and its application to optimal redesign of an integrated production–distribution network with structure dynamics and ripple effect considerations. *International Journal of Production Research*, 51(18), 5386-5403.
- Lee, H. L., Padmanabhan, V., & Whang, S. (1997). Information distortion in a supply chain: The bullwhip effect. *Management science*, 43(4), 546-558.
- Lin, Y. K., Huang, C. F., Liao, Y. C., & Yeh, C. C. (2017). System reliability for a multistate intermodal logistics network with time windows. *International Journal of Production Research*, 55(7), 1957-1969.
- Nair, A., & Vidal, J. M. (2011). Supply network topology and robustness against disruptions-an investigation using multi-agent model. *International Journal of Production Research*, 49(5), 1391-1404.
- Palma, F., Saucedo, J. A., & Marmolejo, J. A. (2018, October). Recovery Method of Supply Chain Under Ripple Effect: Supply Chain Event Management (SCEM) Application. In *International Conference on Intelligent Computing & Optimization* (pp. 455-465). Springer, Cham.
- Roldán (2017). Cadena de suministro. Obtenido en <https://economipedia.com/definiciones/cadena-de-suministro.html>
- Snyder, L. V., & Daskin, M. S. (2005). Reliability models for facility location: the expected failure cost case. *Transportation Science*, 39(3), 400-416.
- Svensson, G. (2005). The multiple facets of the bullwhip effect: refined and re-defined. *International Journal of Physical Distribution & Logistics Management*.



# ANEXO A

---

## Códigos de la ventana principal:

```

TIEMPO=1000;
TIEMPO2=150;
replicas=10;
TIEMPO_H=30;
H=0;
LD_transporte=4;
Z=2;
M=14;
ANNS=zeros(replicas,1);
AOR1_a=zeros(replicas,1);
AOR2_a=zeros(replicas,1);
AOR3_a=zeros(replicas,1);
AOR4_a=zeros(replicas,1);
AOR1=zeros(replicas,1);
AOR2=zeros(replicas,1);
AOR3=zeros(replicas,1);
AOR4=zeros(replicas,1);
SOL=zeros(replicas,8);
for i=1:replicas
[ANNS(i),AOR1(i),AOR1_a(i),AOR2(i),AOR2_a(i),AOR3(i), AOR3_a(i), AOR4(i), AOR4_a(i)]
=modelobuenoLDmovil(TIEMPO, TIEMPO2,H, TIEMPO_H,LD_transporte,M,Z); end
SOL=[AOR1,AOR1_a,AOR2,AOR2_a,AOR3,AOR3_a,AOR4,AOR4_a];

```

## Códigos de la función:

```

function[NNS,OR1,OR1_a,OR2,OR2_a,OR3, OR3_a, OR4, OR4_a]=modelobuenoLDmovil(TIEMPO,
TIEMPO2,H, TIEMPO_H,LD_transporte,M,Z)
%TIEMPO+TIEMPO2
% TIEMPO=1000;
% TIEMPO2=150;
% H=0;

```

```

%M=14
% TIEMPO_H=50;
NNS=0;
% LD_transporte=4;
%VARIABLES BÁSICAS NODO 1 Y 2
    S1=zeros(TIEMPO+TIEMPO2,1); %STOCK DESEADO
    S2=zeros(TIEMPO+TIEMPO2,1);%STOCK DESEADO
    S3=zeros(TIEMPO+TIEMPO2,1); %STOCK DESEADO
    S4=zeros(TIEMPO+TIEMPO2,1); %STOCK DESEADO
    INV1=zeros(TIEMPO+TIEMPO2,1); %INVENTARIO 1
    INV2=zeros(TIEMPO+TIEMPO2,1);%INVENTARIO 2
    INV3=zeros(TIEMPO+TIEMPO2,1);%INVENTARIO 3
    INV4=zeros(TIEMPO+TIEMPO2,1);%INVENTARIO 4
    %MC1=180; %MAXIMA CAPACIDAD 1
    %MC2=600;%MAXIMA CAPACIDAD 2
    %MC3=600;%MAXIMA CAPACIDAD 3
    %MC4=600;%MAXIMA CAPACIDAD 4
    WIP1=zeros(TIEMPO+TIEMPO2,1); %INVENTARIO EN PROCESO 1
    WIP2=zeros(TIEMPO+TIEMPO2,1); %INVENTARIO EN PROCESO 2
    WIP3=zeros(TIEMPO+TIEMPO2,1); %INVENTARIO EN PROCESO 3
    WIP4=zeros(TIEMPO+TIEMPO2,1); %INVENTARIO EN PROCESO 4
    B1=zeros(TIEMPO+TIEMPO2,1); %BACKLOG 1
    B2=zeros(TIEMPO+TIEMPO2,1);%BACKLOG 2
    B3=zeros(TIEMPO+TIEMPO2,1);%BACKLOG 3
    B4=zeros(TIEMPO+TIEMPO2,1);%BACKLOG 4
    ORDER1=zeros(TIEMPO+TIEMPO2,1); %ORDER 1
    ORDER2=zeros(TIEMPO+TIEMPO2,1); %ORDER 2
    ORDER3=zeros(TIEMPO+TIEMPO2,1); %ORDER 3
    ORDER4=zeros(TIEMPO+TIEMPO2,1); %ORDER 4
    ENTREGA1=zeros(TIEMPO+TIEMPO2,1); %ENTREGA 1
    ENTREGA2=zeros(TIEMPO+TIEMPO2,1); %ENTREGA 2
    ENTREGA3=zeros(TIEMPO+TIEMPO2,1); %ENTREGA 3
    ENTREGA4=zeros(TIEMPO+TIEMPO2,1); %ENTREGA 3
    ENTREGA5=zeros(TIEMPO+TIEMPO2,1); %NODO 5 HIPOTÉTICO
%VARIABLES PARA EL CALCULO DEL LD MÓVIL
    %M=14
    m=0;

```

```

LD_aprox1=ones(TIEMPO+TIEMPO2,1)*4;
LD_aprox2=ones(TIEMPO+TIEMPO2,1)*4;
LD_aprox3=ones(TIEMPO+TIEMPO2,1)*4;
%LD_aprox4=cuatros(TIEMPO+TIEMPO2,1);
SUMLD1=zeros(TIEMPO+TIEMPO2,1);
SUMLD2=zeros(TIEMPO+TIEMPO2,1);
SUMLD3=zeros(TIEMPO+TIEMPO2,1);
%SUMLD4=zeros(TIEMPO+TIEMPO2,1);
LD_media1=ones(TIEMPO+TIEMPO2,1)*4;
LD_media2=ones(TIEMPO+TIEMPO2,1)*4;
LD_media3=ones(TIEMPO+TIEMPO2,1)*4;
LD_media4=ones(TIEMPO+TIEMPO2,1)*4;
entrega2=zeros(TIEMPO+TIEMPO2,1);
entrega3=zeros(TIEMPO+TIEMPO2,1);
entrega4=zeros(TIEMPO+TIEMPO2,1);
falta1=zeros(TIEMPO+TIEMPO2,1);
falta2=zeros(TIEMPO+TIEMPO2,1);
falta3=zeros(TIEMPO+TIEMPO2,1);
%falta4=zeros(TIEMPO+TIEMPO2,1);
% diferencia2=0;
% diferencia3=0;
% diferencia4=0;

%DEMANDA CLIENTES FINALES
%DEMANDA=DEMANDAFIJA;
DEMANDA=zeros(TIEMPO+TIEMPO2,1);
% "demand" es una variable que calcula en cada iteracion un número aleatorio
%siguiendo unas restricciones

%VARIABLES PARA EL CALCULO DE LA DEMANDA MEDIA Y VARIANZA DE LA MISMA
SUMDEMANDA1=zeros(TIEMPO+TIEMPO2,1); %Variable que acumula la suma de todas las demanda
para hacer posteriormente la media
SUMDEMANDA2=zeros(TIEMPO+TIEMPO2,1); %idem nodo 2
SUMDEMANDA3=zeros(TIEMPO+TIEMPO2,1); %idem nodo 3
SUMDEMANDA4=zeros(TIEMPO+TIEMPO2,1); %idem nodo 4
DEMANDAMEDIA1=zeros(TIEMPO+TIEMPO2,1); %demanda media nodo 1

```

```

DEMANDAMEDIA2=zeros(TIEMPO+TIEMPO2,1);%demanda media nodo 2
DEMANDAMEDIA3=zeros(TIEMPO+TIEMPO2,1);%demanda media nodo 3
DEMANDAMEDIA4=zeros(TIEMPO+TIEMPO2,1);%demanda media nodo 4
SUMVAR1=zeros(TIEMPO+TIEMPO2,1); %suma de las varianzas para hacer posteriormente la
media
SUMVAR2=zeros(TIEMPO+TIEMPO2,1); %suma de las varianzas para hacer posteriormente la media
SUMVAR3=zeros(TIEMPO+TIEMPO2,1); %suma de las varianzas para hacer posteriormente la media
SUMVAR4=zeros(TIEMPO+TIEMPO2,1); %suma de las varianzas para hacer posteriormente la media
VARMEDIA1=zeros(TIEMPO+TIEMPO2,1); %varianza media 1
VARMEDIA2=zeros(TIEMPO+TIEMPO2,1); %varianza media 2
VARMEDIA3=zeros(TIEMPO+TIEMPO2,1); %varianza media 3
VARMEDIA4=zeros(TIEMPO+TIEMPO2,1); %varianza media 4

%DATOS PARA EL MODELADO
%Z=2; %cte implicada en el calculo del stock deseado
R=1; %REVISION PERIOD
N=15; %PERIODO MEDIA MÓVIL
n=N; %variable usada para cuando tenemos menos de N datos para hacer la media
%LD=4; %LEAD TIME
NODOS=4; %numero de nodos
FC=5; %factor capacidad flag=0;
%VARIABLES PARA CALCULAR RATIOS
% NIVEL DE SERVICIO
NS=ones(TIEMPO+TIEMPO2,1)*404;
NS_suma=0;
entrega1=zeros(TIEMPO+TIEMPO2,1); %ENTREGA EN CADA PERIODO SIN CONTAR EL
BACKLOG ACUMULADO w=0; %Variable que cuenta el numero de veces que se puede calcular el
nivel de servicio (teninedo en cuenta tambn el warm up period)
WARM=300;

%NS_media: nivel de servicio medio
%WARMUP
%PERIODOS DE SIMULACION

%ORDER RATE
SUMORDER1=0; %variable acumulativa de orders para calcular la media
SUMORDER1_a=0;
SUMORDER2=0; %variable acumulativa de orders para calcular la media
SUMORDER2_a=0;

