

UNIVERSIDAD PANAMERICANA  
FACULTAD DE INGENIERÍA

Con estudios incorporados a la  
Secretaría de Educación Pública

**“Estimación de los costos presupuestales de mano de obra para la Empresa Petrolera Mexicana: una propuesta metodológica basada en modelos autorregresivos”**

**C A S O  
P R Á C T I C O**

**QUE PARA OBTENER EL TÍTULO DE  
MAESTRÍA EN DIRECCIÓN DE OPERACIONES**

**P R E S E N T A**

**CÉSAR RIVERA PALMA**

**DIRECTORA DE TESIS:**

**Dra. Jen ai Magdalena De la Cruz Juárez**

MÉXICO, D.F.

2022

## Resumen.

El presente caso práctico tiene como objetivo implementar un modelo para el pronóstico de la mano de obra que proporcione a la Empresa Petrolera Mexicana (EPM) una herramienta confiable y veraz para la distribución del presupuesto de mano de obra y así reducir la brecha entre lo presupuestado y lo ejercido; y en consecuencia aprovechar los recursos presupuestales en el *Core business* de la EPM; la exploración y producción del crudo.

Para el alcance del objetivo fue necesario analizar empresas del ramo energético y otros ramos que hayan implementado, de manera exitosa, técnicas econométricas para la estimación de costos presupuestales en general y laborales en particular, para desarrollar un marco de referencia de dichas aplicaciones en la industria petrolera.

Contar con un modelo econométrico en la Empresa Petrolera Mexicana (EPM) representa una ventaja, respecto a la dinámica actual, que permitiría la liberación de recursos para la exploración y producción de hidrocarburos, contribuiría a incrementar la producción de petróleo en el país que desde hace algunos años ha sufrido una caída importante en la producción. Entre las aportaciones de este trabajo sobresale la creación de tres distintos productos:

1. Un modelo econométrico que nos ayude a tener un pronóstico del presupuesto, el método elegido para implementar en la EPM, es un modelo SARIMA
2. Un repositorio para poder contar con el historial de los pronósticos que se vayan realizando
3. Una página web donde se puede consultar y visualizar el pronóstico del presupuesto por subdirecciones.

A lo anterior habría que sumar el cumplimiento del objetivo del trabajo, la reducción de la brecha entre el costo presupuestado y el ejercido.

### **Dedicatoria y agradecimientos.**

Quiero agradecer a mi mamá por haberme inculcado a luchar siempre por mis sueños y nunca darme por vencido; por enseñarme que el único obstáculo e impedimento somos nosotros mismos.

A mi hermana, por el apoyo que siempre me ha brindado; porque puedo confiar en ella totalmente; dispuesta siempre para ayudarme.

A mi asesora de tesis, ya que con sus conocimientos me ayudó a plasmar de una manera más entendible los datos relevantes ya que es una de las cosas más importantes del caso práctico para poder explicarlo y sea comprensible.

## Índice de contenido.

	<b>Pág.</b>
Introducción .....	<u>8</u>
Capítulo 1. Antecedentes .....	<u>12</u>
Capítulo 2. Diagnóstico de la situación .....	<u>15</u>
Capítulo 3. Marco teórico .....	<u>23</u>
Capítulo 4. Solución propuesta e implementación .....	<u>41</u>
Capítulo 5. Resultados, análisis e interpretación .....	<u>46</u>
Capítulo 6. Conclusiones y sugerencias para trabajos futuros .....	<u>54</u>
Referencias bibliográficas .....	<u>58</u>
Anexos .....	<u>61</u>

## Índice de tablas e índice de figuras.

	Pág.
Introducción	
Capítulo 1. Antecedentes	
Figura 1. Estructura general de la EPM	... 12
Capítulo 2. Diagnóstico de la situación	
Tabla 1. Presupuesto y ejercicio 2021 de EP	... 18
Grafica 1. Comparativo del presupuesto y ejercicio 2021 de EP	... 19
Grafica 2. Ejercicios presupuestales históricos del 2017 - 2020 por mes	... 20
Tabla 2. Modelos autorregresivos aplicados en diferentes áreas	... 22
Capítulo 3. Marco teórico	
Figura 2. La metodología Box - Jenkins (ARIMA)	... 26
Ecuación 1. Modelo autorregresivo AR	... 27
Figura 3. Comportamiento de la autocorrelación y autocorrelación parcial en modelos de orden AR (1) y AR (2)	... 28
Ecuación 2. Modelo promedios móviles MA	... 28
Figura 4. Comportamiento de la autocorrelación y autocorrelación parcial en modelos de orden MA (1) y MA (2)	... 30
Ecuación 3. Ecuación general del ARMA (p, q)	... 30
Figura 5. Comportamiento de la autocorrelación y autocorrelación parcial en modelos de orden ARMA (1) y ARMA (2)	... 31
Tabla 3. Patrones de autocorrelación y auto correlación parcial.	... 32
Ecuación 4. Ecuación integrado estacional	... 33
Ecuación 5. Equivalencia de ruido blanco	... 33
Ecuación 6. SARIMA con componente estacional	... 33

