

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

Colegio de Administración y Economía

**Análisis de la serie temporal “Uso de Suelos” de la
empresa Corporación de Recursos Naturales S.A.
Proyecto de investigación**

Juan Pablo Ortiz Espinoza

Economía

Trabajo de titulación presentado como requisito
para la obtención del título de
Licenciado en Economía

Quito, 10 de mayo de 2016

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ
COLEGIO ADMINISTRACIÓN Y ECONOMÍA

**HOJA DE CALIFICACIÓN
DE TRABAJO DE TITULACIÓN**

Análisis de la serie temporal “Uso de Suelos” de la empresa Corporación de Recursos Naturales S.A.

Juan Pablo Ortiz Espinoza

Calificación:

Nombre del profesor, Título académico

Jaime Maya , MBA.

Firma del profesor

Quito, 10 de mayo de 2016

Derechos de Autor

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Firma del estudiante: _____

Nombres y apellidos: Juan Pablo Ortiz Espinoza

Código: 00136392

Cédula de Identidad: 1717205973

Lugar y fecha: Quito, mayo de 2016

RESUMEN

En la actualidad, las técnicas econométricas son usadas para analizar las variables de interés tanto en empresas privadas como públicas; las empresas buscan entender el comportamiento de sus variables en función del tiempo, para anticiparse a los cambios potenciales de sus mercados. El presente estudio recopila datos del uso de suelos de la empresa Corporación para los Recursos Naturales S.A., los cuales son diagnosticados y analizados; en función de sus características y su comportamiento. Adicionalmente los datos son modelados mediante el uso de distintos modelos ARIMA y posteriormente se realiza un contraste entre los datos reales de la serie de tiempo y los pronósticos de los modelo que mejor expliquen el comportamiento de la serie, con el objetivo de conocer el que menor porcentaje de error muestre y sea capaz de realizar pronósticos con precisión alta.

Palabras Clave: ARIMA, Series de Tiempo, Univariante, Indicadores, Efectos

ABSTRACT

Nowadays econometric techniques are used to analyze variables in the public and private sector. The companies search for a clear understanding of the behavior of the variables through time periods with the purpose of prompt react of any potential change in the market. This study collect data about de consumption of soil in the company Corporación para los Recursos Naturales S.A. the techniques used for the diagnostic and analysis are based in ARIMA models those model where used to forecast the studied variable. Different indicator where applied to measure the percentage of error to be able to recognize the finest model that suit the variable.

Keywords: ARIMA, Time Series, Univariate, Indicators, Efectts

TABLA DE CONTENIDO

1. Introducción.....	10
1.1 Revisión de Literatura	10
1.2 Justificación	12
1.3 Objetivo General.....	14
1.4 Objetivos Específicos.....	15
1.5 Introducción	16
2. Marco Teórico	18
2.1 Series de Tiempo	18
2.2 Modelos Arima	18
2.3 Indicadores de modelos de Series de Tiempo.....	21
3. Metodología	23
3.1 Características de la Serie	23
3.2 Identificación de la Serie	23
3.3 Tratamiento de la Serie	28
4. Desarrollo	30
4.1 Modelo 0: Planteamiento, Estimación y Diagnóstico	30
4.2 Modelo 1: Planteamiento, Estimación y Diagnóstico	32
4.3 Modelo 2: Planteamiento, Estimación y Diagnóstico	36
5. Resultados	40
5.1 Contraste de Modelos.....	40

6. Conclusiones y Recomendaciones	43
6.1 Conclusiones.....	43
6.2 Recomendaciones.....	44
7. Bibliografía	45

INDICE DE GRÁFICOS

Grafico No. 1: Serie de Tiempo en Toneladas	24
Grafico No. 2 Representación del Ajuste Lineal.....	25
Grafico No. 3: Serie - Transformación Log	26
Grafico No. 4: Representación del Ajuste Lineal Log.....	27
Grafico No. 5: Serie Transformada	28
Grafico No. 6: ACF y PACF.....	29
<i>Grafico No. 7: Resultados Modelo 0</i>	<i>30</i>
<i>Grafico No. 8: Residuos del Modelo 0</i>	<i>31</i>
<i>Grafico No. 9: Residuos ACF y PACF</i>	<i>32</i>
<i>Grafico No. 10: Resultados Modelo 2 Efecto Semana Santa</i>	<i>34</i>
<i>Grafico No. 11: Residuos Modelo 1</i>	<i>35</i>
<i>Grafico No. 12: Modelo 1 ACF y PACF</i>	<i>36</i>
<i>Grafico No. 13: Modelo 2 con MA(1).....</i>	<i>37</i>
<i>Grafico No. 14: Residuos Modelo 2</i>	<i>38</i>
<i>Grafico No. 15: Modelo 2 ACF y PACF</i>	<i>38</i>
<i>Grafico No. 16: Pronósticos Modelo 1</i>	<i>41</i>
<i>Grafico No. 17: Pronósticos Modelo 2</i>	<i>41</i>

INDICE DE TABLAS

<i>Tabla No. 1: Indicadores RMSE, MAE, MAPE.....</i>	<i>42</i>
--	-----------

1. INTRODUCCIÓN

1.1 Revisión de literatura

En la actualidad, las predicciones y sus modelos asociados son fundamentales en el campo de investigación, los mismos permiten tomar decisiones en el corto y largo plazo para desarrollar estrategias eficientes en distintos escenarios (Adebisi, Adewumi, & Ayo, 2014). Para esto existen métodos de análisis de series de tiempo que toman el peso de los datos durante distintos periodos, para identificar características de autocorrelación, tendencia o estacionalidad, lo cual permite ajustar y modelar las series de estudio a través del tiempo (Reyes, 2007). La precisión en el estudio de series de tiempo permite realizar pronósticos para mitigar y minimizar los riesgos en los proyectos; es por esta razón que cada vez el factor motivacional crece, lo cual permite evolucionar y desarrollar nuevos modelos de predicción que se ajusten a la realidad de las industrias (Atsalakis, Dimitrakakis, & Zopounidis, 2011). Las técnicas comunes más usadas incluyen regresiones, métodos de acercamiento a series de tiempo y algoritmos de red artificiales (Box & Jenkins, 1976). Entre los modelos de series de tiempo, el método ARIMA (Auto Regressive Integrated Moving Average), es utilizado con frecuencia para pronosticar series de tiempo relacionadas al sector petrolero con resultados eficaces (Morana, 2001). De la misma manera, los métodos de predicción ARIMA, son capaces de proveer información precisa y efectiva para sustentar la planificación de una demanda en un mercado específico (Cho, Hwang, & Chen, 2014).

Los pronósticos generados trabajan con supuestos y datos históricos, que son fiables para predicciones en el futuro. (Tsitsika, Maravelias, & Haralabous, 2007).

1.2 Justificación

A partir de la constante evolución de las empresas, respecto a la planificación de proyectos, se vuelve de vital importancia la búsqueda de métodos que sean capaces de simular eventos futuros en base a información histórica, esto permitirá que las empresas puedan anticiparse a posibles resultados, lo que permitirá mitigar riesgos y minimizar costos derivando en mayor productividad para la compañía (Kaleshovska, 2014). En la actualidad, el uso de pronósticos en los proyectos de una empresa es una ventaja competitiva, ya que permite que estos sean manejados de acuerdo a escenarios potenciales; con planes de acción, que permitan reaccionar de manera rápida y eficiente para el cumplimiento de metas y objetivos en una empresa (Project Management Institute, 2014).