```

```
SUMORDER3=0; %variable acumulativa de orders para calcular la media
SUMORDER3_a=0;
SUMORDER4=0; %variable acumulativa de orders para calcular la media
SUMORDER4_a=0;

x1=0; % contador para calcular las veces que se deben usar datos para la
      %media
x1_a=0;
x2=0; % contador para calcular las veces que se deben usar datos para la
      %media (podía haber usado el valor de x1, pero para detectar errores lo dejo así,
independiente)
x2_a=0;
x3=0; % contador para calcular las veces que se deben usar datos para la media (podía haber usado el
valor de x1, pero para detectar errores lo dejo así, independiente)
x3_a=0;
x4=0; % contador para calcular las veces que se deben usar datos para la media (podía haber usado el
valor de x1, pero para detectar errores lo dejo así, independiente)
x4_a=0;
%MEDIAORDER1 media de pedidos 1
%MEDIAORDER2 media de pedidos 2
%MEDIAORDER3 media de pedidos 3
%MEDIAORDER4 media de pedidos 4
SUMVARORDER1=0; %variable acumulativa de la varianza de los pedidos 1 para el calculo de la
VARIANZA DE LOS PEDIDOS
SUMVARORDER1_a=0;
SUMVARORDER2=0; %variable acumulativa de la varianza de los pedidos 2 para
      %el calculo de la VARIANZA DE LOS PEDIDOS
SUMVARORDER2_a=0;
SUMVARORDER3=0; %variable acumulativa de la varianza de los pedidos 3 para
      %el calculo de la VARIANZA DE LOS PEDIDOS
SUMVARORDER3_a=0;
SUMVARORDER4=0; %variable acumulativa de la varianza de los pedidos 4
para el calculo de la VARIANZA DE LOS PEDIDOS
SUMVARORDER4_a=0;
%VARORDER1 varianza de pedidos 1
%VARORDER2 varianza de pedidos 2
%VARORDER3 varianza de pedidos 3
%VARORDER4 varianza de pedidos 4
%OR1: ORDER RATE 1
```

%OR2: ORDER RATE 2

%OR3: ORDER RATE 3

%OR4: ORDER RATE 4

SUMDEMANDA1\_T=0; %suma demanda media total 1

%DEMANDAMEDIA1\_T %DEMANDA MEDIA teniendo en cuenta todos los  
%datos ( a partir del warm up periods)

SUMDEMANDA1\_T\_a=0;

SUMVAR1\_T=0; %sumatorio calculo varianza total

%VAR1\_T: varianza de todos los datos de la demanda 1

SUMVAR1\_T\_a=0;

%INVENTARIO MEDIO

SUMINV1=0; %sumatorio necesario para el inventario medio 1

SUMINV2=0; %sumatorio necesario para el inventario medio 2

SUMINV3=0; %sumatorio necesario para el inventario medio 3

SUMINV4=0; %sumatorio necesario para el inventario medio 4

%INVMEDIO1

%INVMEDIO2

%INVMEDIO3

%INVMEDIO4

% s=rng; %sirve para fijar la semilla

% INV4(LD)=TIEMPO+TIEMPO2; %PARA REDUCIR EFECTO BULLWHIP EN EL WARM UP PERIOD

% INV1(LD)=400; %PARA REDUCIR EFECTO BULLWHIP EN EL WARM UP PERIOD

% INV3(LD)=600; %PARA REDUCIR EFECTO BULLWHIP EN EL WARM UP  
PERIOD % INV2(LD)=400; %PARA REDUCIR EFECTO BULLWHIP EN EL  
WARM UP PERIOD

for t=(LD\_transporte+1):TIEMPO+TIEMPO2



%NODO 1

%calculo demanda cliente

demand=max(0, normrnd(50,20));

DEMANDA(t)=round(demand,0);

```

%Medias Móviles Nodo 1
for i=1:N
    if t-i<(LD_transporte+1)
break
end
SUMDEMANDA1(t)=SUMDEMANDA1(t)+ DEMANDA(t-i);
SUMVAR1(t)=SUMVAR1(t)+(DEMANDA(t-i)-DEMANDAMEDIA1(t-i))^2;
%n=i;
end
DEMANDAMEDIA1(t)=SUMDEMANDA1(t)/n;
if n==1
    VARMEDIA1(t)=SUMVAR1(t)/n ;
else
    VARMEDIA1(t)=SUMVAR1(t)/(n-1);
end

%CALCULO MC1
MC1=10000000*FC;

%forecast LD_aprox
m=M;
for i=1:M
if (t-i<(LD_transporte+1))
break
end
if falta1(t-i)~=0
    LD_aprox1(t-i)=i+LD_transporte;
end
SUMLD1(t)=SUMLD1(t)+LD_aprox1(t-i);
m=i;
end
LD_media1(t)=SUMLD1(t)/m;
%Cálculo S para este periodo
S1(t)=(LD_media1(t)+R)*DEMANDAMEDIA1(t)+Z*sqrt((LD_media1(t)+R)*VARMEDIA1(t));
%OPCION 1
INV1(t)=INV1(t-1)+ENTREGA2(t-LD_transporte);
WIP1(t)=WIP1(t-1)-ENTREGA2(t-LD_transporte);
ENTREGA1(t)=min(INV1(t),DEMANDA(t)+B1(t-1));
entrega1(t)=max(0,ENTREGA1(t)-B1(t-1)); %me sirve para el NS

```

$$INV1(t)=INV1(t)-ENTREGA1(t);$$

$$B1(t)=B1(t-1)+DEMANDA(t)-ENTREGA1(t);$$

ORDER1(t)=min(max(0, S1(t)-INV1(t)+B1(t)-WIP1(t)), MC1); %S(t-1) porque es el calculado en el anterior periodo

$$WIP1(t)=WIP1(t)+ORDER1(t);$$

%CALCULOS PARA EL ORDER RATE (PEDIDOS MEDIOS) %anterior

if t<=TIEMPO

if t>WARM

x1\_a=x1\_a+1;

SUMORDER1\_a=SUMORDER1\_a+ORDER1(t);

end

end

%posterior

if t>TIEMPO

if t>WARM

x1=x1+1;

SUMORDER1=SUMORDER1+ORDER1(t);

end

end

%CALCULOS PARA EL ORDER RATE (DEMANDA MEDIA)%anterior

if t<=TIEMPO

if t>WARM

SUMDEMANDA1\_T\_a=SUMDEMANDA1\_T\_a+DEMANDA(t);

end

end

%POSTERIOR

if t>TIEMPO

if t>WARM

SUMDEMANDA1\_T=SUMDEMANDA1\_T+DEMANDA(t);

end

end

%CALCULOS PARA EL INVENTARIO MEDIO

if t>WARM

SUMINV1=SUMINV1+INV1(t);

end

```

%NIVEL DE SERVICIO

if t>WARM && DEMANDA(t)~=0
    NS(t)= entrega1(t)/DEMANDA(t);
end
        if NS(t)<1 && t> TIEMPO
            NNS=NNS+1;
end

%NODO2

        %ENTREGA3 es igual que ORDER2 porque supongo que este último nodo           %(2) tiene un
proveedor (3)con material infinito y le llega todo lo que pide

        %Primero llega el nuevo material y posteriormente se envía la entrega
        %Medias Móviles Nodo 2
for i=1:N
if (t-i<(LD_ transporte+1))
    break
end
        SUMDEMANDA2(t)=SUMDEMANDA2(t)+ ORDER1(t-i);
        SUMVAR2(t)=SUMVAR2(t)+(ORDER1(t-i)-DEMANDAMEDIA2(t-i))^2;
        %n=i;
        %tengo que tener en cuenta que N no puede
        %ser más grande que cuando empiezo a simular, por eso he puesto el
        %if

end

        DEMANDAMEDIA2(t)=SUMDEMANDA2(t)/n;
if n==1
        VARMEDIA2(t)=SUMVAR2(t)/n ;
else
        VARMEDIA2(t)=SUMVAR2(t)/(n-1);
end
    
```

```

        %CALCULO MC2
        MC2=1000000*FC;
        %forecast      LD_aprox
m=M;
for i=1:M
                if (t-i<(LD_transporte+1))
                        break
end
        if falta2(t-i)~=0
                LD_aprox2(t-i)=LD_transporte+i;
end
SUMLD2(t)=SUMLD2(t)+LD_aprox2(t-i);
        m=i;
end
                LD_media2(t)=SUMLD2(t)/m;

        %Cálculo S para este periodo

S2(t)=(LD_media2(t)+R)*DEMANDAMEDIA2(t)+Z*sqrt((LD_media2(t)+R)*VARMEDIA2(t));
        %OPCION 1
                INV2(t)=INV2(t-1)+ENTREGA3(t-LD_transporte);
                WIP2(t)=WIP2(t-1)-ENTREGA3(t-LD_transporte);
                ENTREGA2(t)=min(INV2(t),ORDER1(t)+B2(t-1));
                entrega2(t)=max(0,ENTREGA2(t)-B2(t-1));
falta1(t)=ORDER1(t)-entrega2(t);
        diferencia2=ENTREGA2(t)-entrega2(t);
if ENTREGA2(t)>entrega2(t)
        for i=1:(TIEMPO+TIEMPO2)
                if falta1(i)~=0
                        if diferencia2<falta1(i)
                                falta1(i)=falta1(i)-diferencia2;
                                        break
                        else
                                falta1(i)=0;
                                        diferencia2=diferencia2-falta1(i);
                                                LD_aprox1(i)=4+(t-i);
                                                        end

