

## ENTREGA TESIS DE GRADO

### **MRP impulsado por la demanda mediante el análisis de series de tiempo y programación de enteros. Una aplicación de estudio de caso en la industria manufacturera de fragancias**

JORGE IVAN ROMERO GELVEZ Y EDISSON ALEXANDER DELGADO SIERRA

#### RESUMEN

El propósito de este trabajo es contribuir al uso de modelos híbridos para resolver MRP que tratan con una demanda estocástica sobre la existencia principal de unidades. La metodología del desarrollo inicialmente aplica el método de pronóstico estacional ARIMA para predecir la demanda del plan maestro de producción, después aplicamos un modelo de programación entero para resolver el MRP utilizando el enfoque de lote a lote (L4L). La contribución principal de este trabajo es mostrar una manera de resolver los problemas de demanda dinámica a través del enfoque SARIMA-MIP.

#### **PALABRAS CLAVES**

MRP; SARIMA; PRONOSTICOS; PROGRAMACION INTEGRAL

#### **1. INTRODUCCION**

En los años 60s el uso extendido de las computadoras en muchas compañías les permitió mejorar el complejo manejo de inventarios (Hopp and Spearman 2011). La adopción de nuevas tecnologías permitió a ORLICKI y otros en IBM desarrollar un plan de fabricación aproximada basada en una demanda independiente sobre artículos principales, y una demanda dependiente sobre los material o materia prima. El desarrollo y la adopción de planeación de requerimientos de material fue lento pero en 1972 la sociedad estadounidense de control de inventarios APICS empezó a implementar este modelo e inicio el MRP cruzado que continua en nuestro tiempo (Mabert 2007). El desarrollo temprano de MRP (hoy se conoce como “mrp pequeño” o MRP-I) se refiere a un modelo que proviene de un plan de producción y se centra en obtener los requerimientos óptimos para el mantenimiento del stock en la lista de materiales (también llamado BOM), (Voß y Woodru 2006). La mejora del MRP años después se llamó MRP-II pero las letras MRP en MRP-II significa que la planificación de recursos de fabricación deja en claro que los recursos son considerados adicionalmente a los materiales como en MRP. La palabra “recurso” se utiliza para enfatizar que algún tipo de capacidad productiva puede ser considerada, no solamente maquinas. En este trabajo nos vamos e enfocar solamente en el modelo de MRP-I, enfocarnos en los pronósticos de demandas y gestionar grandes conjuntos de datos para los números de componentes (SKU) en el portafolio de productos de la compañía.

## 2. REVISION DE LITERATURA

Esta sección describe los conceptos básicos de la planificación de requerimientos de material, planificación de requisitos de material impulsado por la demanda y técnicas de pronósticos necesarias para resolver el problema de demanda dinámica presente en el caso de estudio.