La precisión de pronósticos es vital para una planificación exitosa, por lo tanto es la primera meta en el sector gubernamental y de empresas privadas el uso de econometría (Studenmund, 2012). La empresa Corporación para los Recursos Naturales S.A., está posicionada entre las empresas líderes de remediación, manejo de suelos y traslado en industrias hidrocarburíferas del Ecuador; uno de sus objetivos del plan operativo es mejorar el uso de sus recursos a través de una planificación minuciosa de sus trabajos (Alvarez, 2016). Por esta razón, en el presente estudio se realiza un análisis de datos del uso de suelos en la empresa, que es la materia prima en

las actividades que realiza, con el fin de desarrollar recomendaciones sobre comportamiento de los datos.

1.3 Objetivo general

Determinar las características de los datos recopilados, respecto al uso de suelos de la empresa Corporación para los Recursos Naturales S.A., y a través del diagnóstico proponer un modelo de pronósticos que describa el comportamiento de los datos en el tiempo.

1.4Objetivos específicos

- Recopilar datos fiables respecto al uso de suelos de la empresa Corporación para los Recursos Naturales S.A..
- Determinar el comportamiento de los datos durante un periodo de tiempo específico.
- Proponer modelos para representar el comportamiento de la serie en estudio.
- Estimar modelos de predicción de series de tiempo.
- Validar modelos mediante un contraste entre el comportamiento de los datos reales y el comportamiento de los pronósticos de los modelos planteados.

1.5 Introducción

El presente estudio se realiza para diagnosticar y encontrar un modelo de serie de tiempo que mejor explique el comportamiento de la serie temporal respecto al uso de suelos para remediación y traslado en el sector petrolero de la empresa ecuatoriana “Corporación para los Recursos Naturales”.

El periodo que se toma en cuenta para el análisis está comprendido entre enero del 2000 hasta diciembre 2014 dado que los datos respecto a estos años están completos y permiten realizar un análisis con resultados robustos. Se reservará los datos de los dos últimos años para hacer un contraste con las predicciones de los datos analizados y conocer el ajuste del modelo a la serie.

El estudio analizará las características de la serie y propondrá las transformaciones necesarias a aplicarse para convertirla en una serie de carácter estacional a partir de las transformaciones realizadas se podrá estudiar la dinámica y comportamiento de la serie, lo cual permitirá describirla en términos de un modelo univariante estacionario.

Después de estimar el modelo se realizará un diagnóstico del nuevo modelo para evaluar su validez y robustez de predicción mediante el análisis del porcentaje de error

que muestra. En caso de que el modelo muestre potencial de mejora se propondrá otro modelo que sea capaz de corregir las fallas que presente el inicial.

Finalmente, se tomarán en cuenta los modelos que mejor ajuste hayan obtenido de acuerdo a la significancia de sus variables para realizar una validación y diagnóstico, lo cual permitirá determinar analíticamente, cual describe acertadamente el comportamiento de la serie en estudio. Adicionalmente, se comparará las predicciones de los pronósticos con los datos reales respecto a los años 2013 y 2014, para evidenciar el ajuste del modelo.

2. MARCO TEÓRICO

2.1 Series de tiempo

Las series de tiempo son observaciones de un proceso o un evento que puede ser de carácter estocástico (Wooldridge, 2001). El uso tradicional de series de tiempo es realizar pronósticos respecto al camino que recorre una variable en el tiempo; interpretar la dinámica de la serie mejora la precisión del pronóstico dado que los componentes identificados en un serie puede ser extrapolados, y reservados para su posterior uso (Enders, 2014).

Las series de tiempo pueden ser descompuestas de acuerdo a sus ciclos, tendencia, estacionalidad y sus componentes irregulares. El componente de tendencia representa el comportamiento a largo plazo; el componente cíclico representa los movimientos periódicos, y el componente irregular es de naturaleza estocástica. La econometría busca estimar y predecir pronósticos con este componente; identificándolo cuantificando su efecto en la serie (Enders, 2014).

2.2 Modelos arima

La modelización de las series temporales con el método ARIMA, es aplicada principalmente en series de alta frecuencia y cuando su tipología de datos se encuentra expresados en trimestres o en meses. Los modelos ARIMA de carácter estacional son

representados por $ARIMA_s(P, D, Q)$, o $SARIMA(P, D, Q)$, donde P es el orden de la parte autoregresiva, D es el número de diferencias estacionales y Q es el orden de la parte de medias móviles (Cabrer, 2004). Entre los métodos ARIMA los modelos univariante tienen ventajas significativas ya que no necesitan la relación de causalidad, explicativa del comportamiento de la variable endógena. Sin embargo, se necesitan todos los datos de la serie temporal de la variable de estudio, para estimar el modelo que se utilizará para predecir (Hurtado C. , 2008). La predicción del modelo univariante se utiliza cuando se espera que en el futuro conserven algunas de las características de su evolución en el pasado (Econometria Novales, 2010) .

Para construcción de modelos ARIMA, se lleva un proceso de varias etapas de acuerdo a las características de los datos recopilados.

- Identificación: Representación gráfica de la serie, permite identificar si la serie es estacionaria o no. Si la serie tiene tendencia, se toma diferencias regulares hasta que el efecto desaparezca, si la serie presenta estacionalidad, se toma diferencias estacionales hasta que el patrón desaparezca (Villavicencio, 2012). Adicionalmente, se identifica la heterocedástica de la serie, si la varianza no es constante se busca un método apropiado para transformar la serie; generalmente una transformación logarítmica brinda excelente resultados para las series, en

caso de necesitar transformaciones más complejas se utiliza la técnica Box-Cox. (Enders, 2014)

- Estimación y Verificación: Observando las gráficas de la Función Autocorrelación(ACF) y Función Autocorrelación Parcial(PACF) de la serie transformada, se derivan los modelos candidatos para la estimación. Un modelo se puede ajustar a varias estructuras ARIMA(P,Q,D). A partir del análisis del modelo se resuelve la significancia de sus variables por medio de una inferencia sobre los parámetros. (Box & Jenkins, 1976)
- Validación: A partir de los modelos planteados se realiza un contraste con los datos reales; lo que permite verificar los indicadores de porcentajes de error en la series de tiempo para conocer la predicción del modelo (Enders, 2014). En caso de existir posibles discrepancias en los modelos, se aplican técnicas para poder mejorarlo (Facultad de Ciencias Economicas y Empresariales, 2009)
- Predicción: Se realiza pronósticos en términos probabilísticos de los valores futuros, para evaluar la capacidad predictiva del modelo. Para esto se utiliza el modelo ARIMA(P,Q,D), que mejor ajuste tuvo a la serie y que sus indicadores de desviación absoluta son los menores en comparación de todos los modelos.

2.3 Indicadores de modelos de series de tiempo

Los indicadores en las series de tiempo comparan la efectividad de los modelos simulados respecto a los datos reales. En los modelos pronosticados se busca el modelo que menor valor tenga para los indicadores MAPE, MAD, MSD, MAE y RMSE ya que menores valores representan un mejor ajuste del modelo (Reyes, 2007).

A continuación se presenta distintos indicadores los cuales son tomados en cuenta de acuerdo a las características de la serie y las preferencias de análisis en las medidas de error del modelo por parte del investigador (Chai & Draxler, 2014).

El MAPE, indica el porcentaje promedio absoluto del error, y la exactitud de los valores estimados de la serie de tiempo (Reyes, 2007).

$$MAPE = \frac{\sum[y_t - \bar{y}_t]/y_t}{n} * 100$$

Donde la precisión del modelo se expresa como un porcentaje con y_t igual al valor observado, \bar{y}_t es el valor estimado y n es el número total de observaciones.