```

```

end
end
end

INV2(t)=INV2(t)-ENTREGA2(t);
B2(t)=B2(t-1)+ ORDER1(t)-ENTREGA2(t);
ORDER2(t)=min(max(0, S2(t)-INV2(t)+B2(t)-WIP2(t)), MC2);
WIP2(t)=WIP2(t)+ORDER2(t);

%CALCULOS NECESARIOS PARA ORDER RATE (MEDIA PEDIDOS)
if t<=TIEMPO
if t>WARM
x2_a=x2_a+1;
SUMORDER2_a=SUMORDER2_a+ORDER2(t);
end
end

%POSTERIOR
if t>TIEMPO
if t>WARM
x2=x2+1;
SUMORDER2=SUMORDER2+ORDER2(t);
end
end

%CALCULOS PARA EL INVENTARIO MEDIO
if t>WARM
SUMINV2=SUMINV2+INV2(t);
end

%NODO 3
%Medias Móviles Nodo 3
for i=1:N
if (t-i<(LD_transporte+1))
break
end
end

```

```

SUMDEMANDA3(t)=SUMDEMANDA3(t)+ ORDER2(t-i);
SUMVAR3(t)=SUMVAR3(t)+(ORDER2(t-i)-DEMANDAMEDIA3(t-i))^2;
% n=i;
    %tengo que tener en cuenta que N no puede
    %ser más grande que cuando empiezo a simular, por eso he puesto el
    %if
end
DEMANDAMEDIA3(t)=SUMDEMANDA3(t)/n;
if n==1
    VARMEDIA3(t)=SUMVAR3(t)/n ;
else
    VARMEDIA3(t)=SUMVAR3(t)/(n-1);
end

%CALCULO MC2
MC3=1000000*FC;

%forecast    LD_aprox
m=M;
for i=1:M
if (t-i<(LD_transporte+1))
    break
end
    if falta3(t-i)~=0
        LD_aprox3(t-i)=i+LD_transporte;
    end
SUMLD3(t)=SUMLD3(t)+LD_aprox3(t-i);
m=i;
end
LD_media3(t)=SUMLD3(t)/m;

%Cálculo S para este periodo
S3(t)=(LD_media3(t)+R)*DEMANDAMEDIA3(t)+Z*sqrt((LD_media3(t)+R)*VARMEDIA3(t));
% OPCION 1
    INV3(t)=INV3(t-1)+ENTREGA4(t-LD_transporte);
    WIP3(t)=WIP3(t-1)-ENTREGA4(t-LD_transporte);
    ENTREGA3(t)=min(INV3(t),ORDER2(t)+B3(t-1));
entrega3(t)=max(0,ENTREGA3(t)-B3(t-1));

```

```

falta2(t)=ORDER2(t)-entrega3(t);
diferencia3=ENTREGA3(t)-entrega3(t);
if ENTREGA3(t)>entrega3(t)
    for i=1:(TIEMPO+TIEMPO2)
if falta2(i)~=0
    if diferencia3<falta2(i)
falta2(i)=falta2(i)-diferencia3;
break
else
falta2(i)=0;
diferencia3=diferencia3-falta2(i);
LD_aprox2(i)=4+(t-i);
        end
        end
    end
end

    INV3(t)=INV3(t)-ENTREGA3(t);
    B3(t)=B3(t-1)+ ORDER2(t)-ENTREGA3(t);
    ORDER3(t)=min(max(0, S3(t)-INV3(t)+B3(t)-WIP3(t)), MC3);
    WIP3(t)=WIP3(t)+ORDER3(t);

    %CALCULOS NECESARIOS PARA ORDER RATE (MEDIA PEDIDOS)
if t<=TIEMPO
    if t>WARM
        x3_a=x3_a+1;
        SUMORDER3_a=SUMORDER3_a+ORDER3(t);
end
    end
    %POSTERIOR
    if t>TIEMPO
if t>WARM
    x3=x3+1;
        SUMORDER3=SUMORDER3+ORDER3(t);
        end
    end

    %CALCULOS PARA EL INVENTARIO MEDIO
if t>WARM

```

```

SUMINV3=SUMINV3+INV3(t);
end

%NODO 4

    %Medias Móviles Nodo 4
    for i=1:N
        if (t-i<(LD_transporte+1))
            break
        end

        SUMDEMANDA4(t)=SUMDEMANDA4(t)+ ORDER3(t-i);
        SUMVAR4(t)=SUMVAR4(t)+(ORDER3(t-i)-DEMANDAMEDIA4(t-i))^2;
        %n=i;
        %tengo que tener en cuenta que N no puede
        %ser más grande que cuando empiezo a simular, por eso he puesto el
        %if

    end

    DEMANDAMEDIA4(t)=SUMDEMANDA4(t)/n;
    if n==1
        VARMEDIA4(t)=SUMVAR4(t)/n ;
    else
        VARMEDIA4(t)=SUMVAR4(t)/(n-1);
    end

    %CALCULO MC2
    %MC4=50*FC;
    if t==TIEMPO
        flag=1;
    end
    if flag==1
        MC4=50*FC*H;
    end
    if t==TIEMPO+TIEMPO_H
        flag=0;
    end

```

```

end
else
MC4=50*FC;
end

    %Cálculo S para este periodo
S4(t)=(LD_media4(t)+R)*DEMANDAMEDIA4(t)+Z*sqrt((LD_media4(t)+R)*VARMEDIA4(t));
    % OPCION 1
INV4(t)=INV4(t-1)+ENTREGA5(t-LD_transporte);
WIP4(t)=WIP4(t-1)-ENTREGA5(t-LD_transporte);
ENTREGA4(t)=min(INV4(t),ORDER3(t)+B4(t-1));
entrega4(t)=max(0,ENTREGA4(t)-B4(t-1));
falta3(t)=ORDER3(t)-entrega4(t);
diferencia4=ENTREGA4(t)-entrega4(t);
if ENTREGA4(t)>entrega4(t)
    for i=1:(TIEMPO+TIEMPO2)
        if falta3(i)~=0
            if diferencia4<falta3(i)
                falta3(i)=falta3(i)-diferencia4;
                break
            else
                falta3(i)=0;
            diferencia4=diferencia4-falta3(i);
            LD_aprox3(i)=4+(t-i);
        end
    end
end
end

INV4(t)=INV4(t)-ENTREGA4(t);
B4(t)=B4(t-1)+ ORDER3(t)-ENTREGA4(t);
ORDER4(t)=min(max(0, S4(t)-INV4(t)+B4(t)-WIP4(t)), MC4);
WIP4(t)=WIP4(t)+ORDER4(t);

    %Nodo 5 hipotético
ENTREGA5(t)=ORDER4(t);
LD_media4(t)=LD_transporte; %no hace falta ponerlo pero lo pongo para acordarme

```

```

        %CALCULOS NECESARIOS PARA ORDER RATE (MEDIA PEDIDOS)
    if t<=TIEMPO
    if t>WARM
    x4_a=x4_a+1;
    SUMORDER4_a=SUMORDER4_a+ORDER4(t);
    end
    end
    %posterior
    if t>TIEMPO
    if t>WARM
    x4=x4+1;
    SUMORDER4=SUMORDER4+ORDER4(t);
    end
    end

        %CALCULOS PARA EL INVENTARIO MEDIO
    if t>WARM
        SUMINV4=SUMINV4+INV4(t);
    end
    end
    %rng(s); %sirve para fijar la semilla

    %GRAFICOS:

    % plot(DEMANDA);
    tiledlayout(2,1)
    % Top plot
    nexttile
    plot(INV3)
    title('INVENTARIO 3')
    % Bottom plot
    nexttile
    plot(ORDER3)
    title('ORDER3')

    %CALCULO NIVEL DE SERVICIO

    %NS_media= NS_suma/w;

```

```

%INVENTARIO MEDIO
INVMEDIO1=SUMINV1/x1;
INVMEDIO2=SUMINV2/x2;
INVMEDIO3=SUMINV3/x3;
INVMEDIO4=SUMINV4/x4; %ORDER RATE 1
%ANTERIOR
    %CALCULO MEDIA PEDIDOS Y DEMANDA
MEDIAORDER1_a=SUMORDER1_a/x1_a;
DEMANDAMEDIA1_T_a=SUMDEMANDA1_T_a/x1_a;
for i=WARM:TIEMPO
    SUMVARORDER1_a=SUMVARORDER1_a+(MEDIAORDER1_a-ORDER1(i))^2;
    SUMVAR1_T_a=SUMVAR1_T_a+(DEMANDAMEDIA1_T_a-DEMANDA(i))^2;
end
    %CALCULO VARIANZA PEDIDOS Y DEMANDA
    VARORDER1_a=SUMVARORDER1_a/x1_a;
    VAR1_T_a=SUMVAR1_T_a/x1_a;
    %ORDER RATE
    OR1_a=VARORDER1_a/VAR1_T_a;

%POSTERIOR
    %CALCULO MEDIA PEDIDOS Y DEMANDA
    MEDIAORDER1=SUMORDER1/x1;
    DEMANDAMEDIA1_T=SUMDEMANDA1_T/x1;

    for i=TIEMPO:(TIEMPO+TIEMPO2)
        SUMVARORDER1=SUMVARORDER1+(MEDIAORDER1-ORDER1(i))^2;
        SUMVAR1_T=SUMVAR1_T+(DEMANDAMEDIA1_T-DEMANDA(i))^2;
    end
    %CALCULO VARIANZA PEDIDOS Y DEMANDA
    VARORDER1=SUMVARORDER1/x1;
    VAR1_T=SUMVAR1_T/x1;

    %ORDER RATE

    OR1=VARORDER1/VAR1_T;

%ORDER RATE 2 %ANTERIOR

