

Uso de series temporales para el análisis y predicción de consumo de materia prima en la industria maquiladora

Hugo Alberto Morales Casas, Francisco López Orozco,
Vicente García Jiménez

Universidad Autónoma de Ciudad Juárez,
Instituto de Ingeniería y Tecnología,
Maestría en Cómputo Aplicado,
México

hugomoca98@gmail.com, francisco.orozco@uacj.mx

Resumen. Los pronósticos de consumo de materia prima dentro de la industria maquiladora representan una de las etapas más importantes para el cumplimiento y satisfacción de las órdenes del cliente en tiempo y forma. Dentro de un esquema tradicional, las estimaciones se llevan a cabo con el uso de fórmulas matemáticas simples que van desde un promedio mensual hasta el incremento porcentual en tasas del 10% al 15% de un periodo a otro. Sin embargo, los resultados no siempre resultan satisfactorios. Por esta razón, la aplicación de técnicas de aprendizaje máquina podrían ofrecer una mejora de las estimaciones mensuales de consumo de energía eléctrica, producción agrícola y manufacturera, utilizando modelos de series temporales como “autoregressive integrated moving average”, (ARIMA). Su aplicación en modelos estacionales previamente demostrados por las pruebas de “Dickey-Fuller”, (DF) y “Kwiatkowski-Phillips-Schmidt-Shin”, (KPSS) para conjuntos de datos de al menos 3 años de registro histórico brinda apoyo para la reducción de incrementos y decrementos de demanda en la industria maquiladora. En este trabajo se propone el uso de series temporales (ST) basados en una mezcla del modelo tradicional de las ST y el modelo “Obtain – Scrub – Explore – Model – Interpret”, (OSEMN) para la estimación de consumo de materiales tales como resinas plásticas, rollos de metales dentro de la industria eléctrica doméstica, considerando solamente una parte del universo de números de parte que cuentan con características de estacionalidad.

Palabras clave: ARIMA; time series; forecasting.

Use of Time Series for the Analysis and Prediction of Raw Material Consumption in the Maquiladora Industry

Abstract. Raw material consumption forecasts within the maquiladora industry represent one of the most important stages for the fulfillment and satisfaction of customer orders in a timely manner. Within a traditional scheme, estimates are carried out with the use of simple mathematical formulas that range from a monthly average to the percentage increase in rates of 10% to 15% from one period to another. However, the results are not always satisfactory. For this reason, the application of machine learning techniques could offer an improvement in the monthly estimates of electrical energy consumption, agricultural and manufacturing production, using time series models such as "autoregressive integrated moving average", (ARIMA). Its application in seasonal models previously demonstrated by the "Dickey-Fuller" (DF) and "Kwiatkowski-Phillips-Schmidt-Shin" (KPSS) tests for data sets of at least 3 years of historical record provides support for the reduction of increases and decreases in demand in the maquiladora industry. This work proposes the use of time series (ST) based on a mixture of the traditional model of the ST and the model "Obtain - Scrub - Explore - Model - Interpret", (OSEMN) for the estimation of consumption of materials such as plastic resins, metal coils within the domestic electrical industry, considering only a part of the universe of part numbers that have seasonal characteristics.

Keywords: ARIMA; timeseries; forecasting.

1. Introducción

El análisis del comportamiento de la demanda de materia prima en el sector maquilador representa una de las mayores áreas de oportunidad dentro de este rubro. El abastecimiento y el proceso que conlleva la logística para la cadena de suministros (Supply Chain) es uno de los principales problemas para lograr el cumplimiento de las entregas en tiempo para el cliente al 100% (On Time Delivery). Cabe mencionar también que esta situación es crucial en dicha industria orientada al cliente al momento de otorgar alguna certificación o una nueva oportunidad de negocios.

Los sistemas de mejora continua que resultan ser aplicados en la industria maquiladora convencional mencionan que dentro de los tópicos primordiales para un On Time Delivery al 100% es el abastecimiento óptimo de materia prima (Raw Material), así como la identificación de forma categórica de los números de parte, por ejemplo, A, B o C dependiendo de su uso temporal en al menos 52 semanas (1 año) [1].