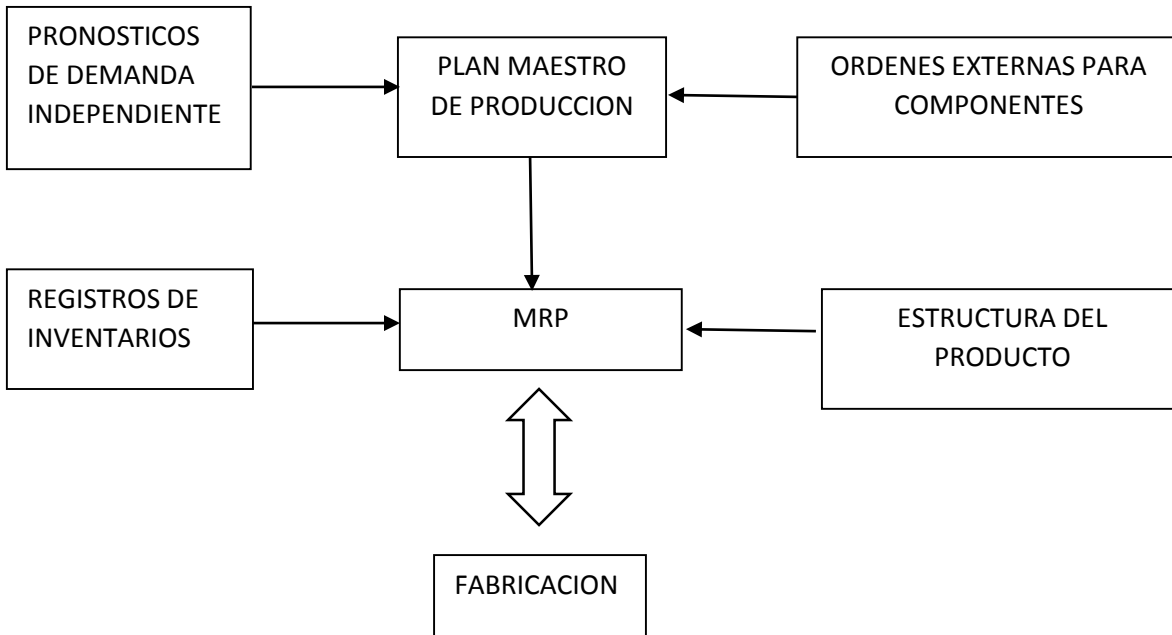
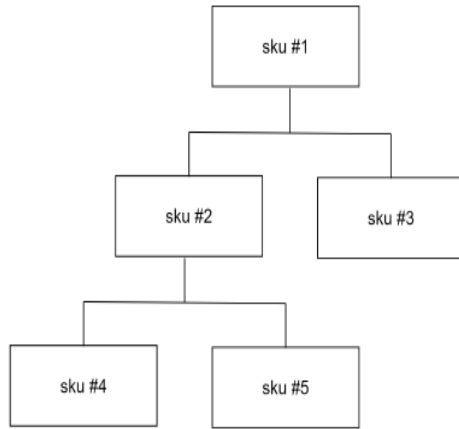


Figura 1. esquema de planificación convencional baso en (Jacobs 2011)

### 2.1. FUNDAMENTOS DE LA PLANIFICACION DE REQUERIMIENTOS DE MATERIAL

En esta sección se describe primero todas las partes en un sistema de producción y luego nos enfocamos en la implementación del MRP. Un plan de producción describe en detalle las principales cantidades de SKU (producto final para la venta) y producido en sub conjuntos de sku, el tiempo exacto de producción y tamaño de lote. El plan de producción puede dividirse en: plan maestro de producción (MPS), planificación de requerimientos de material (MRP) y el plan detallado de trabajo en el piso de producción.



(a) BOM para un ejemplo simple.

	Period				
	1	2	3	4	5
Gross requirements		10		40	10
Scheduled receipts	50				
Projected available balance	4	54	44	44	4
Planned order releases				50	
Lead time = one period					
Lot size = 50					

(b) forma básica de MRP: (Jacobs 2011).

Figura 2. Ejemplo de una lista de fabricación y registros básicos para alimentar el sistema MRP

El diccionario de APICS define MRP como: “conjunto de técnicas que utiliza datos de lista de materiales, datos de inventarios y el plan maestro de producción para calcular los requerimientos de material” (Cox and Blackstone 2002). El MRP requiere tres entradas básicas: Primero el plan maestro de producción (MPS), segundo la lista de materiales (BOM) para cada SKU (número de partes) que otros SKU son requeridos como componentes directos, y tercero el nivel actual de inventario para todo el SKU. Viendo la figura 2. De acuerdo a (Jacobs 2011). Un sistema de MRP tiene un papel central en la planeación y control de material. Esto traduce los planes generales para la producción dentro de los pasos individuales detallados para lograr esos planes. Esto proporciona información para desarrollar planes de capacidad, y se vincula con los sistemas que actualmente realizan la producción. (Nahmias and Cheng 2005).