El MAD, indica la desviación media absoluta, mide la exactitud de los valores pronosticados de la serie de tiempo. Expresa la exactitud en la mismas unidades de los datos (Reyes, 2007).

$$MAD = \frac{\sum_{t=1}^n [y_t - \bar{y}_t]}{n}$$

El MSD, indica la desviación cuadrática media, la cual tiene mayor sensibilidad a errores anormales de pronósticos en las series de tiempo a diferencia del MAD (Reyes, 2007).

$$MSD = \frac{\sum_{t=1}^n [y_t - \bar{y}_t]^2}{n}$$

El RMSE, indica la raíz del error cuadrado medio, es una medida de desempeño cuantitativa comúnmente utilizada para evaluar métodos de pronóstico de demanda (Chai & Draxler, 2014).

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

El MAE indica la error absoluto en la media, es decir el valor absoluto de la diferencia entre el pronóstico y la serie real (Chai & Draxler, 2014).

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

3. METODOLOGÍA

3.1 Características de la serie

La serie temporal respecto al traslado, uso de suelos y remediación muestra la demanda que la Corporación para Recursos Naturales, CORENA S.A., tiene durante el año 2000 al año 2014. Los datos obtenidos de la empresa son de carácter mensual y su unidad de medida esta expresada en toneladas. En caso de encontrar datos atípicos en la serie, estos no serán tomados en cuenta para lograr un modelo más robusto.

3.2 Identificación de la serie

Para identificar la serie en el presente estudio se tomará en cuenta periodos de carácter mensual desde enero del 2000 hasta diciembre del 2012. Los datos que pertenecen a enero 2013 hasta diciembre del 2014 se los utilizara para contrastar los modelos y verificar su validez y aproximación a datos reales.

A continuación se presenta el Gráfico No.1 realizado a partir de los datos reales de la serie en estudio.

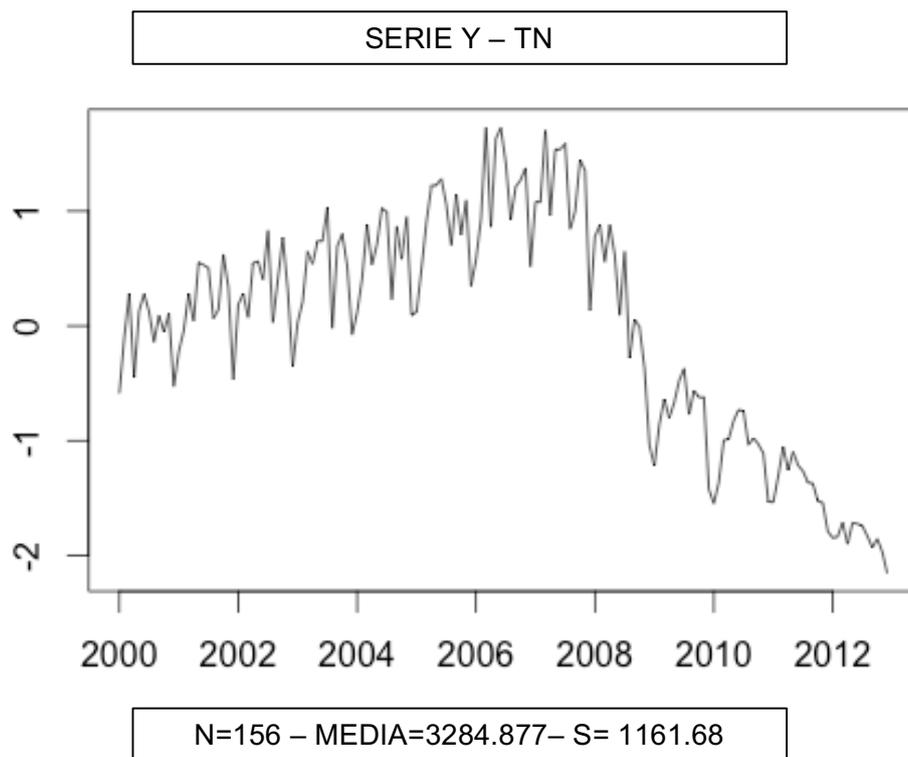


Grafico No. 1: Serie de Tiempo en Toneladas

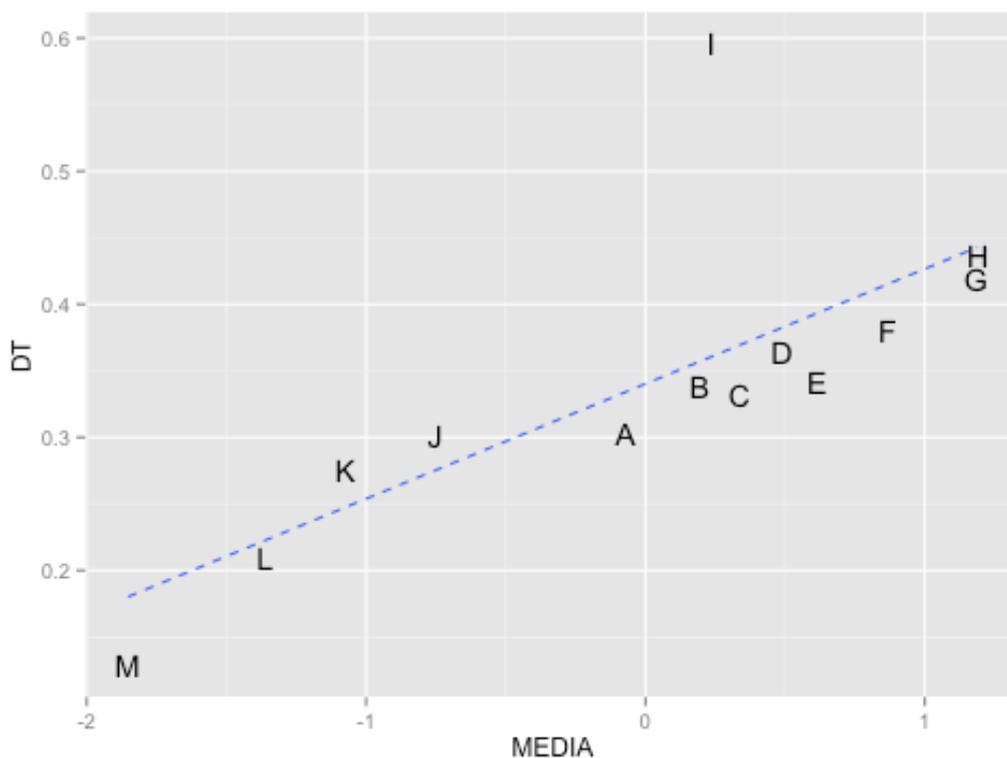


Gráfico No. 2 Representación del Ajuste Lineal

De acuerdo al a la representación Gráfica No.1 se puede evidenciar que existe una no estacionariedad en la varianza de los datos. Para este tipo de comportamiento se sugiere utilizar una transformación de datos. Se realiza una representación del ajuste lineal de los datos en el Gráfico No.2 donde se evidencia la asociación lineal y positiva entre la media y la desviación estándar. Por lo tanto se realiza una transformación logarítmica para corregir la no estacionariedad en la varianza.

A continuación se muestra la serie con transformación logarítmica y la asociación lineal.