Sin embargo, la metodología que es aplicada en la mayoría de las empresas al momento de asignar una categoría A, B o C a los números de parte de materia prima y producto terminado, consta del cálculo de un promedio de uso dentro de un rango segmentado por meses durante por menos un año, buscando tener un aprovechamiento

óptimo de la materia prima. De esta forma se asegura en todo momento disponibilidad, sin tener grandes excedentes ni la falta de el mismo. Esto en algunas ocasiones deriva en la falta de materia prima durante los periodos de temporada alta, y exceso de inventario en las temporadas bajas, ya que el consumo de materia se proyecta como un pronóstico similar o “estable” durante todo el año, el cual no siempre resulta ser así.

En la actualidad, la búsqueda de patrones y tendencias en los comportamientos diarios como sociedad, se puede ver reflejado en la implementación de técnicas de aprendizaje máquina (AM), en actividades cotidianas [4], con el fin de encontrar alternativas y soluciones que sean más simples a las tareas realizadas por el ser humano. Basta con dar un vistazo a algunas herramientas de uso diario, y en las que de alguna forma el AM se ve involucrado.

Desde sugerencias publicitarias apareciendo en redes sociales por medio de algoritmos que analizan conjuntos de búsquedas en el navegador, aplicaciones de compra y venta, palabras claves mencionadas a voz dentro de conversaciones cotidianas, e inclusive por medio de rutinas de traslado y ubicación GPS [5] que son analizadas por medio de técnicas para el procesamiento de datos.

Estas técnicas logran ser aplicadas en escalas aún mayores, como lo son el análisis de tendencias en temporadas electorales, logrando influenciar de forma crítica en las decisiones políticas de la población de un país [6].

Sumado al afán de identificar y establecer rutinas para cada día de la semana, con la intención de obtener una mayor administración para las tareas del hogar con ayuda de la domótica, y de esta forma evitar algún imprevisto a futuro gracias a que estas actividades logran ser identificadas por medio de patrones con múltiples similitudes, a veces aún más notorias de lo que se puede esperar [7].

Es aquí donde el aprendizaje máquina toma relevancia, identificando, descubriendo nuevas y significativas relaciones, modelos, así como tendencias al evaluar grandes cantidades de datos con la ayuda de tecnologías de reconocimiento de patrones, redes neuronales, lógica difusa, algoritmos genéticos, entre otros [8].

Por ejemplo, ciudades fronterizas donde se encuentran instaladas una gran cantidad de complejos maquiladores, por lo que se convierten en un gran campo de oportunidades para la integración de técnicas para el análisis de datos como las series temporales, tal y como se propone en este trabajo, el cual aplica técnicas basadas en aprendizaje máquina para el análisis y pronóstico del proceso de requisición de materia prima a proveedores del sector maquilador en un periodo de tres años.

Resultando que de esta forma más órdenes de producto terminado lleguen al cliente en tiempo, logrando un aprovechamiento óptimo de energías renovables actuales, e impulsando su correcta sustitución en hogares y automóviles donde aún no han sido implementadas.

2. Trabajos relacionados

En la actualidad existen herramientas teóricas basadas en la experiencia de grandes corporativos industriales como Toyota, basados en el concepto de mejora continua o “*Lean Manufacturing*”. Sin embargo, no resultan ser totalmente efectivas al momento de planear y realizar pronósticos (*forecast*) de consumos para la materia prima. El uso de herramientas de aprendizaje máquina o series temporales podría ayudar a obtener mejores resultados para el pronóstico de datos basados en los registros de usos

históricos con una mayor efectividad y fluidez, beneficiando a la industria maquiladora en el ramo eléctrico, como es el caso de Ciudad Juárez.

De esta manera se brindan pronósticos a proveedores con mayor efectividad y ofertando una reducción de costos ocasionados por tiempo extra de producción, costo de expeditado y compras con proveedores provisionales (*Spot Buy*), con quienes el material resulta ser más costoso de lo habitual al momento de intentar cubrir los requerimientos del cliente en tiempo.