### 2.1.1 MRP de lote a lote

### 2.1.2 Optimización del modelo MRP

La formulación para MRP es basada en el modelo propuesto por Voß y Woodruff (2006) por medio de la siguiente formula:

$$\underset{x}{\text{minimize}} \sum_{i=1}^P \sum_{t=1}^T (T - t) X_{i,t}$$

S.A

$$[h] \quad \sum_{\tau=1}^{t-LT(i)} X_{i,\tau} + I(i, 0) \geq \sum_{\tau=1}^t \left( D(i, \tau) + \sum_{j=1}^P R(i, j) X_{i,j} \right)$$

$$X_{i,t} - \delta_{i,t} LS(i) \geq 0$$

$$\delta_{i,t} - \frac{X_{i,t}}{M} \geq 0$$

$$\delta_{i,t} \in 0, 1$$

$$\forall i \in 1, \dots, P, \forall t \in 1, \dots, T.$$

P = Numero de SKU  
T = Tiempo de cada periodo (tiempo de planeación)  
LT = Tiempo de espera para SKU  
R (i, j) =Numero de i necesarios para hacer j  
D (i, t) = Demanda externa i para periodo t  
I (i,0) = Inventario inicial para cada SKU i  
LS (i) = Mínimo tamaño de lote para SKU i  
M =Numero muy grande para penalizar el modelo

## 2.3 METODOS TRADICIONALES DE PRONOSTICOS

El núcleo del MPS es el trabajo de los pronósticos para predecir las demandas futuras.

El plan maestro de producción (MPS) especifica las cantidades exactas y los tiempos de producción de cada artículo terminado en un sistema productivo. El MPS se refiere a artículos no acumulados. De esta manera, las entradas para determinar el MPS son pronósticos.

### METODOS DE SERIES DE TIEMPO

Los métodos de series de tiempo son llamadas métodos comunes, porque ya no requieren otra información de los valores pasados. Las series de tiempo son un término para referirse a la colección de observaciones de fenómenos económicos o físicos dibujado en puntos discretos en el tiempo. La idea es que la información pasada se pueda utilizar para pronosticar valores futuros de la serie.

En análisis de series de tiempos nosotros intentamos aislar los patrones que surgen con mayor frecuencia, estos incluyen los siguientes:

1. Tendencia: se refiere a la tendencia de una serie de tiempo que exhibe un patrón estable de crecimiento o decrecimiento.
2. Estacionalidad: Un patrón de estacionalidad son aquellos que se repiten en intervalos fijos.
3. Ciclos: La variación de ciclos es similar a la estacionalidad, excepto que la duración y la magnitud del ciclo varia. Uno asocia ciclos con variaciones económicas que también están presentes en las fluctuaciones estacionales.
4. Aleatoriedad: Una serie aleatoria es donde no se tiene un patrón reconocido de datos. Uno puede generar series aleatorias de datos que tengan una estructura especifica. Los datos que pareciera que aparentemente tienen una aleatoriedad, en realidad tienen una estructura especifica. Realmente los datos realmente aleatorios fluctúan alrededor de una media fija.

### MODELO DE BOX-JENKINS

Este tipo de modelos son mucho más sofisticados que los anteriormente mencionados. A continuación, se van a presentar los conceptos básicos de análisis BOX-JENKINS. Este método se dio gracias a dos estadísticos conocidos (GEORGE E BOX Y GWILYM M. JENKINS). Los modelos planteados se basan en explotar la estructura de auto correlación

de una serie de tiempo. Los métodos de BOX- JENKINS se basan en relaciones estadísticas de series de tiempo, a diferencia de la teoría básica que se basa en el famoso libro de NORBERT WIERNER de 1949 y antes.

Los modelos BOX-JENKINS son también conocidos con el nombre de modelos ARIMA que es un acrónimo para media móvil integrada auto regresiva. La función de auto correlación juega papel central en el desarrollo de estos modelos, esta es la característica que distingue al modelo de ARIMA de los otros métodos mencionados anteriormente. Como todos estos pronósticos los manejamos a través de modelos, denotamos las series de tiempo, denotando las series de tiempo de interés como  $D_1, D_2, \dots$ . Nosotros vamos a asumir inicialmente que la serie es estacionaria. De esta manera  $E=D_i = \mu$  y  $\text{var}=D_i = \sigma^2$  para todos los  $i=1,2,\dots$ . Prácticamente hablando, En la estacionalidad no existe crecimiento o decrecimiento en la serie, y la variación permanece relativamente constante. Esto es importante para denotar que la estacionalidad no implica independencia. Por lo tanto es posible evaluar de  $D_i$  y  $D_j$  son variables aleatorias dependientes cuando  $i \neq j$  aunque sus funciones de densidad marginal son las mismas.