```

```

%CALCULO MEDIA PEDIDOS Y DEMANDA
MEDIAORDER2_a=SUMORDER2_a/x2_a;

for i=WARM:TIEMPO
SUMVARORDER2_a=SUMVARORDER2_a +(MEDIAORDER2_a-ORDER2(i))^2;
end

%CALCULO VARIANZA PEDIDOS Y DEMANDA
VARORDER2_a=SUMVARORDER2_a/x2_a;

%ORDER RATE

OR2_a=VARORDER2_a/VAR1_T_a;

%POSTERIOR

%CALCULO MEDIA PEDIDOS Y DEMANDA
MEDIAORDER2=SUMORDER2/x2;

for
i=TIEMPO:(TIEMPO+TIEMPO2)
SUMVARORDER2=SUMVARORDER2
+(MEDIAORDER2-ORDER2(i))^2;
end

%CALCULO VARIANZA PEDIDOS Y DEMANDA
VARORDER2=SUMVARORDER2/x2;

%ORDER RATE

OR2=VARORDER2/VAR1_T;

%ORDER RATE 3 ANTERIOR

%CALCULO MEDIA PEDIDOS Y DEMANDA
MEDIAORDER3_a=SUMORDER3_a/x3_a;

for i=WARM:TIEMPO
SUMVARORDER3_a=SUMVARORDER3_a+(MEDIAORDER3_a-ORDER3(i))^2;
end

%CALCULO VARIANZA PEDIDOS Y DEMANDA

```

```
VARORDER3_a=SUMVARORDER3_a/x3_a;
```

```
%ORDER RATE
```

```
OR3_a=VARORDER3_a/VAR1_T_a;
```

```
%POSTERIOR
```

```
%CALCULO MEDIA PEDIDOS Y DEMANDA
```

```
MEDIAORDER3=SUMORDER3/x3;
```

```
for i=TIEMPO:(TIEMPO+TIEMPO2)
```

```
SUMVARORDER3=SUMVARORDER3+(MEDIAORDER3-ORDER3(i))^2;
```

```
end
```

```
%CALCULO VARIANZA PEDIDOS Y DEMANDA
```

```
VARORDER3=SUMVARORDER3/x3;
```

```
%ORDER RATE
```

```
OR3=VARORDER3/VAR1_T;
```

```
%ORDER RATE 4 %ANTERIOR
```

```
%CALCULO MEDIA PEDIDOS Y  
DEMANDA
```

```
MEDIAORDER4_a=SUMORDER4_a/x4_a;
```

```
for i=WARM:TIEMPO
```

```
SUMVARORDER4_a=SUMVARORDER4_a+(MEDIAORDER4_a-ORDER4(i))^2;
```

```
end
```

```
%CALCULO VARIANZA PEDIDOS Y DEMANDA
```

```
VARORDER4_a=SUMVARORDER4_a/x4_a;
```

```
%ORDER RATE
```

```
OR4_a=VARORDER4_a/VAR1_T_a;
```

```
%POSTERIOR
```

```
%CALCULO MEDIA PEDIDOS Y
```

## DEMANDA

```
MEDIAORDER4=SUMORDER4/x4;      for
i=TIEMPO:(TIEMPO2+TIEMPO)
```

```
    SUMVARORDER4=SUMVARORDER4+(MEDIAORDER4-ORDER4(i))^2;
end
```

```
    %CALCULO VARIANZA PEDIDOS Y DEMANDA
```

```
VARORDER4=SUMVARORDER4/x4;
```

```
%ORDER RATE
```

```
OR4=VARORDER4/VAR1_T;
```

```
end
```

# ANEXO B

## Resultados obtenidos durante la simulación:

### ENSAYO 1

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	2,24	1,42	5,54	2,91	12,77	6,39	17,70	11,23	51
replicas	10	2,14	1,40	6,03	2,71	16,68	5,68	23,00	10,95	53
TIEMPO_H	50	2,14	1,23	6,77	2,11	23,05	4,20	22,75	8,23	50
H	0	2,45	1,34	5,56	2,42	16,17	4,61	19,65	8,40	50
LD transporte	4	1,85	1,33	4,02	2,41	12,18	5,03	18,96	10,33	40
Z	2	1,58	1,34	3,66	2,36	9,44	4,79	19,10	8,66	48
LD forecast (M)	14	1,96	1,36	5,34	2,54	13,87	5,24	20,36	10,46	42
		2,05	1,37	6,19	2,52	18,13	5,22	24,38	10,01	40
		2,32	1,29	5,31	2,23	14,69	4,53	17,32	9,13	44
		1,69	1,36	4,41	2,49	12,95	5,13	18,27	8,98	45
		2,04	1,35	5,28	2,47	14,99	5,08	20,15	9,64	46,30

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,73	1,25	4,42	2,32	11,06	5,04	20,56	10,04	19
replicas	10	2,07	1,37	4,74	2,50	10,36	5,07	18,93	9,93	11
TIEMPO_H	30	2,25	1,28	6,20	2,27	16,75	4,77	21,54	9,33	20
H	0	1,81	1,34	5,96	2,29	18,96	4,42	21,90	8,18	24
LD transporte	4	2,26	1,26	6,02	2,26	15,95	4,42	25,08	8,32	28
Z	2	2,09	1,25	5,50	2,06	16,09	4,07	22,22	8,10	19
LD forecast (M)	14	1,99	1,30	5,75	2,23	19,00	4,31	22,92	8,02	28
		2,38	1,31	7,17	2,32	22,43	4,68	20,21	8,56	24
		2,08	1,34	4,21	2,47	9,37	5,04	21,14	9,52	15
		2,38	1,37	6,16	2,48	18,71	5,12	21,20	9,15	24
		2,10	1,31	5,61	2,32	15,87	4,69	21,57	8,92	21,20

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,20	1,36	2,23	2,42	4,59	4,94	9,12	9,64	0
replicas	10	1,27	1,33	2,30	2,42	4,68	5,05	10,59	9,46	1
TIEMPO_H	10	1,32	1,38	2,21	1,99	4,24	3,91	9,29	7,16	0
H	0	1,43	1,31	2,80	2,37	6,03	4,75	13,62	9,07	5
LD transporte	4	1,20	1,25	2,22	2,23	4,12	4,67	7,03	8,77	0
Z	2	1,29	1,29	2,13	2,22	4,08	4,37	8,73	8,54	0
LD forecast (M)	14	1,24	1,30	2,03	2,32	3,91	4,67	7,68	8,70	0
		1,43	1,24	2,56	2,09	4,91	4,02	10,85	7,60	0
		1,38	1,30	2,80	2,12	6,72	3,77	16,31	7,10	4
		1,32	1,27	2,51	2,24	5,36	4,49	11,00	8,65	1
		1,31	1,28	2,38	2,24	4,86	4,46	10,42	8,47	1,10

### ENSAYO 2:

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,93	1,29	4,85	2,24	11,65	4,58	19,13	9,31	35
replicas	10	1,63	1,30	3,54	2,18	7,31	3,94	16,34	7,35	35
TIEMPO_H	50	1,87	1,34	4,13	2,40	10,67	4,45	19,78	8,11	41
H	0	1,73	1,36	4,47	2,38	8,54	4,71	20,30	8,20	35
LD transporte	2	1,78	1,34	5,09	2,39	15,56	4,87	15,49	9,68	33
Z	2	2,16	1,24	5,36	2,08	14,43	3,92	17,05	7,23	20
LD forecast (M)	14	1,53	1,20	3,41	2,02	9,32	3,94	15,12	7,90	24
		1,91	1,31	4,94	2,26	13,51	4,50	19,22	9,26	40
		1,39	1,30	2,94	2,16	6,69	4,13	15,55	8,09	21
		1,61	1,35	3,30	2,38	8,02	4,66	13,64	8,83	35
		1,75	1,30	4,20	2,25	10,57	4,37	17,16	8,40	31,90

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,72	1,38	3,29	2,62	7,89	5,25	17,48	9,95	18
replicas	10	1,91	1,38	5,06	2,47	13,23	4,85	19,42	9,18	21
TIEMPO_H	30	1,19	1,37	2,27	2,66	4,63	5,78	13,09	11,33	7
H	0	1,76	1,32	5,16	2,44	12,21	5,05	20,45	9,37	19
LD transporte	2	1,63	1,35	4,08	2,49	9,47	5,18	16,20	9,61	17
Z	2	2,22	1,28	6,17	2,17	17,90	4,36	22,08	8,36	24
LD forecast (M)	14	2,04	1,44	5,93	2,72	17,30	5,72	23,23	10,85	13
		1,93	1,35	5,18	2,39	13,85	4,81	22,89	8,93	17
		1,80	1,29	3,81	2,13	9,23	3,97	16,87	7,59	18
		2,16	1,31	5,17	2,29	11,37	4,89	19,32	8,92	15
		1,84	1,35	4,61	2,44	11,71	4,99	19,10	9,41	16,90