Así más órdenes de producto terminado llegarían al cliente en tiempo y forma, logrando un aprovechamiento óptimo de energías renovables actuales, e impulsando su correcta sustitución en hogares y automóviles donde aún no han sido implementadas.

En el año 2016, Delgadillo [9], presentó su trabajo en el cual se emplearon diversas herramientas con la intención de realizar una comparativa en el pronóstico de series de tiempo aplicados a la producción de granos básicos en México

Esto, con la intención de predecir sus valores a corto plazo, aplicando modelos como *Autoregressive Integrated Moving Average* (ARIMA), el cual es una combinación de los parámetros de Auto Regresión (AR) e Integrado (I) a los modelos de medias móviles (MA) [10], modelo de Brown, suavización simple y modelo de Holt.

La integración de dichos modelos cuenta con antecedentes en trabajos realizados dentro de países como Canadá dentro de la predicción de producción de trigo y Bangladesh para la papaya, piña y mango utilizando modelos de series temporales ARIMA. Delgadillo utilizó registros de 112 años en segmentos mensuales, (1897 a 2009), provenientes de la organización federal SAGARPA.

Además de esto, se implementó el modelo ARIMA en sus cuatro etapas: Identificación, estimación, comprobación, pronóstico. Durante el proyecto, se realizaron pruebas con otros modelos, sin embargo, el modelo ARIMA fue el que presentó mejores resultados, brindándole de esta forma estimaciones hasta el año 2020, y 2050, siempre teniendo en cuenta que podrían verse afectadas por la gran distancia en años entre los datos originales a los estimados.

Por otro lado, dentro de la industria manufacturera de la India, Siregar [11] aplica la metodología ARIMA y Box – Jenkins para los pronósticos de ventas del año 2015. Los datos utilizados corresponden a las ventas de productos plásticos en el periodo mensual durante los años del 2012- 2014.

Además de esto, aplica métricas de error porcentual absoluto medio, (MAPE) para medir el nivel de error obteniendo resultados de entre el 68% y 74% de efectividad, planteando una posibilidad de aventajamiento ante la competencia industrial para ser más competitivos y ofrecer productos de calidad en tiempo y forma para los clientes.

Debido a que mantener un pronóstico débil o pésimo, orilla a las compañías a generar niveles bajos de inventario y un servicio ineficiente, es posible identificar de esta forma las métricas de ventas como un área de mejora.

Antes de comenzar con el análisis de datos, estos fueron preprocesados por medio de tres etapas: Limpieza, donde el autor removió los posibles puntos de ruido, se rellenaron los campos faltantes, y se identificaron “Outliers”, Integración de los datos, donde se combinaron los conjuntos de datos correspondientes a los años del 2012 a 2014, y la selección de datos, donde se escogieron las muestras relevantes y necesarias para el pronóstico.

En 2018 A. Rafael [12] realizó una comparativa de diversos modelos predictivos, esto debido a que no es posible aplicar la misma metodología de solución en diversos



Fig. 1. Adaptación del Modelo Obtain – Scrub – Explore – Model – Interpret (OSEM), presentado por Chen Han Lau, con inclusión de modelo tradicional en la sección de modelado e interpretación [14].

problemas. Su efectividad depende totalmente de los parámetros con los que se cuente dentro de los datos a analizar.

A. Rafael comparó resultados obtenidos al evaluar 95 diferentes conjuntos de datos para producción de chocolate en Australia, dentro de periodos mensuales durante los años de 1960 a 1990. Se aplicaron modelos como SARIMA, ARIMA, KNN y el modelo de Máquina de Soporte Vectorial (SVM).

Resultando el modelo SARIMA el que mejores resultados ofreció al término del análisis. Rafael utilizó la metodología de series de tiempo, la cual permite estimar los parámetros para posteriormente realizar predicciones de datos.