Ecuación 7. Polinomios para ruido blanco y varianza	...	34
Ecuación 8. Modelo para varios componentes de un periodo.	...	34
Ecuación 9. Polinomios que representan media cero y varianza cuadrada	...	34
Ecuación 10. Criterio AIC	...	36
Ecuación 11. Criterio BIC	...	36
Tabla 4. Artículos internacionales de modelos ARIMA en diferentes áreas.	...	37
Tabla 5. Artículos internacionales de modelos utilizados en el área petrolera	...	38
Capítulo 4. Solución propuesta e implementación		
Figura 4. Funcionamiento de la implementación en la EPM.	...	44
Figura 5. Front end de ejecución de armado de información para la página web	...	45
Figura 6. Página web del pronostico	...	45
Capítulo 5. Resultados, análisis e interpretación		
Figura 7. Gráfica del horizonte de valores del 2017 - 2020	...	46
Figura 8. Gráfica aplicando logaritmo al horizonte de valores 2017 - 2020	...	47
Figura 9. Gráfica aplicando diferencia de logaritmo al horizonte de valores 2017 - 2020	...	47
Figura 10. Gráfica aplicando diferencia estacional al horizonte de valores 2017 - 2020	...	48
Tabla 6. Resultado de los modelos SARIMA en base al criterio BIC y AIC	...	48
Figura 11. Graáfica de los valores pronosticados para el 2021 y 2022	...	49
Tabla 7. Valores pronosticados para el 2021 y 2022	...	50
Figura 12. Comparativo a nivel subdirección de los presupuestado, ejercido del 2021 y pronosticado por el modelo SARIMA para el 2021 y 2022.	...	51
Figura 13. Gráfica del ejercicio del año 2021.	...	51
Figura 14. Mapa por estado de la distribución del presupuesto pronosticado 2021 por el modelo SARIMA.	...	52

Figura 15. Gráfica por subdirecciones de la distribución del presupuesto ... 52  
pronosticado 2021 por el modelo SARIMA.

Figura 16. Gráfica por subdirecciones de la distribución del presupuesto ... 53  
pronosticado 2022 por el modelo SARIMA.

Capítulo 6. Conclusiones y sugerencias para trabajos futuros

Referencias bibliográficas

Anexos

## **Introducción.**

El uso de técnicas para la estimación del presupuesto en una empresa cobra relevancia ya que partir de esta se crea una herramienta que coadyuve al uso eficiente de los recursos y en consecuencia el crecimiento de los beneficios para la misma, así como para todos los interesados.

En el caso de la Empresa Petrolera Mexicana la estimación del presupuesto de la mano de obra hoy día se realiza mediante ponderaciones, lo que da pie a la existencia de brechas entre el presupuesto estimado y ejercido de hasta 15.58%, de acuerdo a los datos de la propia empresa; ello da lugar a la subutilización de recursos, lo que implica un uso ineficiente de los mismos. Además de la asignación de los recursos existen otros problemas asociados al proceso de estimación basado en ponderaciones, dado que no está sistematizado, o registrado en algún documento que se traduzca en un manual de estimación asequible para otros usuarios, lo que genera problemas de dependencia de la empresa con la persona a cargo, y riesgos en caso de ausencia del mismo.

El contexto descrito dio lugar a plantear como objetivo de este trabajo: “Desarrollar un proceso autorregresivo que permita pronosticar el costo presupuestal de mano de obra de la Empresa Petrolera Mexicana”. Para ello fue necesario buscar un método estadístico el cual pronostique el costo de mano de obra de la EPM, por lo que fue preciso hacer la revisión y análisis de referentes, a nivel internacional y sectorial. A partir de ello se encontraron modelos de pronósticos existentes. Particularmente, para el objetivo de este trabajo, sobresalen los autorregresivos (AR, MA, ARIMA, SARIMA) ya que utilizan como variable de entrada horizontes amplios de datos históricos, tal como los que utiliza la EPM para el pronóstico de su costo de mano de obra.