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,27	1,31	2,25	2,19	4,26	4,14	8,86	8,40	0
replicas	10	1,28	1,42	2,32	2,48	4,81	4,75	10,75	9,21	0
TIEMPO_H	10	1,36	1,32	2,29	2,29	4,20	4,46	8,79	7,92	0
H	0	1,56	1,29	2,90	2,15	6,21	4,06	13,74	7,78	0
LD transporte	2	1,43	1,29	2,77	2,21	6,18	4,17	12,42	7,48	0
Z	2	1,31	1,35	2,18	2,30	3,55	4,37	5,80	8,36	0
LD forecast (M)	14	1,28	1,21	2,06	2,00	3,39	3,79	6,86	7,22	0
		1,34	1,29	2,38	2,24	4,84	4,29	11,16	7,77	0
		1,27	1,30	2,32	2,37	4,93	4,81	11,93	9,97	0
		1,13	1,33	1,84	2,35	3,38	4,56	7,84	8,58	0
		1,32	1,31	2,33	2,26	4,57	4,34	9,81	8,27	0,00

**ENSAYO 3:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,31	1,32	2,51	2,29	5,46	4,51	9,12	8,70	2
replicas	10	1,13	1,31	1,65	2,29	2,95	4,57	5,53	9,45	0
TIEMPO_H	50	1,42	1,24	2,88	2,15	6,88	4,26	9,78	8,16	2
H	0,5	1,34	1,21	2,39	2,05	4,93	4,04	9,56	8,08	1
LD transporte	4	1,16	1,29	1,99	2,23	3,97	4,29	6,09	8,37	0
Z	2	1,20	1,31	2,16	2,48	4,47	5,39	6,90	10,19	0
LD forecast (M)	14	1,28	1,27	2,25	2,11	4,41	3,97	7,97	7,17	0
		1,29	1,35	2,15	2,41	4,13	4,69	8,19	8,33	0
		1,18	1,29	2,07	2,28	3,90	4,66	5,90	9,36	0
		1,40	1,29	2,49	2,25	4,92	4,41	8,80	8,43	0
		1,27	1,29	2,26	2,26	4,60	4,48	7,78	8,62	0,50

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,29	1,41	2,43	2,69	5,50	5,87	9,94	11,98	0
replicas	10	1,16	1,42	1,99	2,92	4,02	6,41	7,39	11,24	0
TIEMPO_H	30	1,38	1,40	2,80	2,71	6,14	5,68	11,78	10,95	0
H	0,5	1,34	1,23	2,63	2,11	5,50	4,19	8,71	8,20	1
LD transporte	4	1,22	1,34	1,92	2,42	3,31	4,62	5,79	8,41	0
Z	2	1,35	1,33	2,25	2,41	4,00	5,03	6,56	10,31	0
LD forecast (M)	14	1,21	1,34	2,07	2,36	4,12	4,80	8,23	8,66	0
		1,20	1,36	1,97	2,53	4,09	5,23	8,66	10,44	0
		1,28	1,37	2,28	2,52	4,09	5,20	6,51	10,00	0
		1,31	1,29	2,18	2,23	3,83	4,54	7,05	9,14	0
		1,27	1,35	2,25	2,49	4,46	5,16	8,06	9,93	0,10

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,15	1,36	1,61	2,49	2,66	5,15	4,58	8,98	0
replicas	10	1,23	1,28	2,00	2,30	3,93	4,68	7,32	9,35	0
TIEMPO_H	10	1,54	1,40	3,32	2,65	8,95	5,33	11,60	9,75	3
H	0,5	1,23	1,34	2,03	2,37	3,98	4,69	7,90	8,91	0
LD transporte	4	1,38	1,33	2,34	2,35	4,82	4,84	9,80	8,94	0
Z	2	1,31	1,38	2,31	2,57	4,79	5,19	9,65	9,84	0
LD forecast (M)	14	1,18	1,33	2,04	2,45	4,47	5,24	9,99	9,98	0
		1,35	1,37	2,39	2,41	4,60	4,66	8,10	8,97	0
		1,28	1,34	2,40	2,55	4,78	5,52	9,79	10,97	0
		1,18	1,29	2,05	2,26	4,19	4,32	8,57	8,09	0
		1,28	1,34	2,25	2,44	4,72	4,96	8,73	9,38	0,30

**ENSAYO 4:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,28	1,37	2,30	2,44	4,68	4,65	8,18	8,88	0
replicas	10	1,16	1,20	1,72	2,00	2,90	3,85	4,89	7,54	0
TIEMPO_H	50	1,41	1,35	2,70	2,35	5,20	4,47	9,76	8,20	0
H	0,5	1,47	1,34	2,78	2,39	5,64	4,74	9,35	9,74	0
LD transporte	2	1,16	1,32	1,96	2,28	3,86	4,20	7,19	7,92	0
Z	2	1,37	1,33	2,37	2,34	4,53	4,65	8,22	8,92	0
LD forecast (M)	14	1,23	1,29	2,11	2,09	3,69	3,90	6,34	7,41	0
		1,37	1,33	2,38	2,36	4,74	4,64	7,83	9,11	0
		1,43	1,25	2,66	2,01	5,07	3,62	7,83	6,86	0
		1,24	1,27	1,95	2,05	3,77	3,83	6,99	7,05	0
		1,31	1,30	2,29	2,23	4,41	4,25	7,66	8,16	0,00

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,28	1,32	2,12	2,47	3,96	5,05	7,60	9,51	0
replicas	10	1,30	1,33	2,04	2,30	3,63	4,51	5,58	9,16	0
TIEMPO_H	30	1,25	1,34	1,97	2,30	3,51	4,61	6,75	8,91	0
H	0,5	1,37	1,34	2,57	2,33	4,96	4,61	9,00	8,42	0
LD transporte	2	1,25	1,29	2,30	2,26	4,88	4,51	9,59	8,39	0
Z	2	1,26	1,27	2,00	2,14	3,59	4,09	5,89	7,73	0
LD forecast (M)	14	1,23	1,34	2,08	2,27	4,04	4,60	7,71	9,17	0
		1,37	1,24	2,41	2,03	4,31	3,72	7,17	7,20	0
		1,34	1,30	2,28	2,31	4,23	4,40	6,74	8,36	0
		1,28	1,31	2,07	2,22	3,75	4,28	7,30	8,34	0
		1,29	1,31	2,18	2,26	4,08	4,44	7,33	8,52	0,00

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,28	1,40	2,29	2,54	4,90	5,30	10,72	10,81	0
replicas	10	1,14	1,38	1,91	2,70	3,74	5,76	6,87	10,08	0
TIEMPO_H	10	1,40	1,36	2,76	2,45	5,90	5,00	10,92	9,67	0
H	0,5	1,32	1,22	2,50	1,99	5,14	3,77	9,92	7,36	0
LD transporte	2	1,19	1,33	1,88	2,34	3,29	4,40	5,98	7,93	0
Z	2	1,34	1,33	2,29	2,31	4,10	4,51	7,64	9,34	0
LD forecast (M)	14	1,24	1,33	2,13	2,25	4,05	4,34	8,00	7,95	0
		1,23	1,36	2,03	2,41	3,80	4,81	8,08	9,51	0
		1,24	1,34	2,07	2,32	3,53	4,56	6,18	9,08	0
		1,38	1,30	2,38	2,19	4,19	4,24	7,70	8,52	0
		1,28	1,34	2,22	2,35	4,26	4,67	8,20	9,03	0,00



**ENSAYO 7:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,34	1,22	2,32	2,12	4,72	4,18	7,29	8,11	0
replicas	10	1,28	1,33	2,15	2,38	3,91	4,74	6,09	9,04	1
TIEMPO_H	50	1,34	1,29	2,72	2,28	5,95	4,53	9,51	8,36	4
H	0,5	1,33	1,17	2,19	1,92	4,06	3,60	6,69	6,41	0
LD transporte	4	1,17	1,29	1,96	2,26	3,72	4,39	6,47	8,21	0
Z	1,5	1,32	1,21	2,63	2,11	5,92	4,14	11,18	7,47	2
LD forecast (M)	14	1,30	1,28	2,17	2,17	4,01	4,22	7,11	8,00	0
		1,21	1,29	1,88	2,30	3,65	4,57	6,72	8,38	1
		1,35	1,21	2,39	2,02	4,36	3,86	7,23	7,14	0
		1,30	1,26	2,27	2,06	4,46	3,75	8,19	6,80	2
		1,29	1,25	2,27	2,16	4,48	4,20	7,65	7,79	1,00

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,32	1,22	2,45	2,10	5,22	4,15	8,77	7,86	4
replicas	10	1,36	1,28	2,36	2,19	4,26	4,22	7,03	7,74	0
TIEMPO_H	30	1,27	1,22	2,07	2,21	3,88	4,48	7,13	8,51	0
H	0,5	1,27	1,38	2,24	2,67	5,02	5,51	9,39	9,82	7
LD transporte	4	1,30	1,25	2,24	2,01	4,17	3,63	6,90	6,74	0
Z	1,5	1,18	1,33	1,76	2,35	3,15	4,54	5,78	7,95	0
LD forecast (M)	14	1,23	1,27	1,93	2,31	3,72	4,67	7,10	8,83	0
		1,26	1,35	2,00	2,47	3,46	5,03	5,56	9,16	0
		1,30	1,34	2,65	2,35	5,85	4,71	1,18	8,95	1
		1,18	1,22	1,96	2,08	3,75	4,01	6,34	7,38	0
		1,27	1,29	2,17	2,27	4,25	4,50	6,52	8,29	1,20

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,38	1,24	2,72	2,11	5,67	3,99	10,71	7,47	2
replicas	10	1,34	1,31	2,60	2,34	5,66	4,64	10,91	8,95	9
TIEMPO_H	10	1,27	1,24	2,37	2,18	4,98	4,31	9,71	8,07	0
H	0,5	1,21	1,27	1,96	2,24	3,90	4,35	7,40	7,98	0
LD transporte	4	1,12	1,37	1,79	2,44	3,38	4,74	6,73	8,76	0
Z	1,5	1,23	1,35	2,05	2,45	3,85	4,78	6,62	9,08	1
LD forecast (M)	14	1,44	1,28	2,86	2,20	6,13	4,08	11,08	7,35	2
		1,23	1,32	2,17	2,43	4,47	5,06	8,33	9,60	0
		1,34	1,24	2,44	2,06	5,06	3,87	9,55	7,26	1
		1,34	1,22	2,48	1,98	4,97	3,79	8,72	7,14	1
		1,29	1,29	2,34	2,24	4,81	4,36	8,98	8,17	1,60