En algunas ocasiones, como parte de la etapa de preprocesamiento es necesario tratar la información antes de ingresarla al modelo seleccionado de evaluación. Llegando inclusive a aplicar técnicas de imputación de datos.

De hecho, Osman [13] lo identifica como uno de los principales problemas presentes en las series de tiempo. Por esta razón, en 2018 elaboró un estudio para identificar qué metodología de imputación resultaría ser la óptima dentro de los sistemas de distribución de agua. Utilizando desde metodologías básicas y tradicionales, hasta las más complejas.

Estos fueron clasificados en grupos de imputación por: media, valores aleatorios, proceso Gaussiano y regresión lineal. Siendo los primeros dos, parte de los modelos más simples de utilizar al momento de trabajar con información faltante dentro de las series de tiempo. Sin embargo, la principal desventaja que presentan corresponde a la pérdida de valores estadísticos de posible relevancia, como lo son incrementos estacionales.

Por otro lado, los últimos dos modelos pertenecen a la familia de aprendizaje máquina, resultando ser más sofisticados, un poco más costosos y para este caso de estudio presentando mejores resultados debido a la gran cantidad de datos disponibles para el estudio.

3. Metodología

En este trabajo se propuso como base de modelación un método tradicional del proceso de ciencia de datos (Data Science), también conocido como modelo O.S.E.M.N. (Obtain – Scrub – Explore – Model – Interpret), representado en la Figura 1, donde para el caso de la obtención de datos, se llevó a cabo un proceso de recopilación mensual de registros de consumo durante el periodo de enero 2019 a diciembre 2021 en una fábrica maquiladora perteneciente al sector electro en Ciudad Juárez, Chihuahua.

La base de datos original consta de 10,000 números de parte, correspondientes únicamente a materia prima obtenida directamente de proveedor, y números de parte enviados desde otras divisiones correspondientes a la misma compañía manufacturera (transferencias inter-planta).

Para el caso de la limpieza de datos, los registros como primera instancia se obtuvieron directamente en formato xls, con algunos vacíos de registros en semanas donde no se utilizó el material. Dichos espacios en blancos fueron rellenados con ceros y además de eso se estandarizaron a valores numéricos con valor decimal.

Al momento de seleccionar las muestras experimentales, se utilizaron números de parte que tuvieran movimientos en cada uno de los treinta y un meses de registros, no importando la unidad de medida.

En el caso de la exploración, los datos fueron dispuestos en tablas y gráficas de barras para la identificación de estacionalidad de uso. El modelado y resultados fueron basados en muestras previamente comprobadas como datos estacionales con la aplicación de las pruebas estacionalidad de Dickey-Fuller (DF) y Kwiatkowski-Phillips-Schmidt-Shin (KPSS), las cuales son pruebas utilizadas dentro del análisis estadístico para la verificación de la existencia o no de raíces unitarias dentro de una serie de tiempo [15], además de comprobar estadísticamente si dicha serie es estacionaria o no [16].

Después para cada uno de los números de parte analizados fueron aplicadas las pruebas de DF y KPSS, corroborando la estacionalidad. Las series estacionales series mantienen sus características estadísticas (valor medio, desviación estándar, etc.), a lo largo del tiempo analizado. Esto quiere decir que no es un comportamiento transitorio, por lo que tiene duración y largo infinito, al menos teóricamente [17].

3.1. Desarrollo

Para propósitos de este artículo, fueron seleccionados únicamente 5 diferentes números de parte (identificados como “Número de parte 1,2,3,4,5” en tablas posteriores) que cumplieran con las características anteriormente mencionadas, registro mayor a cero de consumo en cada uno de 31 meses estudiados en el presente trabajo, es decir, se hubieran utilizado al menos una vez en el mes registrado.

Se realizaron pruebas aplicando los modelos *Moving Average* (MA), *Weight Moving Average* (WMA) y ARIMA. Para los modelos de MA y WMA se consideraron parámetros de *lags* igual a tres.