Desde la experiencia internacional se observó el uso de modelos autorregresivos, sin embargo, la mayoría de los casos solo hacen pronósticos en industrias distintas a la petrolera, que se enfocan, principalmente al pronóstico del precio del petróleo, pero la literatura sobre las técnicas o propuestas para la estimación de presupuesto, y

específicamente de la mano de obra, es escasa.

Dado la falta de referentes sobre estimaciones presupuestales en la industria petrolera, fue necesario el análisis y clasificación de la información que maneja la EPM, a partir de lo cual se pudo caracterizar a la misma con los elementos que conforman las series de tiempo, particularmente el peso de la estacionalidad de la misma, dado que para la estimación del presupuesto es necesario considerar elementos como vacaciones, rendimiento o fondo de ahorro, el pago del buen fin, etc.

Una vez que se ubicaron los elementos de una serie de tiempo y su peso, se concluyó que los modelos autorregresivos con estacionalidad eran la herramienta adecuada para la estimación del presupuesto del costo de mano de obra de una EPM.

El desarrollo de un modelo que estime el costo de mano obra, representa una ventaja en términos del uso de recursos, sin embargo, otra de las preocupaciones de este trabajo era el desarrollo de una herramienta que sistematizara el proceso y que fuera asequible para usuarios diversos. Para ello se creó una base de datos que recopila, tanto los datos históricos de entrada del modelo autorregresivo, así como los resultados que se generan.

Una vez que el modelo ha hecho las estimaciones del presupuesto, lo pronosticado se visualiza en una página web creada para visualizar el presupuesto pronosticado y consultar, de manera interna, lo cual permite a las diferentes áreas, a nivel dirección, tener elementos cuantitativos, con significancia estadística, para la toma de decisiones referente al presupuesto de cada año futuro y así poder destinar mayores recursos presupuestales al ***Core Business*** de la EPM.

En suma, los productos desarrollados a partir de esta investigación representan una herramienta que permite, de manera eficiente y concreta, destinar los recursos presupuestales excedentes, resultado de las técnicas previas de estimación y que con nuevo modelo se evitara esa brecha, es decir, la herramienta, resultado de este trabajo, permite aprovechar al máximo los recursos en la EPM y poder aumentar o mantener los niveles de

producción del país.

Para el desarrollo de este trabajo en el primer apartado se hace una revisión de los antecedentes donde caracteriza la organización y conformación de la plantilla laboral, posteriormente se hace un diagnóstico de la situación: se analiza a la Empresa Petrolera Mexicana (EPM), se revisa el algoritmo de cálculo del pronóstico de mano de obra de la EPM, y se hace un comparativo de los datos presupuestados contra lo ejercido. En el capítulo 3 se hace una revisión de los modelos de pronóstico Autorregresivos: AR, MA, ARIMA, SARIMA y los criterios de selección. La solución propuesta e implementación, se exponen en el capítulo 4, mientras que en el capítulo 5 se muestran los modelos analizados y los resultados del modelo elegido que se comporta y ajusta de mejor forma a los datos históricos utilizados de la EPM. Por último, se hace un apartado donde se exponen las conclusiones, así como propuestas de trabajos futuros y propuestas de aplicaciones del modelo para que se aplique a nivel institucional en la EPM.

Objetivo general

“Desarrollar un proceso autorregresivo que permita pronosticar el costo presupuestal de mano de obra de la Empresa Petrolera Mexicana”. Para lograrlo es necesario:

Objetivos particulares:

1. A partir de la revisión de la base de datos de Recursos Humanos y de Finanzas, estandarizar los criterios para asegurar la confiabilidad de los datos.
2. Analizar empresas del ramo energético o en otros ramos en México que hayan implementado de manera exitosa técnicas econométricas para la estimación de costos presupuestales en general, y laborales en particular, para desarrollar un marco de referencia de dichas aplicaciones en la industria petrolera.
3. Gestionar la infraestructura necesaria para hacer las pruebas, contar con prototipo en el ambiente de calidad y si fuera el caso, migrarlo a productivo con la respectiva autorización del negocio.
4. Crear base de datos con la información necesaria que servirá de insumo para los escenarios.