**ENSAYO 8:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,28	1,21	2,11	1,94	4,08	3,61	7,62	7,09	0
replicas	10	1,33	1,30	2,34	2,21	4,85	4,21	9,76	7,75	0
TIEMPO_H	50	1,24	1,32	1,95	2,20	3,58	4,00	5,58	7,23	0
H	0,5	1,28	1,26	2,20	2,16	4,32	4,28	7,08	8,01	0
LD transporte	2	1,23	1,27	2,06	2,14	3,66	4,01	6,58	7,46	0
Z	1,5	1,26	1,29	2,00	2,21	3,66	4,14	5,98	7,45	0
LD forecast (M)	14	1,40	1,26	2,48	2,04	4,60	3,80	7,79	7,23	0
		1,36	1,35	2,59	2,32	5,13	4,44	10,09	8,70	0
		1,40	1,29	2,43	2,09	4,64	3,78	6,06	6,97	0
		1,05	1,27	1,53	2,02	2,62	3,56	4,54	6,46	0
		1,28	1,28	2,17	2,13	4,11	3,98	7,11	7,44	0,00

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,26	1,24	2,02	2,02	3,81	3,77	7,42	6,82	0
replicas	10	1,29	1,18	2,10	1,86	3,70	3,25	7,03	5,66	0
TIEMPO_H	30	1,21	1,22	1,96	1,96	3,94	3,53	7,66	6,55	0
H	0,5	1,12	1,30	1,76	2,15	3,07	3,86	5,21	7,09	0
LD transporte	2	1,24	1,24	1,90	2,11	3,43	4,07	6,48	7,81	0
Z	1,5	1,14	1,25	1,80	2,02	3,30	3,50	5,76	6,61	0
LD forecast (M)	14	1,24	1,25	1,96	2,04	3,47	3,67	6,11	6,99	0
		1,37	1,28	2,45	2,14	4,50	3,83	7,89	6,97	0
		1,09	1,34	1,86	2,27	3,68	4,20	7,41	7,65	0
		1,14	1,20	1,61	1,98	2,75	3,71	5,01	7,04	0
		1,21	1,25	1,94	2,05	3,56	3,74	6,60	6,92	0,00

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,20	1,27	2,15	2,13	4,12	3,95	6,73	7,24	0
replicas	10	1,39	1,20	2,35	1,90	4,26	3,40	7,40	6,47	0
TIEMPO_H	10	1,24	1,24	1,98	2,03	3,63	3,75	6,67	6,80	0
H	0,5	1,13	1,27	1,67	2,11	2,96	3,96	5,84	7,67	0
LD transporte	2	1,37	1,24	2,44	2,10	4,73	4,12	8,66	8,01	0
Z	1,5	1,32	1,26	2,25	2,10	4,07	3,99	7,21	7,61	0
LD forecast (M)	14	1,30	1,23	2,21	2,05	4,42	3,91	8,39	7,47	0
		1,11	1,19	1,54	1,89	2,58	3,39	4,68	6,14	0
		1,52	1,19	3,00	1,85	6,13	3,31	12,01	6,08	0
		1,16	1,33	1,86	2,29	3,40	4,20	5,97	7,81	0
		1,27	1,24	2,14	2,04	4,03	3,80	7,36	7,13	0,00

**ENSAYO 9:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,61	1,32	3,30	2,42	7,30	5,13	15,04	9,58	44
replicas	10	1,64	1,27	3,27	2,37	6,37	5,15	16,67	9,91	55
TIEMPO_H	50	1,95	1,25	4,79	2,24	11,97	4,63	20,44	8,90	61
H	0	1,51	1,32	3,73	2,42	9,11	4,99	15,80	9,51	42
LD_transport	4	1,80	1,40	3,75	2,71	7,55	5,68	21,69	11,36	52
Z	2	1,63	1,35	3,74	2,43	8,03	4,96	17,99	9,83	54
LD forecast (	7	1,86	1,25	4,06	2,23	9,59	4,66	16,86	8,59	46
		1,70	1,31	3,11	2,35	6,95	4,89	16,55	9,00	45
		2,07	1,41	5,22	2,60	14,10	5,42	17,50	10,18	49
		1,51	1,40	3,28	2,59	7,18	5,65	15,38	10,94	32
		1,73	1,33	3,83	2,44	8,82	5,12	17,39	9,78	48,00

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,81	1,31	3,87	2,28	8,60	4,44	18,16	7,88	24
replicas	10	1,55	1,26	3,51	2,19	9,62	4,33	16,63	8,68	18
TIEMPO_H	30	1,80	1,26	4,58	2,26	10,87	4,62	17,70	8,89	29
H	0	1,42	1,36	2,99	2,68	6,69	5,77	13,52	10,87	14
LD_transport	4	1,80	1,29	3,39	2,38	7,27	5,34	12,11	10,47	6
Z	2	2,06	1,32	4,95	2,44	12,18	4,81	21,52	9,27	26
LD forecast (	7	1,62	1,36	3,55	2,61	7,08	5,69	16,02	10,95	12
		1,52	1,32	3,06	2,42	6,43	5,08	15,02	9,93	19
		1,98	1,34	4,95	2,42	13,04	5,15	22,85	10,07	19
		1,67	1,40	4,02	2,62	10,19	5,53	15,66	10,40	14
		1,72	1,32	3,89	2,43	9,20	5,08	16,92	9,74	18,10

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,34	1,45	2,71	2,83	5,78	6,18	16,01	11,45	2
replicas	10	1,42	1,22	2,93	2,19	6,86	4,66	14,20	9,18	1
TIEMPO_H	10	1,10	1,29	1,78	2,26	3,42	4,57	8,43	8,88	0
H	0	1,19	1,40	2,04	2,62	4,23	5,68	10,72	10,61	0
LD_transport	4	1,21	1,31	2,09	2,32	4,22	4,68	8,35	8,73	0
Z	2	1,43	1,24	2,64	2,11	6,34	4,28	15,73	8,42	2
LD forecast (	7	1,29	1,35	2,71	2,36	6,26	4,61	13,47	8,47	0
		1,33	1,40	2,49	2,69	5,72	5,80	11,90	11,26	0
		1,45	1,38	3,01	2,67	5,89	5,86	12,67	10,20	2
		1,39	1,33	2,59	2,46	5,69	5,25	12,15	10,22	0
		1,31	1,34	2,50	2,45	5,44	5,16	12,36	9,74	0,70

**ENSAYO 10:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,75	1,35	3,05	2,37	5,84	4,72	16,62	8,94	36
replicas	10	1,78	1,35	3,84	2,47	7,07	5,02	18,56	10,36	40
TIEMPO_H	50	1,50	1,28	3,46	2,13	8,17	4,04	16,38	7,90	46
H	0	1,62	1,36	2,73	2,39	5,74	4,71	14,19	9,15	30
LD_transport	2	1,58	1,32	3,35	2,22	7,33	4,13	17,36	7,74	40
Z	2	1,57	1,26	2,72	2,18	6,45	4,27	16,01	8,69	22
LD forecast (	7	1,63	1,31	2,91	2,33	5,82	4,81	14,71	9,51	36
		1,76	1,32	3,73	2,26	10,55	4,32	18,73	8,33	31
		1,44	1,31	2,98	2,25	6,11	4,42	18,09	8,60	39
		1,90	1,30	3,71	2,22	8,48	4,21	17,78	8,20	33
		1,65	1,32	3,25	2,28	7,16	4,46	16,84	8,74	35,30

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,69	1,31	3,55	2,18	7,07	4,00	15,13	7,66	10
replicas	10	1,41	1,22	2,62	1,98	5,58	3,67	12,93	6,93	15
TIEMPO_H	30	1,39	1,29	2,39	2,22	4,65	4,33	12,21	8,46	3
H	0	1,64	1,29	3,00	2,26	6,12	4,52	14,77	8,98	18
LD_transport	2	1,50	1,35	2,57	2,38	4,36	4,64	14,49	9,21	3
Z	2	1,66	1,34	3,16	2,30	6,83	4,46	15,94	8,94	12
LD forecast (	7	1,49	1,30	2,94	2,24	6,34	4,29	17,99	8,40	18
		1,41	1,29	2,65	2,15	5,18	3,94	15,92	7,64	8
		1,64	1,34	3,26	2,34	6,10	4,73	16,66	8,86	14
		1,36	1,28	2,62	2,26	4,93	4,41	14,68	8,88	12
		1,52	1,30	2,88	2,23	5,72	4,30	15,07	8,40	11,30

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,27	1,36	2,12	2,40	4,24	4,58	10,56	8,98	0
replicas	10	1,13	1,32	1,78	2,28	3,15	4,36	6,24	8,64	0
TIEMPO_H	10	1,25	1,28	2,12	2,23	4,30	4,30	9,68	8,69	0
H	0	1,22	1,28	2,12	2,08	3,99	3,84	8,65	7,36	0
LD_transport	2	1,28	1,30	2,25	2,32	4,21	4,51	10,57	8,49	0
Z	2	1,05	1,31	1,73	2,31	3,60	4,53	8,87	8,49	0
LD forecast (	7	1,38	1,26	2,53	2,33	5,03	4,68	12,83	9,27	0
		1,30	1,26	2,28	2,08	4,57	4,00	9,14	7,93	0
		1,26	1,33	2,02	2,39	3,40	4,87	6,54	9,61	0
		1,33	1,30	2,11	2,23	4,15	4,32	9,73	8,31	0
		1,25	1,30	2,11	2,26	4,06	4,40	9,28	8,58	0,00