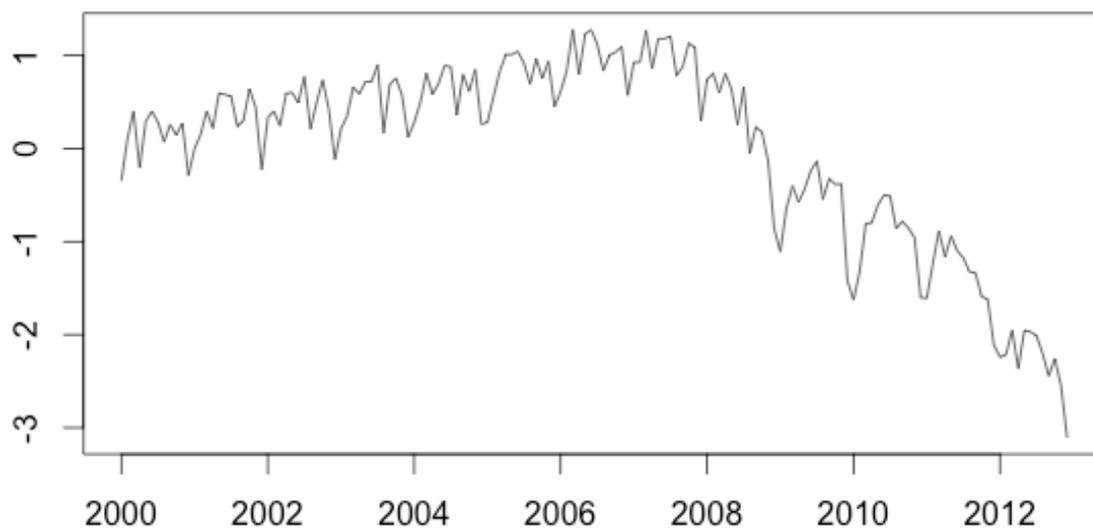


Grafico No. 3: Serie - Transformación Log

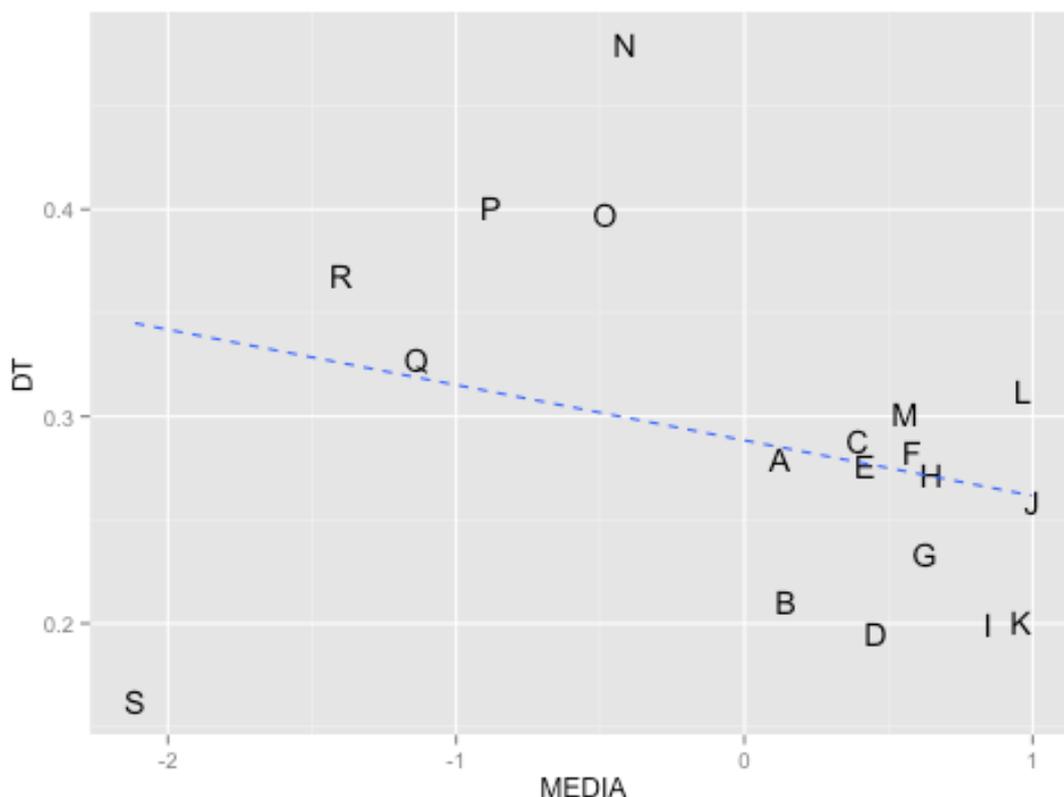


Gráfico No. 4: Representación del Ajuste Lineal Log

De acuerdo al Gráfico No.3 y el Gráfico No. 4 se logra evidenciar que no es estacionaria la serie, ya que el nivel medio general no es constante y la serie muestra de forma clara la estacionalidad paralelamente revela que la dispersión fue corregida. Por lo tanto, la transformación logarítmica logra representar los ciclos estacionales; estas estructuras se repiten anualmente lo que evidencia la necesidad de una diferencia estacional (periodos de 12 meses) y una diferencia regular.

$$\nabla \nabla_{12} y_t^{\lambda=0} = (1 - \beta)(1 - \beta^{12}) \ln y_t$$

Donde $(1 - \beta)$, representa la diferencia regular, $(1 - \beta^{12})$ representa la diferencia estacional y $\ln y_t$ la transformación de la serie.

3.3 Tratamiento de la serie

A continuación se presenta el Grafico No. 5 donde se representa el tratamiento de la serie transformada con su diferenciación y en el Grafico No.6 la función de autocorrelación(ACF) y la función de autocorrelación parcial(PACF) las cuales permitirán hacer una recomendación para el uso de modelos, que mejor se ajusten a la serie transformada.



Grafico No. 5: Serie Transformada

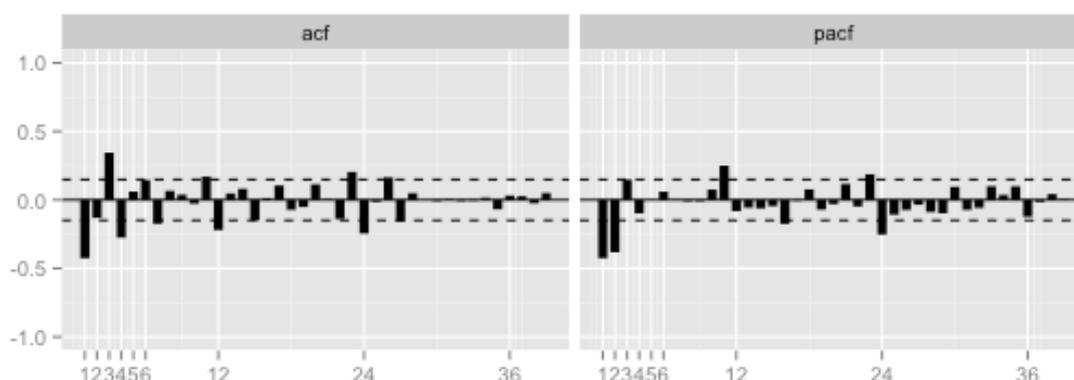


Gráfico No. 6: ACF y PACF

La dinámica de la serie y su comportamiento para la parte regular se aproxima a un modelo autoregresivo de segundo orden AR(2) y para la parte estacional sugiere un modelo autoregresivo estacional de segundo orden SAR(2). Por lo tanto de acuerdo a la función de autocorrelación(ACF) y la función de autocorrelación parcial(PACF) el modelo AR(2)xSAR(2) se puede expresar como:

$$(1 - \phi_1 B - \phi_2 B^2)(1 - \Phi_1 B^{12} - \Phi_2 B^{24}) \nabla \nabla_{12} \ln y_t = A_t$$

Donde $(1 - \phi_1 B - \phi_2 B^2)$ representa el operador AR(Autoregresivo de Orden 2), y $(1 - \Phi_1 B^{12} - \Phi_2 B^{24})$, presenta el operador SAR(Estacional Autoregresivo de Orden 2), y donde $\nabla \nabla_{12}$, representa la diferencia regular diferencia estacional y donde $\ln y_t$ representa la transformación de la serie.