5. Crear escenarios de los modelos de Procesos autorregresivos con los datos
6. Identificar el modelo de proceso autorregresivo que mejor se ajuste a los datos
7. A partir de los resultados proponer una metodología para la estimación de costos
8. Ajustar los datos presupuestales en la base de datos de acuerdo con el pronóstico seleccionado.
9. Crear página web con el pronóstico de costo presupuestal de la mano de obra de la EPM.
10. Tiempo de prueba a ser definido ya que tiene que ver con trámites administrativos de la nueva administración.

## Capítulo 1. Antecedentes.

La **Empresa Petrolera Mexicana**<sup>1</sup> (EPM) se encuentra conformada por direcciones corporativas. Son áreas de servicios que brindan apoyo administrativo a las áreas del negocio dentro de las cuales está la Dirección de Finanzas y las áreas de negocio conformadas por **Exploración y Producción (EP)**, Refinación, Fertilizantes y Logística son las que dan valor agregado a la **EPM**, áreas cuyas tareas principales se asocian a la operación de la empresa a concentrar a la exploración, extracción, transporte y transformación del petróleo o gas en productos (Plan de negocios 2019-2023).

Fuente: Elaboración propia con datos de la Empresa Petrolera vigente al 2021.

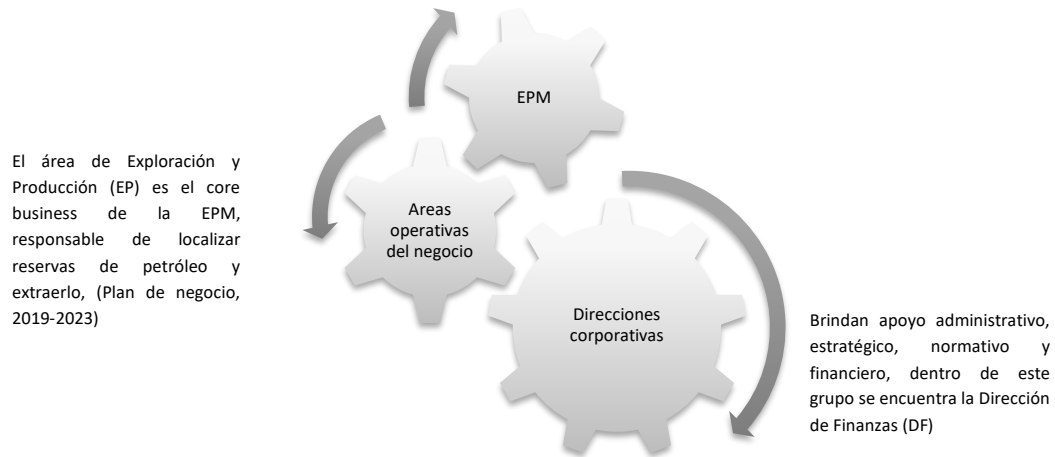


Figura 1. Estructura general de la EPM.

Como se observó en la Figura 1, el área de **Exploración y Producción (EP)** es el *core business* de la **EPM**, ya que representa los mayores ingresos dentro de la empresa y cuentan con mayor plantilla de personal, además tiene asignados el 63% presupuestales, con base a la demanda de petróleo mundialmente y a su plan de negocios 2019-2023.

---

<sup>1</sup> Nombre ficticio en el cual se basa mi tesis ya que por cuestiones de seguridad no se puede divulgar datos reales por el compromiso de no difundir información sensible que a su vez está redactado en mi contrato colectivo.

La **EPM** cuenta con direcciones corporativas, dentro de la cual está la Dirección de Fianzas (DF)<sup>2</sup>, donde está adscrita la subdirección encargada de dar servicios financieros a la **EP**, tales como los asociados a la parte presupuestal. Como su nombre lo indica, elaboran los presupuestos mensuales del año en curso.

Respecto a la estructura laboral de la **EP**, para el 2018, estaba dividida en empleados de confianza y sindicalizados dentro de la **EPM**, con un total de 121,654 plazas de las cuales 22,516 eran de confianza y 99,138 sindicalizadas<sup>3</sup>; lo anterior da cuenta del tamaño de su estructura laboral que servirá de punta de lanza para que en el futuro se obtenga el costo presupuestal de mano de obra de toda la **EPM** y no solo de la **EP**.