El supuesto de estacionalidad implica que la distribución marginal de dos observaciones separadas por el mismo intervalo de tiempo son los mismos. Esto quiere decir que  $D_t$  y  $D_{t+1}$  tienen la misma distribución que  $D_{t+m}$  y  $D_{t+m+1}$  para cualquier  $m \geq 1$ . Esto implica que la covarianza de  $D_t$  y  $D_{t+1}$  es exactamente la misma covarianza de  $D_{t+m}$  y  $D_{t+m+1}$ . Por lo tanto, la covarianza de estas dos observaciones depende solamente del número de periodos que los separen. En este contexto la covarianza es también conocida como la auto covarianza, nosotros estamos comparando dos valores de la misma serie separados por un retraso fijo. Dejar  $\text{Cov}(D_{t+m}, D_{t+m+k})$  sea la covarianza de  $D_{t+m}$  y  $D_{t+m+k}$  dada por  $\text{Cov}(D_{t+m}, D_{t+m+k}) = E(D_{t+m} D_{t+m+k}) - E(D_{t+m}) E(D_{t+m+k})$  para cualquier entero  $k \geq 1$ .

El coeficiente de correlación de estas dos variables esta dada por

$$\rho_k = \frac{\text{Cov}(D_{t+m}, D_{t+m+k})}{\sqrt{\text{Var}(D_{t+m})} \sqrt{\text{Var}(D_{t+m+k})}$$

Esto se conoce a menudo como el coeficiente de auto correlación del retraso K, ya que se refiere a la correlación que hay entre todos los valores de la serie separado por k periodos. Estos coeficientes de auto correlación se calculan para varios valores de k. Son estos coeficientes de auto correlación los que serán primordiales para la construcción de modelos ARIMA.

Los coeficientes de correlación se estiman a partir de un historial de series. Para garantizar una estimación fiable, Box y Jenkins sugirió que uno tiene al menos 72 puntos de datos de

historia pasada de las series. Por lo tanto, estos modelos son solamente significativo cuando uno tiene un histórico confiable de la serie en estudio.

## ESTIMACION DE LA FUNCIÓN DE AUTOCORRELACION

Sea  $D_1, D_2, \dots, D_n$  una historia de observaciones de una serie de tiempo. Los coeficientes de auto correlación del retraso  $k$  se estima de la siguiente manera:

$$r_k = \frac{\sum_{t=k+1}^n (D_t - \bar{D})(D_{t-k} - \bar{D})}{\sum_{t=1}^n (D_t - \bar{D})^2},$$

Donde  $\bar{D}$  es la media muestral (promedio) de los valores observados de la serie.  $r_k$  como coeficientes de auto correlación de muestra. Este cálculo normalmente se da por 10 o 15 valores de  $k$ .

## RESUMEN DE LOS PASOS REQUERIDOS PARA CONSTRUIR UN MODELOS ARIMA

Hay cuatro pasos principales que se necesitan para construir modelos de pronósticos BOX-JENKINS

1. Transformaciones de datos: El método BOX-JENKINS se basa en el inicio de una serie de tiempo estacionaria. Para estar seguros de que la serie de tiempo es estacionaria, se necesitan de varios pasos preliminarmente. Sabemos que la diferenciación elimina la tendencia y la estacionalidad. Sin embargo, si la media de la serie es relativamente fija, este puede ser el caso en el que la varianza no es constante, por lo que se va a requerir una transformación de los datos.
2. Identificación del modelo: Este paso se refiere exactamente a cuál es el modelo de ARIMA más apropiado. La identificación del tipo de modelo es tanto arte como ciencia, es difícil si no imposible, para identificar el modelo se examina solamente la serie. Es mucho más efectivo estudiar las auto correlaciones de muestra y auto correlaciones parciales para la identificación de patrones que coinciden con los de los procesos conocidos. En algunos casos la estructura de auto correlación apuntara a un proceso simple de AR o MA, pero es más común la mezcla de estos dos términos para tener un mejor ajuste.
3. Estimación de parámetros: Una vez identificado el modelo apropiado, los valores óptimos de los parámetros del modelo (i.e.,  $a_0, a_1, \dots, a_p$  y  $b_0, b_1, \dots, b_q$ ) debe ser determinado, por lo general este paso se realiza por medio de métodos de ajustes mínimos cuadrados o mediante el método de máxima probabilidad, este paso es realizado por alguno programa de computadora.