4. DESARROLLO

4.1 Modelo 0: Planteamiento, estimación y diagnóstico

A partir del modelo expuesto en el tratamiento de la serie se realiza la estimación del modelo 0 para identificar la significancia de los parámetros. A continuación en el Grafico No.7 se muestra los resultados.

```

ARIMA(2,1,0)x(2,1,0)_{s=12} . Time series: cemS (lambda= 0 )

      Estimate   Std.Dev   t.test   p.value
ar1  -0.5937500  0.07170400 -8.280570 2.220446e-16
ar2  -0.3978432  0.07120554 -5.587251 2.306922e-08
sar1  -0.2811687  0.07460869 -3.768578 1.641802e-04
sar2  -0.4001626  0.07384036 -5.419294 5.983486e-08

Sigma^2 = 0.00701191 . Log.Lik= 174.5986 , AIC= -339.1972

Correlation matrix
      ar1      ar2      sar1      sar2
ar1  1.00000000  0.425470038 -0.10115247 -0.017618490
ar2  0.42547004  1.000000000 -0.05525608  0.007360059
sar1 -0.10115247 -0.055256075  1.00000000  0.197123479
sar2 -0.01761849  0.007360059  0.19712348  1.000000000

Statistic d.f.   p.value
L-B Q  42.01530  NA 1.930351e-01
J-B    20.49337  NA 3.547489e-05

```

Grafico No. 7: Resultados Modelo 0

De acuerdo a los resultados podemos observar que los contrastes de significación individuales señalan que los parámetros de estudio son significativos, por lo tanto se evidencia que su efecto es válido para poder explicar el modelo. En cuanto a

la matriz de correlaciones todas se encuentran en un nivel moderado, con distintos niveles de correlación lo cual permite aceptar el modelo. Adicionalmente los parámetros asociados al modelo autoregresivo y autoregresivo estacional cumplen con la condición de estacionariedad.

$$\phi_2 - \phi_1 < 1; \phi_2 + \phi_1 < 1; |\phi_2| < 1$$

A continuación se presenta el Grafico No. 8 donde se presenta los residuos del modelo 0 y en el Grafico No. 9 la función de autocorrelación(ACF) y la función de autocorrelación parcial(PACF).

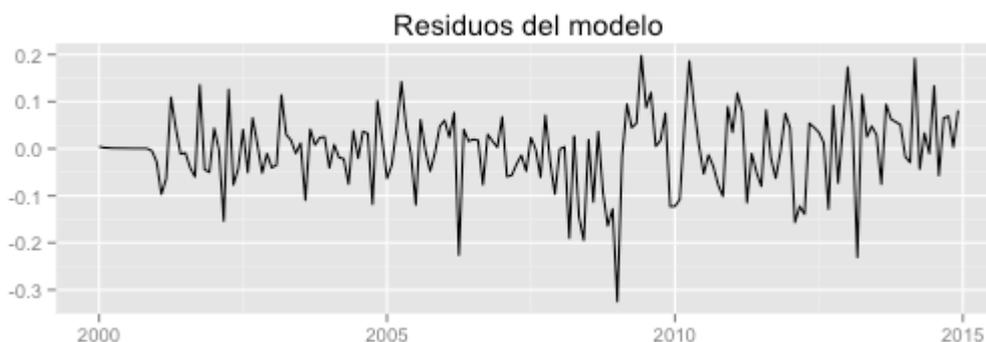


Grafico No. 8: Residuos del Modelo 0

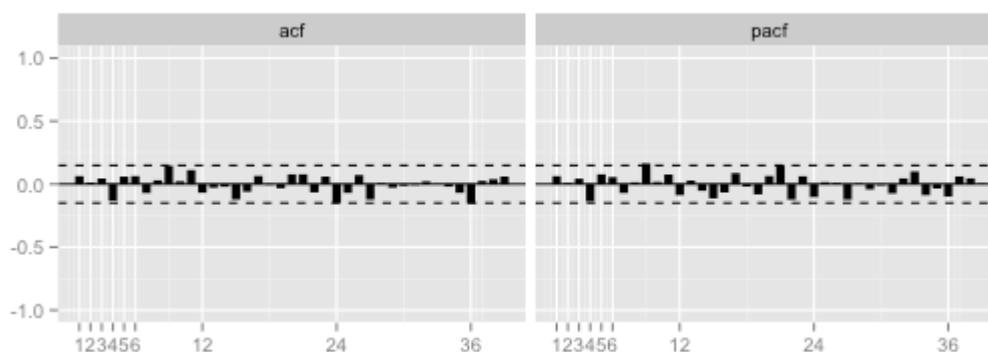


Gráfico No. 9: Residuos ACF y PACF

De acuerdo al Gráfico No.8 de los residuos del modelo 0 se observa que el comportamiento de la serie tiene una distribución relativamente estacionaria. Mientras la función de autocorrelación(ACF) y la función de autocorrelación parcial(PACF) en los residuos evidencia que existe un remanente de dinámica que no fue recogido por el modelo 0 lo cual evidencia la capacidad del modelo para mejorarlo y tener mejores resultados.

4.2 Modelo 1: Planteamiento, estimación y diagnóstico

El estudio de series en el tiempo evidencia las características y su comportamiento de acuerdo a la interacción de sus variables en el tiempo, existen ciertas series temporales que de acuerdo a sus tipologías se deben someter a una análisis de homogenización debido a que presentan anomalías que se repiten anualmente, y no son recogidas en la parte estacional de la serie.

Estos componente de variabilidad sistemática pero de carácter irregular se pueden presentar durante periodos concretos. Para el estudio se toma en cuenta el periodo de Semana Santa donde la empresa tiene mayor irregularidad y es necesario conocer su efecto en el tiempo, ya que esta se presenta en distintos periodos mensuales(marzo-abril). El periodo comprendido en Semana Santa es una variable analizada en distintas series de tiempo ya que tiene efectos significativos en múltiples series económicas. Lo cual nos permite tener un idea clara de cómo analizar dicho efecto.

A partir del modelo 0 se plantea formular un modelo complementario que sea capaz de recoger el efecto, que permite predecir con mayor precisión los datos en el modelo. A continuación se presenta el modelo propuesto.

$$\nabla\nabla_{12}lny_t = w_1\nabla\nabla_{12}\xi_t^{SS} + U_t, \text{ con } (1 - \phi_1B - \phi_2B^2)(1 - \Phi_1B^{12} - \Phi_2B^{24})U_t = A_t$$

Donde ξ_t^{SS} es una variable que toma el valor de 1 en el mes que se se encuentra el periodo con variabilidad sistemática de carácter irregular y 0 en el resto de meses, $(1 - \phi_1B - \phi_2B^2)$ representa el operador AR(Autoregresivo de Orden 2), y $(1 - \Phi_1B^{12} - \Phi_2B^{24})$, presenta el operador SAR(Estacional Autoregresivo de Orden 2), y donde $\nabla\nabla_{12}$, representa` la diferencia regular diferencia estacional y donde lny_t representa la transformación de la serie.