Dado el peso que tiene el área de **EP** en la Empresa Petrolera Mexicana cobra relevancia contar con una herramienta formal para el pronóstico del costo presupuestal de mano de obra, basado en técnicas estadísticas, técnicas computacionales sólidas, tales como sistemas autorregresivos que den certeza sobre el uso de los recursos disponibles en el año en cuestión, además de hacer más confiable la estimación del costo presupuestal de mano de obra, al tener herramientas que garanticen su significancia estadística, además que su implementación a nivel institucional mediante una política interna representaría la estandarización de los criterios utilizados en todas las áreas

Actualmente, en la EPM, la estimación del costo presupuestal de mano de obra considera ponderaciones y porcentajes de diversas variables; sin embargo no se encuentran fundamentados en un modelo de pronóstico que considere i) rendimientos, tales como el pago de utilidades generadas en un año, ii) pago de vacaciones, iii) de número de catorcenos, iv) del aguinaldo, v) del bono mensual, vi) del “Buen fin” para plazas de confianza, vii) el incremento salarial, viii) el gasto mano de obra en meses normales, ix) fondo de ahorro y x) discriminación de los registros que del IVA impacta en el pronóstico del costo de mano de obra.

En suma, el homogeneizar el criterio de estimación del presupuesto de mano de obra a nivel institucional se evitaría que las áreas presenten diferentes cifras del costo presupuestal de

---

<sup>2</sup> La Dirección de Finanzas (DF) brinda servicios de inteligencia financiera a las empresas generadoras de valor, de acuerdo con su estatuto orgánico vigente.

<sup>3</sup> Plan de negocios 2019 - 2023

mano de obra a nivel directivo, ya que esto no permitía que llegaran a los acuerdos necesarios indispensables para aumentar la producción de extracción de hidrocarburos y optimizando el destino del presupuesto en la actividad primordial, la producción. En el siguiente apartado se presenta una caracterización del proceso original de estimación del presupuesto, así como las áreas de oportunidad para la mejora de este.

## Capítulo 2. Diagnóstico de la situación

### Metodología actual para la elaboración del pronóstico

Actualmente el pronóstico del costo de la mano de obra de **EP**, se realiza mediante ponderaciones lo cual implica imprecisiones<sup>4</sup>; dicha estimación se hace considerando las siguientes variables:

1. **Número de catorcenos por mes:** al inicio de cada año se determina el número de meses que tienen el pago de tres catorcenos.
2. **Meses normales:** un gasto normal, aquellos que reflejan el pago de nómina (viáticos, sueldos, horas extras, prestaciones, etc.) y que se toman como referencia para estimar el promedio del costo de mano de obra.
3. **Rendimientos:** una vez que se tiene el pronóstico de los meses de todo un año, en junio se aplica una ponderación del 1%<sup>5</sup> que se agrega al total de dicho mes.
4. **Incremento salarial:** el incremento pactado con el sindicato, cada año se refleja solo en los meses de agosto a diciembre y con base a una ponderación, que se aplica a estos que para el 2021 correspondió del 3.7%<sup>6</sup>
5. **Impuesto al valor agregado (IVA):** se identifican los registros que corresponden al IVA.
6. **Bono:** cada mes el trabajador recibe un bono, por lo tanto, se hace una revisión del histórico del año anterior y ese monto se le suma al mes correspondiente.

---

4 Las imprecisiones pueden ser en los montos calculados lo que da lugar a discrepancias entre los montos estimados y ejercidos.

<sup>5</sup> Es un porcentaje fijo que toma el área Recursos Humanos.

<sup>6</sup> Es un valor resultante de las negociaciones contractuales del sindicato con EPM.

7. **“Buen fin”**: políticas de la empresa dictan que se va a pagar lo correspondiente al “Buen fin”, en el mes de noviembre, a trabajadores bajo el régimen de confianza. Una vez que se ubican a los beneficiarios, se revisa cuánto se pagó en el histórico y se suma lo correspondiente; si lo anterior no aplica se sigue el paso 10.

**Aguinaldo**: si el “Buen fin” se pagó en el mes de noviembre, para trabajadores de confianza, entonces solo se pagaría el aguinaldo para trabajadores sindicalizados y se revisa cuánto se pagó en el histórico. Pero si se va a pagar aguinaldo al personal de confianza y sindicalizado, entonces se revisa cuánto se pagó en el histórico y se suma lo correspondiente.

8. **Fondo de ahorro**: se verifica cuánto se pagó en el año anterior y se le suma al total del mes de diciembre.
9. **Vacaciones**: cuando un trabajador va a disfrutar el goce de su primer periodo de vacaciones en el año, se le paga lo correspondiente a dicha prestación; principalmente en verano donde existe más afluencia.