4. Pronósticos: Una vez el modelo haya sido identificado y los valores de los parámetros óptimos determinado, el modelo proporciona pronósticos de valores futuros de la serie. Los modelos BOX-JENKINS son más efectivos para proporcionar pronósticos de un paso adelante, pero también puede proporcionar pronósticos de pasos múltiples.
5. Evaluación: El patrón de residuos (los errores de pronostico) puede dar información útil para ver la calidad del modelo. Los residuos deben formar ruido blanco (es decir, aleatorio) proceso con media cero. Cuando existen patrones en los residuos, se sugiere que el modelo de puede mejorar.

### 3. METODOLOGIA

En este documento nosotros vamos a proponer una metodología basada en una combinación de SARIMA y técnicas de MRP para ayudar a los administradores del sector de fragancias industriales a definir las mejores políticas de inventario y suministro. Los pasos seguidos en la metodología se muestran en la figura 3.

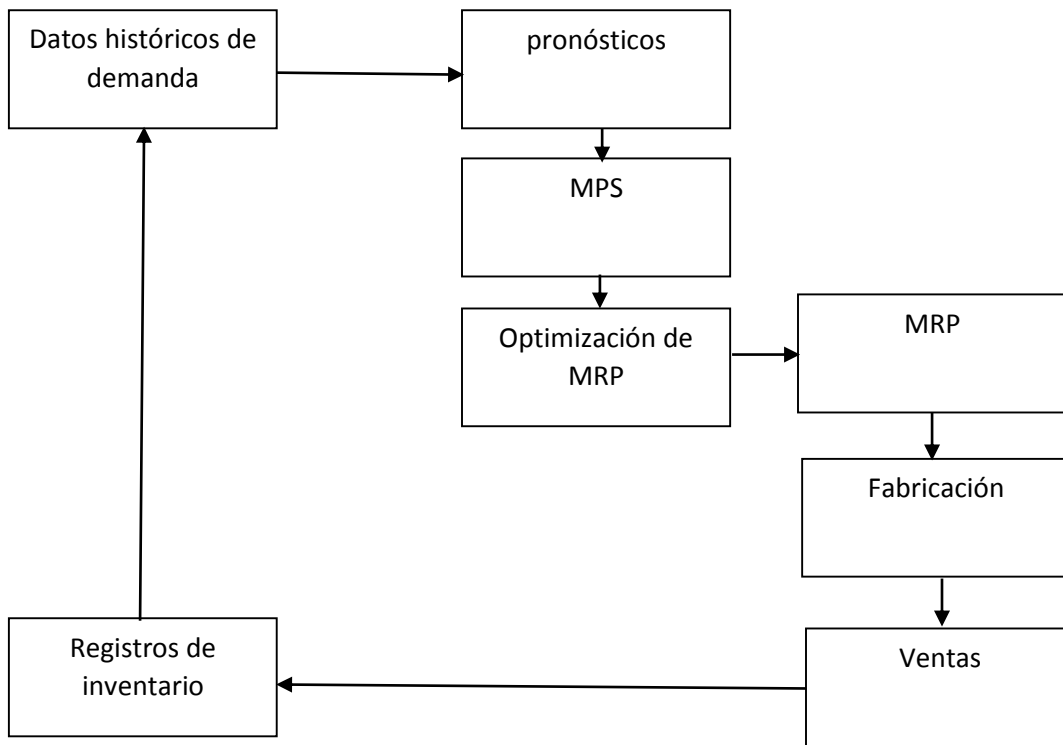


Figura 3. Enfoque metodológico

La metodología será aplicada a uno caso de estudio en particular. Ayudar a los administradores de fragancias industriales a alcanzar sus objetivos relacionados con minimizar el inventario y minimizar las desviaciones importantes en sus pronósticos. Principalmente el trabajo de los pronósticos se realizará utilizando la metodología de Box-Jenkins. (ver 2.3 métodos tradicionales de pronósticos), después se creará el MPS basado


en pronósticos anteriores y la optimización del MRP se realizará para obtener el MRP final. Los resultados del modelo MRP son evaluados con la demanda real y mejorado para ajustar los registros de demanda de datos históricos.