Así mismo, los pesos para el modelo de WMA fueron asignados desde tres a uno, en forma descendiente. Finalmente, para la asignación de los valores P y Q de modelo ARIMA se utilizaron las funciones de Auto Correlación y Auto Correlación Parcial respectivamente. Los registros fueron separados en dos grupos, uno de entrenamiento con el 66% de los datos y 34% de prueba.

Para el primer número de parte se aplicaron los tres métodos de predicción. En la Figura 2, podemos observar el comportamiento que registro dentro de los 31 meses analizados, así mismo dentro de la Tabla 1, podemos observar los resultados obtenidos para cada uno de los modelos aplicados en este número de parte y visualmente en la Figura 3.

Este mismo procedimiento fue aplicado para el resto de las 5 piezas analizadas.

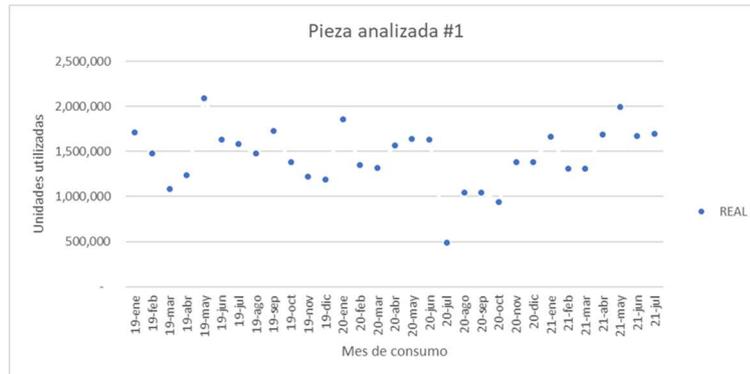


Fig. 2. Correspondiente a la pieza analizada #1 de parte seleccionado, en él se muestran los comportamientos de consumo a lo largo de 31 meses.

Tabla 1. Correspondiente a la pieza analizada #1, en ella se muestran los resultados obtenidos aplicando los 3 diferentes modelos, además de los resultados esperados o reales.

Mes	REAL	MA	WMA	ARIMA (1,1,0)
20-sep	1,046,833	1,053,865	956,554	904,666
20-oct	942,286	859,970	953,038	1,046,309
20-nov	1,384,952	1,011,257	994,196	967,369
20-dic	1,378,733	1,124,690	1,181,044	1,275,871
21-ene	1,666,592	1,235,324	1,308,065	1,380,224
21-feb	1,310,902	1,476,759	1,523,699	1,597,478
21-mar	1,310,902	1,452,076	1,440,771	1,400,490
21-abr	1,687,517	1,429,465	1,370,184	1,310,902
21-may	1,994,980	1,436,440	1,499,210	1,594,341
21-jun	1,673,653	1,664,466	1,778,479	1,925,291
21-jul	1,693,876	1,785,383	1,783,073	1,749,858

3.2. Validación de resultados

Como parte de la validación de resultados se aplicó el error MAPE (Error Porcentual Absoluto Medio o Mean Absolute Percentage Error por sus siglas en inglés), comparando los valores reales con los obtenidos en cada uno de los modelos predictivos. Otorgando resultados muy próximos, y en 3 de ellos teniendo un error menor para ARIMA, los cuales se encuentran resaltados en color verde.

También se aplicó el error MSE (Error Cuadrático Medio o por sus siglas en inglés mean squared error) como parte de validación de resultados, dentro de la Tabla 3, podemos observar los resultados obtenidos, siendo los remarcados en verde los mejores para dichos experimentos. Donde en esta ocasión solamente para uno de ellos se presentó una menor cantidad de error en la categoría de ARIMA.

Además de esto, se realizaron pruebas T. Student aplicado a la comparativa de cada uno de los resultados obtenidos al aplicar el cálculo de errores MAPE y MSE.