Como se mencionó anteriormente, parte del proceso de estimación para el costo de mano de obra se basa en el uso de ponderaciones de los rendimientos, “Buen fin”, bono, fondo de ahorro, aguinaldo, ello hace que la estimación tenga imprecisiones, por tanto, da lugar a una brecha entre lo presupuestado y lo ejercido en el año. El objetivo de este trabajo es proponer un modelo que reduzca dichas diferencias, que implica las siguientes ventajas:

- ✓ Reducción de la brecha entre el presupuesto ejercido y el planeado.
- ✓ La reducción de la brecha permitiría contar con recursos presupuestales para la actividad de extracción de hidrocarburos
- ✓ Toma de decisiones a nivel directivo con datos precisos
- ✓ Cifras homologadas a nivel institucional

De acuerdo con lo anterior, en el siguiente apartado se hace una comparación entre el presupuesto estimado y el ejercido para evidenciar la necesidad de desarrollar una nueva metodología que reduzca dicha brecha, para así demostrar a partir de la estadística descriptiva qué tan significativa puede ser la brecha.

## Comparación del presupuesto y ejercido del costo de mano de obra de 2021

El método que se utiliza para la estimación del presupuesto de mano de obra a lo largo de los años ha mostrado discrepancias con el ejercido. En este apartado se busca evidenciar dicho problema a partir de la visualización y comparación del pronóstico presupuestal del costo de mano de obra de la EP del año 2021 entre enero y diciembre, así como las cifras del presupuesto ejercido del costo de la mano de obra hasta el mes de septiembre, considerado como mes cerrado<sup>7</sup>; los resultados obtenidos son multiplicados y divididos por una constante<sup>8</sup>.

En la Tabla 1 se puede observar las cifras mensuales del año 2021, en términos reales del pronóstico del costo presupuestal de mano de obra de EP, donde se ve que el acumulado de enero a diciembre es de **44,304,565** pesos; en lo que se refiere al presupuesto ejercido al mes de diciembre el acumulado alcanza los **39,040,850** pesos, cabe resaltar que hay **5,263,714** pesos ejercidos que superan lo pronosticado, aproximadamente una diferencia del **15.58%**, que se podría reducir al implementar un modelo de pronóstico basado en técnicas estadísticas.

Tabla 1. Presupuesto y ejercicio 2021 de EP en términos reales 2020=100.

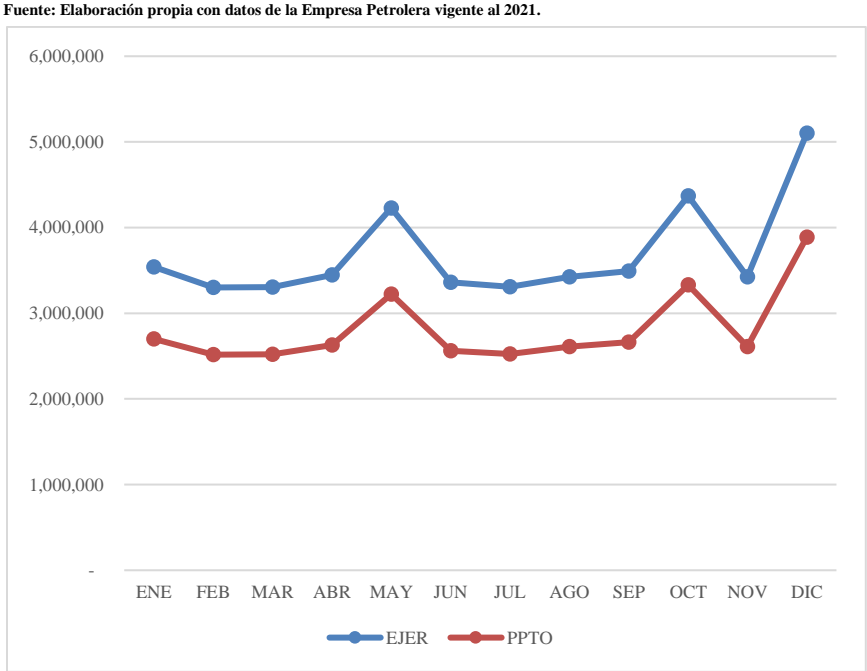
Tipo	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC	Total
PPTO	3,541,276	3,301,104	3,304,725	3,447,885	4,228,253	3,360,776	3,310,179	3,423,656	3,490,548	4,369,171	3,425,897	5,101,094	44,304,565
EJER	3,062,177	2,622,887	2,650,670	3,837,681	3,039,105	3,224,806	3,040,340	2,800,098	3,105,576	3,892,725	2,804,368	4,960,418	39,040,850
<b>PPTO-EJER</b>	<b>479,099</b>	<b>678,217</b>	<b>654,054</b>	<b>- 389,796</b>	<b>1,189,148</b>	<b>135,969</b>	<b>269,839</b>	<b>623,559</b>	<b>384,972</b>	<b>476,446</b>	<b>621,529</b>	<b>140,677</b>	<b>5,263,714</b>

Fuente: Elaboración propia con datos de la Empresa Petrolera vigente al 2021.