A continuación en el Grafico No.8 se muestra los resultados del modelo que recoge el Efecto de Semana Santa.

```

ARIMA(2,1,0)x(2,1,0)_{s=12} . Time series: log(cem1) (lambda= NULL )

      Estimate   Std.Dev   t.test   p.value
ar1    -0.4401542  0.08764293 -5.022130 5.110145e-07
ar2    -0.2066857  0.09399969 -2.198791 2.789280e-02
sar1    -0.1561274  0.09068243 -1.721694 8.512500e-02
sar2    -0.3400148  0.08934714 -3.805548 1.414904e-04
sSemSan -0.1121592  0.02253768 -4.976519 6.473794e-07

Sigma^2 = 0.006421904 . Log.Lik= 148.3364 , AIC= -284.6728

Correlation matrix
      ar1      ar2      sar1      sar2      sSemSan
ar1    1.00000000  0.37071340  0.126393854  0.10932125 -0.061544645
ar2    0.37071340  1.00000000  0.140684873  0.01175998 -0.363698623
sar1    0.12639385  0.14068487  1.000000000  0.10846583 -0.007526437
sar2    0.10932125  0.01175998  0.108465834  1.000000000 -0.026369578
sSemSan -0.06154465 -0.36369862 -0.007526437 -0.02636958 1.000000000

      Statistic d.f.   p.value
L-B Q  59.75806   NA  0.004112312
J-B   12.73257   NA  0.001718532

```

Grafico No. 10: Resultados Modelo 2 Efecto Semana Santa

De acuerdo a los resultados de modelo 1 podemos observar que los contrastes de significación individuales señalan que los parámetros de estudio son significativos para todos con un $\alpha = 0.10$, sin embargo utilizando un $\alpha = 0.05$ que es más preciso la variable correspondiente al SAR(1) no es significativa. Por lo tanto los resultados evidencian que el efecto de la Semana Santa es significativo y está presente dentro del

modelo, el valor del coeficiente es 11% lo que se puede interpretar como las irregularidades que se presentan en la empresa en el uso de suelos.

A continuación se presenta el Grafico No.11 donde se presenta los residuos del modelo 1 y en el Grafico No. 12 la función de autocorrelación(ACF) y la función de autocorrelación parcial(PACF).

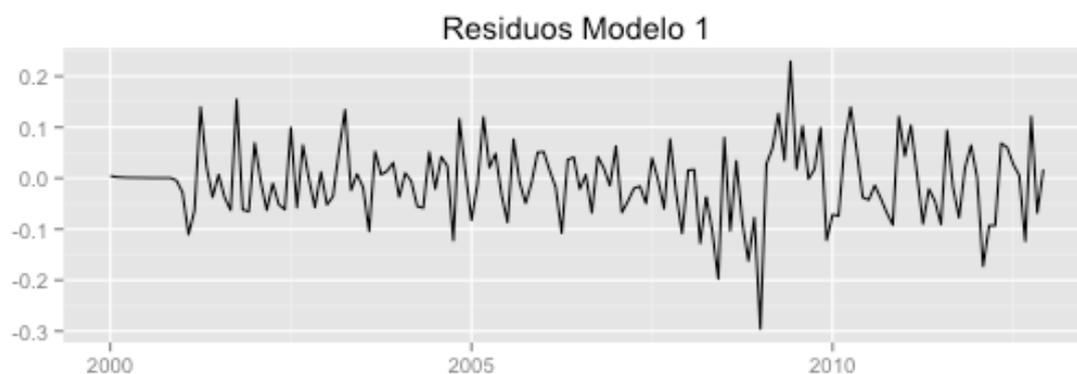


Grafico No. 11: Residuos Modelo 1

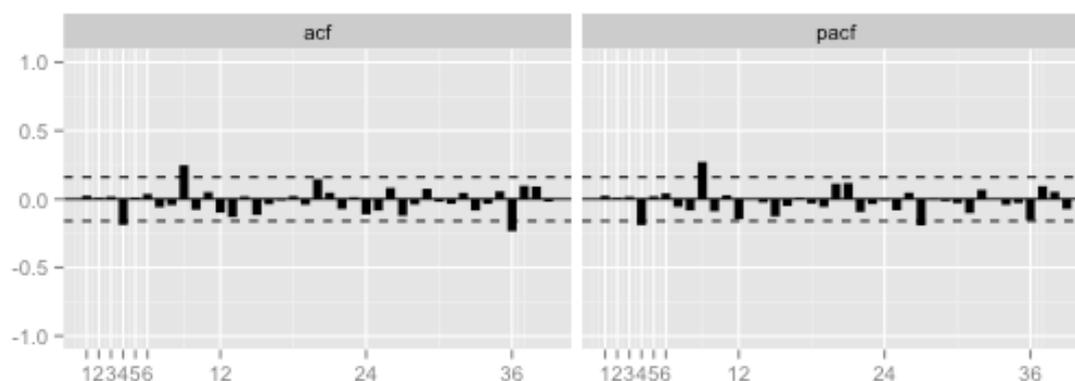


Gráfico No. 12: Modelo 1 ACF y PACF

De acuerdo al Gráfico No.11 y No. 12 de los residuos del modelo 1 no se observa un patrón repetitivo. En el Gráfico No. 12 la función de autocorrelación(ACF) y la función de autocorrelación parcial(PACF) podría existir dinámica de carácter residual significativo lo que nos indica que el modelo es susceptible a mejora.

4.3 Modelo 2: Planteamiento, estimación y diagnóstico

En base al modelo 1, se decide reemplazar el modelo AR(2) aproximándolo por un MA(1). Por lo tanto añadimos al modelo un $MA(1)_{12}$ estacional, dado que se recomienda utilizarlo para series estacionales.

A continuación en el Gráfico No.8 se muestra los resultados de la estimación del modelo 2.

ARIMA(0,1,1)x(2,1,1)_{s=12} . Time series: log(cem1) (lambda= NULL)

	Estimate	Std.Dev	t.test	p.value
ma1	-0.3293006	0.08167500	-4.031841	5.534169e-05
sar1	0.4046332	0.11651023	3.472941	5.147884e-04
sar2	-0.3365362	0.09609874	-3.501983	4.618088e-04
sma1	-0.7650867	0.12030485	-6.359566	2.023242e-10
sSemSan	-0.1203932	0.01817041	-6.625786	3.454059e-11

Sigma^2 = 0.005311203 . Log.Lik= 156.82 , AIC= -301.6401

Correlation matrix

	ma1	sar1	sar2	sma1	sSemSan
ma1	1.00000000	0.16459537	-0.07409823	-0.24992318	-0.01927392
sar1	0.16459537	1.00000000	0.06366805	-0.63735151	0.01445269
sar2	-0.07409823	0.06366805	1.00000000	-0.35908014	-0.06470095
sma1	-0.24992318	-0.63735151	-0.35908014	1.00000000	0.01338428
sSemSan	-0.01927392	0.01445269	-0.06470095	0.01338428	1.00000000

	Statistic	d.f.	p.value
L-B Q	36.23088	NA	0.3649120569
J-B	15.44916	NA	0.0004418334

Grafico No. 13: Modelo 2 con MA(1)

De acuerdo a los resultados podemos observar que los contrastes de significación individuales señalan que los parámetros de estudio son significativos y explican el modelo.