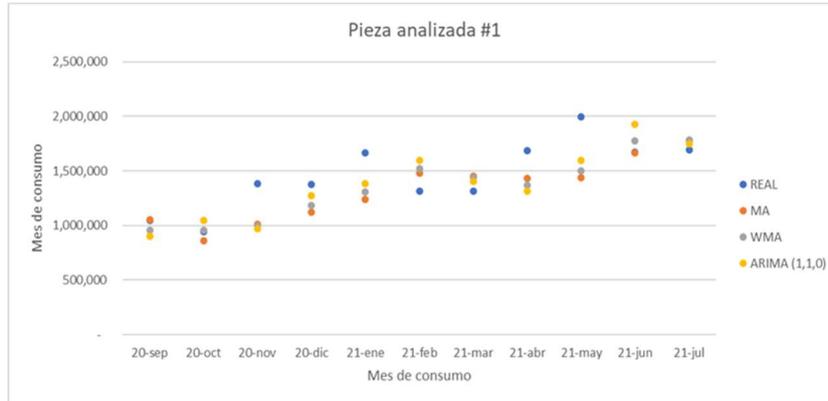


Fig. 3. Comparativa para los últimos 11 meses, correspondiente al 34% de los datos, donde se puede observar el comportamiento que presento cada uno de los modelos aplicados contra los registros reales de uso.

Tabla 2. Comparación de porcentaje de error MAPE para cada una de las piezas analizadas.

	MAPE / REAL-MA	MAPE / REAL-WMA	MAPE / REAL-ARIMA
Número de parte 1	13.9%	14.1%	15.4%
Número de parte 2	9.1%	8.5%	6.6%
Número de parte 3	16.8%	17.4%	16.7%
Número de parte 4	16.4%	17.1%	16.6%
Número de parte 5	31.5%	31.0%	30.6%

Tabla 3. Comparación de porcentaje de error MSE para cada una de las piezas analizadas.

	MSE / REAL-MA	MSE / REAL-WMA	MSE / REAL-ARIMA
Número de parte 1	75,587,017,701	68,741,895,279	68,813,906,564
Número de parte 2	174,723	163,444	125,331
Número de parte 3	63,650,560,805	62,946,768,760	65,218,856,112
Número de parte 4	59,016,581,648	58,724,258,348	61,906,662,175
Número de parte 5	47,658,823,669	48,574,991,531	57,194,017,714

En la Tabla 4, podemos observar que las diferencias no resultan ser significativas al momento de aplicar la prueba T. Student, debido a que los valores arrojados por esta prueba resultan ser muy próximos entre sí.

En la Tabla 5, podemos observar resultados similares para la prueba de error MSE, donde los resultados vuelven a no presentar significancia de resultados, debido a que se encuentran próximos entre sí.

4. Conclusiones (ventajas y desventajas) y trabajo futuro

Se puede observar que el uso de metodologías como MA, WMA y ARIMA para la predicción de consumos de materia prima en la industria maquiladora, resulta ser muy

Tabla 4. Resultados obtenidos al aplicar T. Student a los resultados obtenidos por MAPE.

	MA-WMA	MA-ARIMA	WMA-ARIMA
Número de parte 1	0.484	0.359	0.365
Número de parte 2	0.357	0.114	0.172
Número de parte 3	0.460	0.493	0.457
Número de parte 4	0.451	0.489	0.467
Número de parte 5	0.470	0.447	0.473

Tabla 5. Resultados obtenidos al aplicar T. Student a los resultados obtenidos por MSE.

	MA-WMA	MA-ARIMA	WMA-ARIMA
Número de parte 1	0.430	0.426	0.499
Número de parte 2	0.355	0.104	0.160
Número de parte 3	0.492	0.484	0.477
Número de parte 4	0.497	0.468	0.466
Número de parte 5	0.470	0.309	0.328

variable y dependiente del comportamiento de los registros con los que se cuente al momento de analizar los datos.