<sup>7</sup> Mes cerrado nos referimos al ejercicio presupuestal que ya se ejerció; por ejemplo, son los meses anteriores al mes actual.

<sup>8</sup> La Universidad Panamericana pide para los trabajos de titulación no mostrar cifras reales, por lo que se utiliza un factor, que mantenga las proporciones de los datos a considerar.

En la Gráfica 1 se pueden observar las variaciones mensuales del presupuesto pronosticado (PPTO) y ejercido (EJER) del año 2021. Queda de manifiesto la diferencia entre ellos que alcanza un máximo del 15.58% del presupuesto contra el ejercicio de manera anual. Lo anterior implica para la empresa destinar menores recursos para el Core Business de la EPM.



Gráfica 1. Comparativo del Presupuesto y ejercicio 2021 de EP

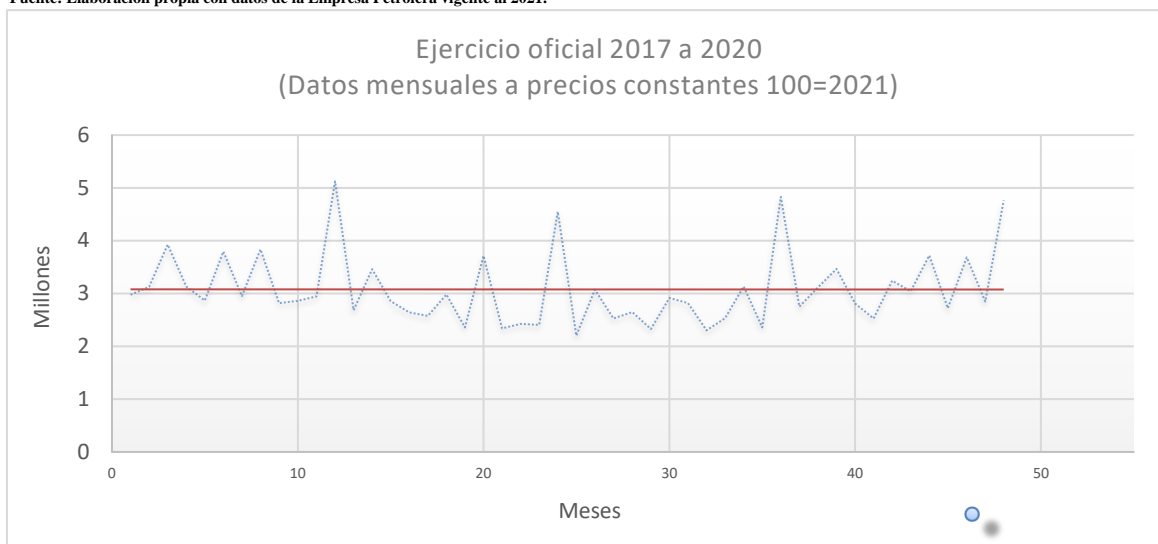
Las discrepancias existentes entre el ejercido y lo planeado dan lugar a adecuados presupuestales mensuales en el transcurso del año que permiten ajustar el presupuesto de acuerdo con el ejercicio de cada mes; por lo tanto, mientras estén más cercanos a la realidad menos ajustes periódicos se realizarán, lo que representará una ventaja en la **EPM** ya que el presupuesto se destinará a líneas de negocio, producción y extracción de hidrocarburos.

En la Gráfica 2 se puede observar los ejercicios presupuestales históricos del 2017 al 2020 por meses, en términos reales<sup>9</sup>. Además, se puede observar que de acuerdo con la línea de tendencia (línea roja) los datos históricos mensuales de los años antes mencionados no

<sup>9</sup> Se tomó el índice de precios al consumidor del año 2020. Fuente INEGI. Índices de precios; estos datos son los que se utilizarán para alimentar nuestra técnica autorregresiva que se ajuste mejor al proceso generador de datos.

tienen media constante y la varianza presenta estacionalidad en los meses correspondientes a aguinaldo, fondo de ahorro y vacaciones.