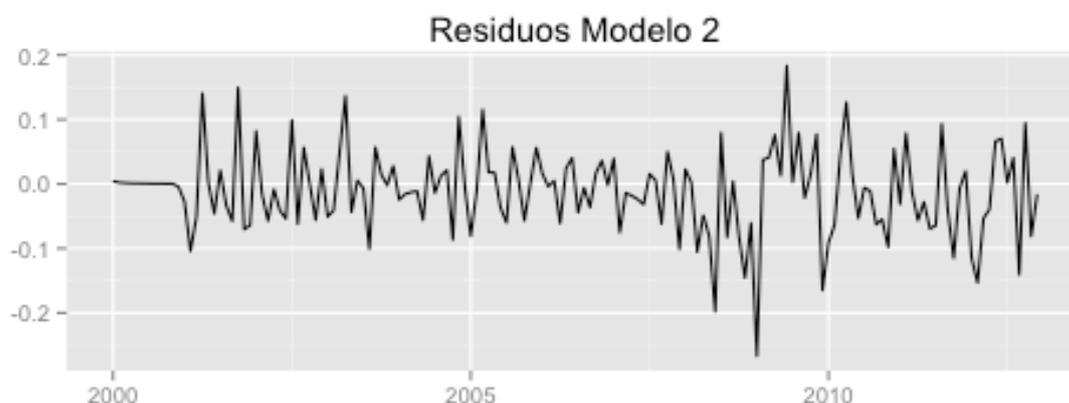


Grafico No. 14: Residuos Modelo 2

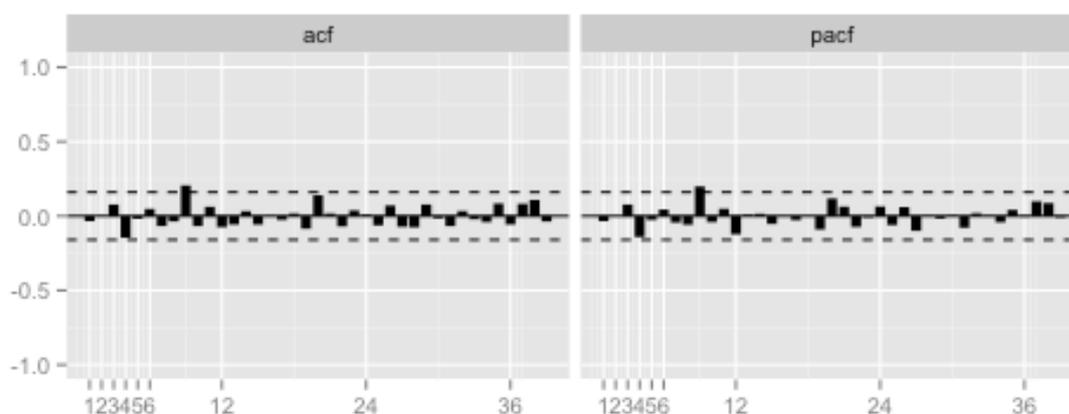


Grafico No. 15: Modelo 2 ACF y PACF

De acuerdo al análisis del Grafico No.11 y No. 12 de los residuos del modelo 2 se observa características de un comportamiento estacionario. En el Grafico No. 12 la función de autocorrelación(ACF) y la función de autocorrelación parcial(PACF) se evidencia también la carencia de dinámica significativa lo que nos indica que se distribuyen siguiendo un modelo de ruido blanco y no contienen más información

relevante que deba ser incluida en el modelo. De acuerdo a la estimación y resultados obtenidos el modelo 2, es el que mejor describe el comportamiento de la serie.

5. RESULTADOS

5.1 Contraste de Modelos

Para determinar la validez y el ajuste de los modelos analizados respecto a los datos reales se realiza una comparación de pronósticos desde enero del 2013 hasta diciembre del 2014. Los pronósticos y la serie de datos reales permitirá identificar el comportamiento de la variable estudiada y los cambios que tiene en función del tiempo.

A continuación se prestan los modelos 1 y 2 para efectos de comparación con los datos reales de la serie; ya que fueron los modelos que tuvieron un mejor ajuste durante el diagnóstico y estimación, respecto a la significancia de sus variables.