#### 4. CASO DE ESTUDIO

dedicada a la creación, desarrollo, fabricación y comercialización de saborizantes y fragancias para la industria colombiana, está comprometida en proporcionar un amplio portafolio de productos innovadores y con altos estándares de calidad que suplan las necesidades específicas de los clientes, para lograr un reconocimiento y posicionamiento sólido en el sector.

##### 4.1 PRONOSTICANDO EL PRINCIPAL SKU

Primero, los datos de demanda histórica son graficados con el fin de conocer los patrones de los datos. Después nosotros aplicamos el modelo SARIMA por medio del lenguaje R.



(a) Gráfico de datos históricos

(b) Pronostico para 2019 (meses)

Figura 4. Pronostico utilizando modelo SARIMA con el lenguaje R

<b>Apr</b>	<b>May</b>	<b>Jun</b>	<b>Jul</b>	<b>Aug</b>
88.34232	98.20327	104.55308	108.39207	110.74301
<b>Sept</b>	<b>Oct</b>	<b>Nov</b>	<b>Dec</b>	
112.17886	113.05630	113.59244	113.92004	

Tabla 1. Pronostico de demanda



## 4.2 Usando el modelo de optimización para MRP

En este artículo nosotros utilizamos el lenguaje de programación de julia y el paquete JuMP para optimización matemática, podemos ver el código para problema a continuación:

```
using JuMP,Cbc,NamedArrays,DataFrames
filas=size(D,1)
col=size(D,2)
mrp=Model(solver=CbcSolver())
@variables mrp begin
x[1:filas,1:col]>=0
d[1:filas,1:col]>=0
end
T=col
@objective(mrp,Min,sum( x[i,j]*((T-j)) for i=1:filas, j=1:col))
for i=1:filas,t=1:col
@constraint(mrp, sum(x[i,s] for s=1:t-LT[i,1])+I[i,1]>=sum(D[i,s]+sum(R[i,j]*x[j,s] for
end
@constraint(mrp,x-d.*LS.>=0)

@constraint(mrp,d-x/10000000000000000.>=0)
#print(mrp)
status=solve(mrp)
println(getobjectivevalue(mrp))
println(DataFrame(getvalue(x)))
println(DataFrame(getvalue(d)))
```

## 4.3 RESULTADOS

EL MRP se generó y se puede ver a continuación en el Apéndice 2

## 5. DISCUSION Y FUTURA INVESTIGACION

La investigación futura debe estar relacionada con DDMRP impulsado por la demanda del MRP y las técnicas de aprendizaje automático relacionadas con los métodos de pronósticos. La primera información está relacionada con los métodos para mantener intervalos mínimos y máximos para la gestión de inventario en cada sku. La segunda afirmación está relacionada con el método que ayuda a obtener mejores y pronósticos más precisos para la demanda futura.

## 6. REFERENCIAS BIBLIOGRAFICAS

- Box, George EP, Gwilym M Jenkins, Gregory C Reinsel, and Greta M Ljung. 2015. *Time series analysis: forecasting and control*. John Wiley & Sons.
- Cox, James F, and John H Blackstone. 2002. *APICS dictionary*. Amer Production & Inventory.
- Hopp, Wallace J, and Mark L Spearman. 2011. *Factory physics*. Waveland Press.
- Jacobs, F Robert. 2011. *Manufacturing planning and control for supply chain management*. McGraw-Hill.
- Mabert, Vincent A. 2007. "The early road to material requirements planning." *Journal of Operations Management* 25 (2): 346–356.
- Nahmias, Steven, and Ye Cheng. 2005. *Production and operations analysis*. Vol. 6. McGraw-hill New York.
- Orlicki, Joseph A. 1975. *Material requirements planning: the new way of life in production and inventory management*. McGraw-Hill.
- Voß, Stefan, and David L Woodruff. 2006. *Introduction to computational optimization models for production planning in a supply chain*. Vol. 240. Springer Science & Business Media.