Sin embargo, resulta ser una opción más apegada a la realidad que el uso de un promedio mensual aplicado al total de registros con los que se cuenta. Si bien los resultados al momento de les fuera aplicados la prueba de T. Student no presentaron significancia, los valores de ARIMA al momento de aplicar las pruebas de error resultaron ser menores, dando pie a una búsqueda de mayor efecto en los resultados para este modelo.

donde, las pruebas pudieran volver a repetirse con un mayor número de muestras, que contasen con más registros aplicados, cabe recalcar que 2 de los trabajos aquí citados utilizaron registros mayores a 30 años y obtuvieron como resultados valores favorables para metodología ARIMA, por lo que podemos deducir que dicho modelo funciona mejor cuando se cuenta con una base de datos más amplia.

Además de esto, una vez encontrado el rango de años adecuados para estudiar, el uso de técnicas de *clustering* podría ayudarnos a abarcar mayor cantidad de números sin profundizar en la búsqueda de parámetros P y Q para la utilización del modelo ARIMA.

Referencias

1. Liker, J. K., Franz, J. K.: El modelo Toyota para la mejora continua: Conectando la estrategia y la excelencia operacional para conseguir un rendimiento superior. Profit Editorial (2020)
2. Monleón-Getino, A.: El impacto del Big-data en la sociedad de la información. Significado y utilidad. Historia y Comunicación Social, vol. 20, no. 2, pp. 427–445 (2015)
3. Brink, H., Richards, J. W., Fetherolf, M.: Real world - Machine learning. Shelter Island, NY: Manning Publications Co (2016)
4. León-Borges, J. A., Noh-Balam, R. I., Rangel-Gómez, L. Philip-Strand, M.: The machine learning in the prediction of elections. Computación e Informática, no. 2 (2015)

5. Herrera-Quintero, L. F.: Viviendas inteligentes. *Ingeniería e Investigación*, vol. 25, no 2, pp. 47–53 (2005)
6. Perez-Lopez, C., Montero-Lorenzo, J. M.: *Minería de datos. Técnicas y herramientas. Paraninfo* (2007)
7. Delgadillo-Ruiz, O., Ramírez-Moreno, P. P., Leos-Rodríguez, J. A., Salas-González, J. M., Valdez Cepeda, R. D.: Pronósticos y series de tiempo de rendimientos de granos básicos en México. *Acta universitaria*, vol. 26, no. 3, pp. 23–32 (2016) doi: 10.15174/au.2016.882
8. Gras, J. A.: *Diseños de series temporales: Técnicas de análisis. Universidad de Barcelona* (2001)
9. Siregar, B., Nababan, E. B., Yap, A., Andayani, U., Fahmi: Andayani and Fahmi, forecasting of raw material needed for plastic products based in income data using ARIMA method. In: *Proceeding of 2017 5th International Conference on Electrical, Electronics and Information Engineering (ICEEIE)*, no. 5, pp. 135–139 (2017) doi: 10.1109/ICEEIE.2017.8328777
10. Parmezana, A. R. S., Souza, V. M. A., Batista, G. E. A. P. A.: Evaluation of statistical and machine learning models for timeseries prediction: Identifying the state-of-the-art and the best conditions for the use of each model. *Information Sciences*, vol. 484, pp. 302–337 (2019) doi: 10.1016/j.ins.2019.01.076
11. Osman, M. S., Abu-Mahfouz, A. M., Page, P. R.: A survey on data imputation techniques: water distribution system as a use case. In: *Proceeding of IEEE*, vol. 6, pp. 63279–63291 (2018) doi: 10.1109/ACCESS.2018.2877269
12. Lau, C. H.: *Towards Data Science*. [En línea] Available: <https://towardsdatascience.com/5-steps-of-a-data-science-project-lifecycle-26c50372b492> (2019)
13. Hacker, S., Abdunnasser, H. J.: *The properties of procedures dealing with uncertainty about intercept and deterministic trend in unit root testing. Royal Institute of Technology, Centre of Excellence for Science and Innovation Studies* (2010)
14. Singh, A.: *A Gentle introduction to handling a non-stationary time series in Python. Analytics Vidhya* (2018)
15. Nava, A.: *Procesamiento de series de tiempo. Fondo de cultura económica* (2015)