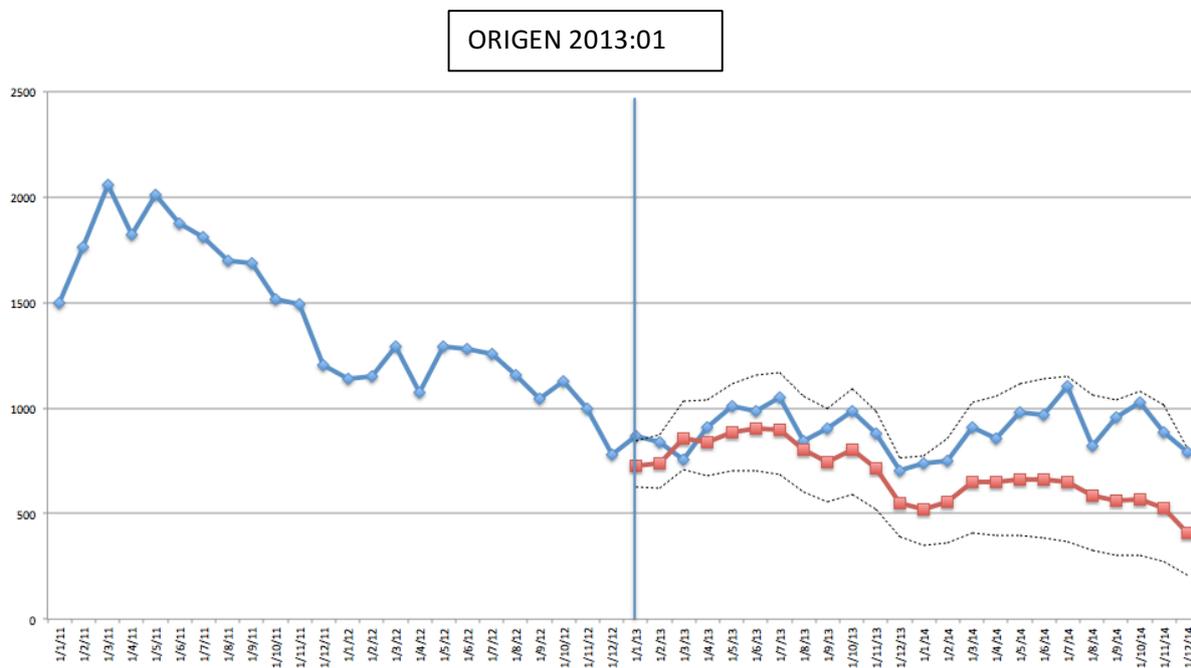


Grafico No. 16: Pronósticos Modelo 1

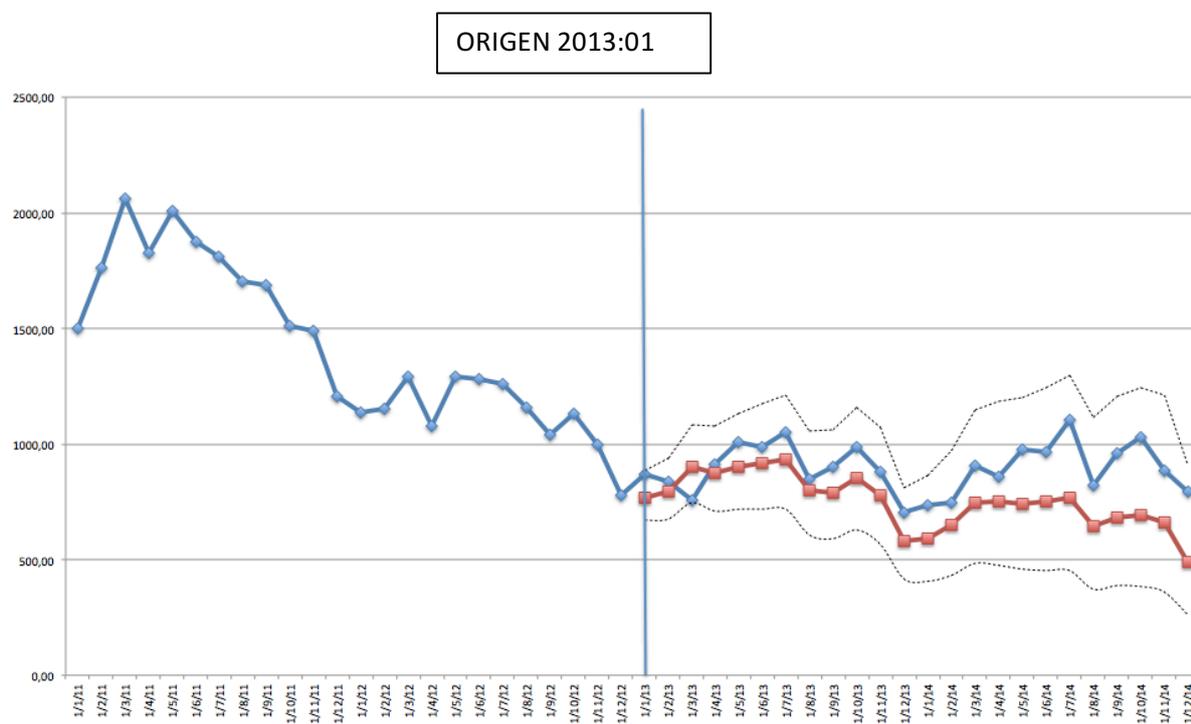


Grafico No. 17: Pronósticos Modelo 2

Indicadores	RMSE	MAE	MAPE
Modelo 1	250,077	219,805	24,3%
Modelo 2	179,307	156,555	17,3%

Tabla No. 1: Indicadores RMSE, MAE, MAPE

De acuerdo a los resultados en los modelos, los indicadores de medidas de error en los pronósticos muestran que el modelo 2 tiene menor diferencia entre los datos reales y los pronosticados; el MAE(Error Absoluto en la Media), el RMSE(la raíz del error cuadrado medio, y el MAPE(porcentaje promedio absoluto del error) son menores en la estimación de la serie temporal respecto al uso del suelos de la empresa Corporación para los Recursos Naturales S.A , tener un porcentaje de error menor al 30% en predicción de datos futuros es un resultado robusto para un modelo (Montgomery & Runger, 2007). El modelo 2 tiene 17,3% de porcentaje de error, por lo tanto, se considera el mejor modelo para realizar pronósticos sobre la serie temporal de estudio.

Por lo tanto la serie temporal de uso de suelo de la empresa Corporación para los Recursos Naturales S.A está mejor explicada a través de la dinámica $ARIMA(0,1,1) \times (2,1,1)_{12}$ por lo tanto el comportamiento se describe con el modelo:

$$(1 - 0.40B^{12} + 0.33B^{24})\nabla\nabla_{12} \ln y_t = (1 - 0.33B)(1 - 0.76B^{12}) - 0.12\nabla\nabla_{12} \xi_t^{SS} + A_t$$

6. CONCLUSIONES Y RECOMENDACIONES

6.1 Conclusiones

Se logró recopilar datos fiables para realizar un análisis robusto de la serie temporal del uso de suelos de la empresa Corporación para los Recursos Naturales S.A, mediante el análisis de la serie se pudo determinar el comportamiento de los datos y el efecto que irregular que generaba el efecto calendario en la serie de estudio.

La transformación de los datos de la serie para estabilizar la media y varianza se hizo por medio de una transformación logarítmica. Adicionalmente, se tomó una diferencia regular y una diferencia estacional lo cual permitió proponer modelos ARIMA para simular el comportamiento de la serie de uso de suelos y realizar un contraste entre los datos reales y los pronosticados.

El modelo 2 $ARIMA(0,1,1) \times (2,1,1)_{12}$ fue el que mejor explico el comportamiento de la serie con un error de pronóstico de 17%, lo cual indica la validez del modelo para modelar la variable de estudio.

6.2 Recomendaciones

Se recomienda que la empresa Corporación para los Recursos Naturales S.A, realice su planificación en base al uso de series de tiempo, para que sus pronósticos de uso de suelo les permita asignar sus recursos productivamente derivando en un aumento de eficiencia y eficacia en el manejo de personal y recursos de la empresa, que a largo plazo se reflejara en la minimización de costos y maximización de su utilidad.

Se recomienda que la empresa realice una minería de datos en sus procesos productivos, para que la base obtenida permita analizar el comportamientos de los datos y esto se pueda traducir en mejoras dentro de la empresa, beneficiando al cliente interno como al cliente externo.

7. BIBLIOGRAFÍA

- Project Management Institute. (2014). *Guía de los Fundamentos de la Dirección de Proyectos* (Vol. Cuarta Edición). Newtown Square, Pennsylvania, USA: PMI.
- Kaleshovska, N. (2014). Adopting PMO to explore the true benefits of project management. *Profesional Paper*, pág. 16.
- Montgomery, D., & Runger, G. (2007). *Probabilidad y Estadística aplicadas a la Ingeniería*. Limusa Wiley.
- Adebiyi, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Stock Price Prediction Using the Arima Model. *UKsim-Amss 16th International Conference on Computer Modelling and Simulation*, 8.
- Reyes, P. (2007). *Metodología de Análisis con Series de Tiempo*.
- Atsalakis, G. S., Dimitrakakis, E. M., & Zopounidis, C. D. (2011). Elliot Wave Theory and neuro-fuzzy systems market prediction. *Expert System with Applications*, 38, 20.
- Box, G. E., & Jenkins, G. M. (1976). *Time Series Analysis Forecasting & Control*. San Francisco, California, USA: Holden-Day.
- Morana, C. (Mayo de 2001). A semiparametric approach to short-term oil price forecasting. *Energy Economics*, 23(3), 15.
- Cho, M. Y., Hwang, J. C., & Chen, C. S. (2014). Customer Short Term Load Forecasting. (N. K. Technology, Ed.) *Arima Transfer Function Model*, 6.

- Tsitsika, E. V., Maravelias, C. D., & Haralabous, J. (2007). Modeling and forecasting pelagic fish product using univariate and multivariate Arima Models. *Hellenic Center for Marine Research*, 12.
- Studenmund, A. H. (2012). *Using Econometrics: A Practical Guide* (Vol. Sixth Edition). (O. College, Ed.) New York, NY, USA: Pearson .
- Alvarez, C. (24 de 03 de 2016). Corporación para los Recursos Naturales S.A. *CORENA*. (J. P. Ortiz, Entrevistador)
- Wooldridge, J. (2001). *Introducción a la Econometría: Un enfoque moderno*. Michigan , USA: Thomson Learning .
- Enders, W. (2014). *Applied Econometric Time Series* (Fourth Edition ed.). Alabama, USA: Wiley.
- Cabrer, B. (2004). *Economía Empresarial*. Valencia, España: ADE.
- Hurtado, C. (2008). *Serie de Tiempo*. Topico en Minería de Datos, Universidad de Chile: Facultad de Ciencias Físicas y Matemáticas, Departamento de Ciencias de la Computación.
- Econometría Novales. (2010). *Modelo de Series Temporales*. Estudio Técnico, Economía.
- Villavicencio, J. (2012). *Introducción a Series de Tiempo*. Recuperado el 24 de Febrero de 2016, de Estadísticas: http://www.estadisticas.gobierno.pr/iepr/LinkClick.aspx?fileticket=4_BxecUaZmg%3D

Facultad de Ciencias Economicas y Empresariales. (2009). Recuperado el 12 de 03 de 2016, de Analisis de Series Temporales: ARIMA: <https://addi.ehu.es/bitstream/10810/12492/1/04-09gon.pdf>

Chai, T., & Draxler, R. R. (30 de Junio de 2014). Root mean square error (RMSE) or Mean absolute error(MAE)? . *Geoscientific Model Development*.