## APÉNDICES

### Apéndice 1

```
using JuMP,Cbc,NamedArrays,DataFrames
mrp=Model(solver=CbcSolver())
@variables mrp begin
x[1:34,1:9]>=0
d[1:34,1:9]>=0, Bin
end
T=9
@objective(mrp,Min,sum( x[i,j]*((T-j)) for i=1:34, j=1:9))
for i=1:34,t=1:9
@constraint(mrp, sum(x[i,s] for s=1:t-LT[i,1])+I[i]>=sum(D[i,s]+sum(R[i,j]*x[j,s] for j=
end
@constraint(mrp,x-d.*LS.>=0)
@constraint(mrp,d-x/10000.>=0)
#print(mrp)
status=solve(mrp)
```

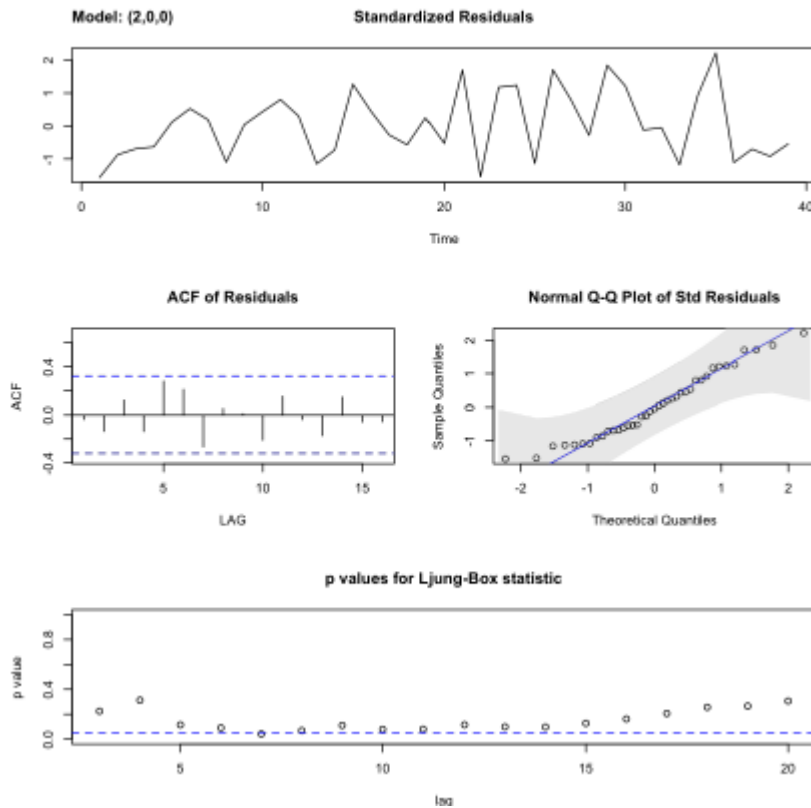


Figura 5. Prueba de aceptación

## Apéndice 2

Table 2.