**ENSAYO 11:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,42	1,39	2,62	2,54	5,99	5,45	7,53	9,76	1
replicas	10	1,31	1,31	2,32	2,39	4,93	4,91	7,36	9,73	0
TIEMPO_H	50	1,63	1,33	3,63	2,50	10,31	5,17	10,88	10,16	2
H	0,5	1,34	1,29	2,24	2,20	4,20	4,34	6,67	8,40	0
LD_transport	4	1,31	1,30	2,14	2,31	3,99	4,74	6,85	8,35	0
Z	2	1,36	1,32	2,31	2,44	4,44	5,32	7,08	10,71	0
LD forecast (	7	1,15	1,40	1,71	2,59	3,05	5,35	5,63	10,57	1
		1,25	1,21	2,07	2,12	3,98	4,53	7,41	8,73	0
		1,18	1,32	1,96	2,64	3,61	6,16	5,92	12,32	0
		1,31	1,37	2,22	2,52	4,08	5,36	7,17	10,66	0
		1,33	1,32	2,32	2,43	4,86	5,13	7,25	9,94	0,40
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,26	1,29	2,14	2,25	4,06	4,54	6,51	8,77	0
replicas	10	1,52	1,29	3,01	2,27	6,81	4,52	14,44	8,55	0
TIEMPO_H	30	1,42	1,26	2,69	2,20	5,23	4,61	9,94	9,44	0
H	0,5	1,28	1,38	2,36	2,78	5,05	6,14	9,26	12,10	0
LD_transport	4	1,49	1,32	3,18	2,24	8,32	4,41	12,44	8,74	4
Z	2	1,31	1,34	2,62	2,36	5,55	4,82	10,85	9,02	0
LD forecast (	7	1,28	1,24	2,22	2,12	5,12	4,28	9,23	8,63	0
		1,49	1,33	2,75	2,40	5,23	4,97	7,72	9,34	1
		1,30	1,58	2,55	3,35	5,70	8,06	9,71	12,36	0
		1,33	1,37	2,36	2,61	5,00	5,81	8,88	10,51	0
		1,37	1,34	2,59	2,46	5,61	5,22	9,90	9,75	0,50
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,15	1,33	1,76	2,35	3,29	4,79	6,37	9,25	0
replicas	10	1,35	1,47	2,56	2,85	5,48	6,01	9,74	10,58	0
TIEMPO_H	10	1,30	1,30	2,70	2,51	7,16	5,59	11,82	11,15	2
H	0,5	1,16	1,29	1,96	2,42	3,60	5,13	6,90	10,26	0
LD_transport	4	1,29	1,27	2,57	2,16	6,21	4,29	12,12	8,54	0
Z	2	1,21	1,31	2,10	2,37	4,09	4,94	7,55	9,36	0
LD forecast (	7	1,38	1,25	2,72	2,20	6,19	4,39	13,02	8,36	0
		1,26	1,34	2,36	2,55	5,55	5,26	10,11	9,92	1
		1,51	1,36	3,14	2,63	7,28	5,64	14,95	10,92	2
		1,33	1,27	2,19	2,23	4,08	4,79	7,31	9,53	0
		1,29	1,32	2,41	2,43	5,29	5,08	9,99	9,79	0,50

**ENSAYO 12:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,47	1,29	2,79	2,12	5,86	4,00	9,68	8,13	0
replicas	10	1,28	1,32	2,17	2,29	4,23	4,31	7,89	8,06	0
TIEMPO_H	50	1,17	1,23	1,94	2,06	3,62	3,95	7,19	7,92	0
H	0,5	1,41	1,32	2,53	2,20	5,30	4,25	9,12	8,57	0
LD_transport	2	1,24	1,29	1,95	2,02	3,48	3,77	6,19	7,34	0
Z	2	1,33	1,27	2,40	2,11	4,83	4,01	8,36	7,62	0
LD forecast (	7	1,29	1,25	1,94	2,19	3,46	4,35	5,41	8,31	0
		1,34	1,29	2,55	2,21	5,40	4,25	9,62	8,21	0
		1,34	1,30	2,30	2,32	4,55	4,64	7,57	8,95	0
		1,25	1,31	2,04	2,21	3,76	4,26	6,86	8,12	0
		1,31	1,29	2,26	2,17	4,45	4,18	7,79	8,12	0,00
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,36	1,25	2,50	2,18	5,22	4,34	10,36	9,00	0
replicas	10	1,16	1,24	1,96	2,15	3,74	4,09	6,73	7,81	0
TIEMPO_H	30	1,30	1,31	2,10	2,28	3,69	4,40	6,03	7,88	0
H	0,5	1,33	1,33	2,35	2,31	4,82	4,60	8,24	9,22	0
LD_transport	2	1,34	1,27	2,21	2,15	4,36	4,11	8,34	7,72	0
Z	2	1,20	1,23	1,87	2,14	3,05	4,23	5,14	8,85	0
LD forecast (	7	1,28	1,32	2,06	2,35	3,83	4,78	6,13	8,92	0
		1,29	1,26	2,05	2,10	3,62	3,92	6,81	7,54	0
		1,29	1,23	2,23	2,06	4,04	4,07	6,49	8,43	0
		1,27	1,33	2,05	2,27	3,90	4,16	8,28	7,82	0
		1,28	1,28	2,14	2,20	4,03	4,27	7,26	8,32	0,00
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,20	1,31	2,13	2,34	4,17	4,41	6,99	8,28	0
replicas	10	1,29	1,25	2,20	2,19	4,60	4,35	9,90	8,63	0
TIEMPO_H	10	1,31	1,36	2,27	2,27	4,49	4,23	9,19	8,38	0
H	0,5	1,30	1,31	2,35	2,32	4,67	4,60	8,74	8,56	0
LD_transport	2	1,19	1,30	1,83	2,26	3,14	4,45	5,75	8,95	0
Z	2	1,25	1,31	2,08	2,27	3,83	4,42	6,83	8,53	0
LD forecast (	7	1,32	1,22	2,26	2,03	4,18	3,88	7,50	7,58	0
		1,51	1,28	2,83	2,21	5,75	4,23	11,14	8,06	0
		1,30	1,29	2,30	2,14	4,51	4,15	8,56	8,29	0
		1,44	1,34	2,28	2,34	4,09	4,42	7,55	8,24	0
		1,31	1,30	2,25	2,24	4,34	4,32	8,22	8,35	0,00

**ENSAYO 13:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,82	1,30	3,43	2,48	7,31	5,37	15,20	9,40	49
replicas	10	1,61	1,18	2,98	1,98	6,13	4,14	17,54	8,30	45
TIEMPO_H	50	1,94	1,34	3,54	2,42	7,21	4,93	15,12	9,14	49
H	0	2,15	1,24	5,77	2,19	11,17	4,37	24,04	8,27	55
LD_transport	4	1,59	1,22	4,15	2,03	10,28	3,82	21,04	7,00	52
Z	1,5	2,01	1,27	4,62	2,42	11,12	5,34	19,92	10,53	50
LD_forecast (	7	1,64	1,32	3,80	2,57	8,95	5,69	19,72	10,66	57
		1,56	1,24	3,23	2,10	8,03	4,28	16,67	8,15	36
		1,34	1,22	2,80	1,96	6,10	3,53	16,55	6,18	32
		1,68	1,36	3,88	2,54	8,92	5,20	20,81	9,50	53
		1,74	1,27	3,82	2,27	8,52	4,67	18,66	8,71	47,80
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,87	1,29	5,62	2,63	15,57	6,13	23,26	9,79	29
replicas	10	1,67	1,38	3,67	2,57	7,83	5,35	14,22	9,99	30
TIEMPO_H	30	1,25	1,19	2,05	2,07	3,40	4,19	11,53	7,99	22
H	0	1,67	1,33	3,88	2,38	7,94	4,78	19,21	8,43	27
LD_transport	4	1,72	1,32	4,48	2,56	11,26	5,49	20,48	10,44	23
Z	1,5	1,50	1,30	3,10	2,35	6,73	4,66	16,05	8,40	16
LD_forecast (	7	1,48	1,33	2,99	2,63	6,85	5,79	15,76	10,79	24
		1,57	1,26	3,31	2,09	7,54	3,94	14,10	7,37	22
		1,94	1,33	5,01	2,43	14,77	5,03	20,04	9,76	20
		1,76	1,23	3,79	2,01	8,17	3,92	18,23	7,34	23
		1,64	1,30	3,79	2,37	9,01	4,93	17,29	9,03	23,60
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,31	1,23	2,17	2,03	4,17	3,89	9,81	7,04	0
replicas	10	1,39	1,28	2,89	2,40	6,19	5,15	13,03	9,76	5
TIEMPO_H	10	1,39	1,29	2,07	2,37	3,99	5,05	9,65	9,37	6
H	0	1,37	1,32	2,50	2,50	4,86	5,58	11,15	10,79	3
LD_transport	4	1,21	1,35	2,08	2,48	3,91	5,13	9,00	9,22	0
Z	1,5	1,42	1,33	2,64	2,50	5,60	5,35	11,94	9,66	2
LD_forecast (	7	1,40	1,34	2,53	2,69	5,50	5,87	13,08	10,42	1
		1,37	1,41	2,70	2,84	6,46	5,98	13,10	10,81	0
		1,58	1,27	3,13	2,27	6,61	4,42	15,36	8,35	4
		1,26	1,38	1,96	2,70	3,23	6,00	5,53	11,58	0
		1,37	1,32	2,47	2,48	5,05	5,24	11,17	9,70	2,10

**ENSAYO 14:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,43	1,29	2,59	2,15	5,21	3,95	12,73	7,31	28
replicas	10	1,65	1,27	3,60	2,06	8,46	3,76	17,84	6,94	39
TIEMPO_H	50	1,32	1,28	2,22	2,12	4,05	4,01	12,74	7,75	38
H	0	1,69	1,21	3,70	1,98	8,60	3,66	17,38	6,78	39
LD_transport	2	1,61	1,18	2,76	1,87	5,50	3,42	17,39	6,47	42
Z	1,5	1,40	1,26	2,73	2,06	5,46	3,73	15,30	6,92	36
LD_forecast (	7	1,47	1,24	2,80	2,13	5,70	4,12	18,50	7,95	47
		1,54	1,22	2,66	1,93	5,61	3,41	15,54	6,03	45
		1,64	1,28	3,19	2,14	6,00	3,85	15,91	6,74	35
		1,19	1,24	2,14	2,04	4,38	3,84	13,62	7,25	35
		1,49	1,25	2,84	2,05	5,90	3,77	15,69	7,01	38,40
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,46	1,25	2,58	2,02	4,96	3,62	12,05	6,67	15
replicas	10	1,34	1,31	2,63	2,14	5,07	3,92	11,55	7,27	18
TIEMPO_H	30	1,42	1,30	2,67	2,22	5,67	4,26	13,79	8,24	26
H	0	1,33	1,30	2,18	2,27	4,46	4,52	12,12	8,74	18
LD_transport	2	1,37	1,26	2,46	2,11	4,23	3,87	12,25	7,15	13
Z	1,5	1,48	1,21	2,71	1,95	5,30	3,45	13,82	6,37	16
LD_forecast (	7	1,53	1,23	3,00	2,05	6,90	3,87	16,07	7,46	17
		1,50	1,32	2,54	2,25	4,59	4,24	12,89	7,85	12
		1,55	1,34	2,91	2,24	5,41	4,05	12,80	7,49	24
		1,55	1,26	2,97	2,14	6,00	4,13	14,34	7,95	21
		1,45	1,28	2,67	2,14	5,26	3,99	13,17	7,52	18,00
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,30	1,27	2,13	2,16	3,97	4,05	9,80	7,50	0
replicas	10	1,26	1,30	2,13	2,19	4,01	4,07	7,35	7,61	0
TIEMPO_H	10	1,24	1,28	2,23	2,08	4,11	3,76	10,46	7,12	0
H	0	1,21	1,31	1,93	2,17	3,88	3,89	8,25	7,10	0
LD_transport	2	1,16	1,28	1,95	2,19	3,75	4,15	9,99	7,64	0
Z	1,5	1,24	1,24	2,04	2,01	3,54	3,70	9,02	6,73	0
LD_forecast (	7	1,37	1,26	2,39	2,07	4,62	3,89	8,64	7,26	0
		1,32	1,20	2,68	1,92	5,18	3,53	12,15	6,59	0
		1,22	1,26	2,18	2,06	4,22	3,72	9,71	7,06	0
		1,18	1,27	2,15	2,10	4,49	3,75	12,46	6,58	0
		1,25	1,27	2,18	2,10	4,18	3,85	9,78	7,12	0,00

**ENSAYO 15:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS	
TIEMPO2	150	1,08		1,26	1,82	2,06	4,15	3,84	6,74	6,88	0
replicas	10	1,18		1,36	2,10	2,58	4,38	5,56	8,19	10,79	0
TIEMPO_H	50	1,18		1,28	2,03	2,36	4,38	5,05	8,65	9,11	0
H	0,5	1,20		1,31	2,02	2,45	4,18	5,29	8,47	9,82	3
LD_transport	4	1,13		1,22	1,89	2,09	3,73	4,29	7,15	8,15	0
Z	1,5	1,42		1,30	2,48	2,41	4,86	5,07	9,10	8,76	0
LD forecast (	7	1,34		1,28	2,43	2,15	5,90	4,18	7,39	8,00	2
		1,30		1,37	2,22	2,47	4,08	5,07	6,24	9,32	0
		1,48		1,33	2,66	2,48	4,68	5,19	7,71	9,88	0
		1,24		1,30	1,89	2,43	3,41	5,00	4,83	9,40	3
		1,26		1,30	2,15	2,35	4,38	4,85	7,45	9,01	0,80
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS	
TIEMPO2	150	1,31		1,19	2,21	1,90	4,59	3,51	9,30	6,41	0
replicas	10	1,33		1,28	2,33	2,35	4,49	5,05	6,99	9,74	2
TIEMPO_H	30	1,32		1,39	2,18	2,59	4,33	5,38	8,47	10,28	1
H	0,5	1,32		1,21	2,35	2,08	4,78	4,39	9,19	8,53	1
LD_transport	4	1,40		1,23	3,12	2,16	7,82	4,33	15,21	8,10	5
Z	1,5	1,47		1,42	3,21	2,83	7,30	6,05	13,15	10,87	2
LD forecast (	7	1,46		1,30	2,99	2,30	6,91	4,48	12,30	8,15	4
		1,24		1,32	2,01	2,31	3,77	4,39	6,40	8,20	0
		1,27		1,27	2,40	2,21	5,76	4,36	11,19	8,15	0
		1,21		1,29	2,19	2,34	4,46	4,89	8,30	9,27	1
		1,33		1,29	2,50	2,31	5,42	4,68	10,05	8,77	1,60
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS	
TIEMPO2	150	1,32		1,33	2,31	2,31	4,57	4,65	8,31	8,71	1
replicas	10	1,27		1,29	2,42	2,34	5,80	4,74	10,50	8,91	0
TIEMPO_H	10	1,41		1,39	2,86	2,71	6,05	5,54	11,36	9,71	2
H	0,5	1,07		1,30	1,61	2,44	2,91	5,22	5,49	8,96	0
LD_transport	4	1,32		1,28	2,42	2,22	4,65	4,42	9,00	8,16	1
Z	1,5	1,34		1,34	2,36	2,54	4,66	5,33	8,40	10,16	1
LD forecast (	7	1,16		1,27	1,87	2,41	3,55	5,24	6,12	9,86	2
		1,33		1,27	2,41	2,26	4,83	4,47	8,10	8,40	0
		1,12		1,41	1,79	3,06	3,47	7,23	6,89	13,21	0
		1,19		1,28	1,79	2,34	3,43	4,66	5,76	8,57	0
		1,25		1,32	2,19	2,46	4,39	5,15	7,99	9,47	0,70

**ENSAYO 16:**

TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,27	1,24	2,08	2,11	4,00	4,02	7,61	7,82	0
replicas	10	1,13	1,28	1,77	2,09	3,34	3,87	6,23	7,55	0
TIEMPO_H	50	1,30	1,26	2,15	2,05	3,67	3,71	6,09	6,76	0
H	0,5	1,39	1,27	2,36	2,05	4,42	3,65	8,40	6,65	0
LD_transport	2	1,30	1,18	2,24	1,99	4,35	3,87	6,69	7,28	0
Z	1,5	1,33	1,22	2,28	1,94	4,12	3,48	7,03	6,64	0
LD forecast (	7	1,13	1,27	1,81	2,15	3,21	4,08	5,88	8,10	0
		1,22	1,23	1,96	2,10	3,53	4,08	5,45	7,96	0
		1,18	1,27	1,91	2,20	3,62	4,28	6,49	8,34	0
		1,34	1,31	2,24	2,29	4,37	4,44	6,57	8,22	0
		1,26	1,25	2,08	2,10	3,86	3,95	6,64	7,53	0,00
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,16	1,22	1,74	1,91	2,94	3,37	5,47	6,23	0
replicas	10	1,46	1,27	2,74	2,12	5,61	4,10	9,13	7,70	0
TIEMPO_H	30	1,22	1,18	2,15	1,90	4,29	3,57	6,88	6,77	0
H	0,5	1,11	1,25	1,69	2,06	2,91	3,87	5,05	7,43	0
LD_transport	2	1,25	1,30	1,91	2,17	3,19	4,04	5,75	7,57	0
Z	1,5	1,16	1,26	1,83	2,03	3,06	3,64	5,09	6,60	0
LD forecast (	7	1,28	1,24	2,06	2,03	3,80	3,74	6,12	6,92	0
		1,28	1,26	2,10	2,05	3,91	3,66	7,52	6,57	0
		1,21	1,26	2,01	2,12	3,83	3,93	7,10	7,56	0
		1,33	1,25	2,23	2,08	3,94	3,84	7,20	7,26	0
		1,25	1,25	2,05	2,05	3,75	3,78	6,53	7,06	0,00
TIEMPO	1000	OR1	OR1_A	OR2	OR2_A	OR3	OR3_A	OR4	OR4_A	NNS
TIEMPO2	150	1,19	1,28	1,88	2,16	3,08	4,10	5,43	7,63	0
replicas	10	1,35	1,17	2,27	1,86	4,18	3,42	7,67	6,42	0
TIEMPO_H	10	1,19	1,29	1,83	2,19	3,10	4,15	5,44	7,79	0
H	0,5	1,33	1,29	2,27	2,19	4,14	4,26	7,49	7,90	0
LD_transport	2	1,27	1,30	2,14	2,24	4,21	4,31	8,29	8,15	0
Z	1,5	1,32	1,22	2,23	1,94	4,31	3,51	7,75	6,61	0
LD forecast (	7	1,23	1,29	2,10	2,16	4,43	3,95	8,82	7,42	0
		1,25	1,26	2,04	2,02	3,71	3,68	6,58	6,52	0
		1,34	1,28	2,35	2,08	4,73	3,90	8,26	7,31	0
		1,18	1,29	2,07	2,09	3,80	3,94	6,80	7,76	0
		1,27	1,27	2,12	2,09	3,97	3,92	7,25	7,35	0,00