Table 3. Period 1 to 7

period1	period2	period3	period4	period5	period6	period7
0	0	0	0	0	0	0
0	0	0	0	22422.6943	24925.5612	26537.2446
0	0	0	0	35.336928	39.281308	41.821232
0	0	0	0	1766.8464	1964.0654	2091.0616
0	0	0	0	1766.8464	1964.0654	2091.0616
0	0	0	0	9345.20398	10388.3347	11060.043
0	0	0	0	8.834232	9.820327	10.455308
11378.4908	12648.5812	13466.4367	13960.8986	14263.6997	14448.6372	14561.6514
70.673856	78.562616	83.642464	86.713656	88.594408	89.743088	90.44504
424.043136	471.375696	501.854784	520.281936	531.566448	538.458528	542.67024
353.36928	392.81308	418.21232	433.56828	442.97204	448.71544	452.2252
4084.94888	4540.9192	4834.53442	5012.04932	5120.75678	5187.15049	5227.72331
2473.58496	2749.69156	2927.48624	3034.97796	3100.80428	3141.00808	3165.5764
2049.54182	2278.31586	2425.63146	2514.69602	2569.23783	2602.54955	2622.90616
1837.52026	2042.62802	2174.70406	2254.55506	2303.45461	2333.32029	2351.57104
1554.82483	1728.37755	1840.13421	1907.70043	1949.07698	1974.34794	1989.79088
1501.81944	1669.45559	1777.40236	1842.66519	1882.63117	1907.04062	1921.9571
1236.79248	1374.84578	1463.74312	1517.48898	1550.40214	1570.50404	1582.7882
848.086272	942.751392	1003.70957	1040.56387	1063.1329	1076.91706	1085.34048
805.681958	895.613822	953.52409	988.535678	1009.97625	1023.0712	1031.07346
706.73856	785.62616	836.42464	867.13656	885.94408	897.43088	904.4504
664.334246	738.48859	786.239162	815.108366	832.787435	843.585027	850.183376
522.986534	581.363358	618.954234	641.681054	655.598619	664.098851	669.293296
353.36928	392.81308	418.21232	433.56828	442.97204	448.71544	452.2252
219.088954	243.54411	259.291638	268.812334	274.642665	278.203573	280.379624
141.347712	157.125232	167.284928	173.427312	177.188816	179.486176	180.89008
173.150947	192.478409	204.924037	212.448457	217.0563	219.870566	221.590348
77.7412416	86.4188776	92.0067104	95.3850216	97.4538488	98.7173968	99.489544
70.673856	78.562616	83.642464	86.713656	88.594408	89.743088	90.44504
70.673856	78.562616	83.642464	86.713656	88.594408	89.743088	90.44504
70.673856	78.562616	83.642464	86.713656	88.594408	89.743088	90.44504
70.673856	78.562616	83.642464	86.713656	88.594408	89.743088	90.44504
42.4043136	47.1375696	50.1854784	52.0281936	53.1566448	53.8458528	54.267024
3533.6928	3928.1308	4182.1232	4335.6828	4429.7204	4487.1544	4522.252

Table 4.

Table 5. Period 8 to 14

period8	period9	period10	period11	period12	period13	period14
0	88.34232	98.20327	104.55308	108.39207	110.74301	112.17886
27511.6416	28108.3478	28472.7895	28695.4978	28831.5788	28914.7289	0
43.356828	44.297204	44.871544	45.22252	45.436976	45.568016	0
2167.8414	2214.8602	2243.5772	2261.126	2271.8488	2278.4008	0
2167.8414	2214.8602	2243.5772	2261.126	2271.8488	2278.4008	0
11466.1467	11714.8386	11866.7285	11959.5476	12016.2627	12050.9175	0
10.839207	11.074301	11.217886	11.30563	11.359244	11.392004	0
14630.7063	14672.9012	0	0	0	0	0
90.873952	91.136032	0	0	0	0	0
545.243712	546.816192	0	0	0	0	0
454.36976	455.68016	0	0	0	0	0
5252.51443	5267.66265	0	0	0	0	0
3180.58832	3189.76112	0	0	0	0	0
2635.34461	2642.94493	0	0	0	0	0
2362.72275	2369.53683	0	0	0	0	0
1999.22694	2004.9927	0	0	0	0	0
1931.07148	1936.64068	0	0	0	0	0
1590.29416	1594.88056	0	0	0	0	0
1090.48742	1093.63238	0	0	0	0	0
1035.96305	1038.95076	0	0	0	0	0
908.73952	911.36032	0	0	0	0	0
854.215149	856.678701	0	0	0	0	0
672.467245	674.406637	0	0	0	0	0
454.36976	455.68016	0	0	0	0	0
281.709251	282.521699	0	0	0	0	0
181.747904	182.272064	0	0	0	0	0
222.641182	223.283278	0	0	0	0	0
99.9613472	100.249635	0	0	0	0	0
90.873952	91.136032	0	0	0	0	0
90.873952	91.136032	0	0	0	0	0
90.873952	91.136032	0	0	0	0	0
90.873952	91.136032	0	0	0	0	0
54.5243712	54.6816192	0	0	0	0	0
4543.6976	4556.8016	0	0	0	0	0

Table 6. Period 15 to 21

period15	period16	period17	period18	period19	period20	period21
113.0563	113.59244	113.92004	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0