Fuente: Elaboración propia con datos de la Empresa Petrolera vigente al 2021.



Gráfica 2. Ejercicios presupuestales históricos del 2017 - 2020 mensual de acuerdo con lo ejercido por la EPM

En suma, la brecha entre el presupuesto planeado y el ejercido ha sido una constante en el costo de la mano de obra de la **EP**, como se mostró, previamente ha llegado a niveles de **5,263,714** de pesos, que es el **15.58%** de lo ejercido, tales discrepancias dejan claro la necesidad de plantear una propuesta para el desarrollo de un mecanismo estadísticamente confiable para la estimación de los costos de mano de obra de **EPM**, que permitan resarcir problemas que actualmente tiene el procedimiento antes descrito, que podrían ser resultado de basar el pronóstico del costo de mano de obra en ponderaciones de porcentaje fijo, asociado a procedimientos de estimación “manual”, lo que hace que el tiempo de respuesta del pronóstico sea lento y con mayor probabilidad de error, dado que no se sustenta en ningún método matemático/estadístico que pueda tener cierto nivel de confianza estadística.

Las disparidades antes mencionadas evidencian que las decisiones que se llevan a cabo a nivel ejecutivo no tienen un fundamento sólido-formal, y en términos de implementación, el proceso no puede ser replicado ya que ha sido construido a través del tiempo por una persona en particular que lo ha desarrollado sin documentarlo en un manual, lo cual representa un doble riesgo; por un lado, le da un alto poder de negociación al responsable, además del riesgo que implica que este se ausente.

Desarrollar un método de estimación que reduzca las diferencias representa la oportunidad de destinar recursos presupuestales a otras áreas de la EPM, que harían más rentable su *Core Business*, por tanto, tener una mayor eficiencia presupuestal apegado a los lineamientos establecidos por el Gobierno Federal.

La propuesta inicial de este trabajo es el desarrollo de un modelo autorregresivo, ya que hay experiencias internacionales que lo han hecho en ámbitos diferentes<sup>10</sup>, algunos de ellos se presentan a continuación (ver Tabla 2):

**Tabla 2. Modelos autorregresivos aplicados en diferentes áreas**

No.	Artículo	Pregunta de investigación	Datos	Métodos	Variables dependientes	Recomendaciones
1	Madrigal, S. (2017)	¿Qué modelos son mejores para el análisis de datos con poca información histórica?	Se emplean 617 series mensuales tomadas de la M Competition (Makridakis et al., 1982). Estas son recortadas para simular información escasa.	Modelos de regresión	Modelo de regresión lineal con transformación Box - Cox (MRLBC) es mejor para meses de 1 a 4 y el modelo de regresión no lineal (MRNL) el cual da mejores resultados entre 1 y 18 meses	Se recomienda, a quienes deben pronosticar series temporales estacionales con pocos datos, seguir estas recomendaciones para minimizar los errores en sus proyecciones, para así tomar mejores decisiones.
2	Corres, G., Passoni, I., Zárate, C. & Esteban, A. (2014)	¿Qué modelos es mejor para el pronóstico de ventas?	Los datos reales de ventas durante 10 años de productos pertenecientes a una misma empresa de conservas de la ciudad de Mar del Plata, con características de estacionalidad e insumos similares entre sí.	Se utilizan métodos de diversos orígenes: determinísticos (suavizado exponencial en sus versiones simples y complejas), ARIMA (Método Autorregresivo Integrado de Medias Móviles) y ANFIS (Sistema Adaptativo de Inferencia Neuro Difuso).	ARIMA es mejor cuando tienes más datos históricos, pero si se reduce la cantidad de datos sigue demostrando que es un buen método con estacionalidad. La ventaja de ANFIS es que puede mejorarse su respuesta variando los parámetros del modelo. Esto puede ser motivo de mayor consumo de tiempo de cálculo computacional.	Se propone a futuro, el análisis de los efectos del error del pronóstico sobre la cadena productiva de la organización.
3	Wong, James M.W., Albert P.C. Chan, and Y. H. Chiang. 2007	¿Se puede utilizar el modelo de corrección de errores vectoriales (VEC) para pronosticar?	Los datos de publicaciones relevantes emitidas por el Censo y Departamento de Estadística (C&SD) del Gobierno de la RAEHK. Esta serie de datos cubren el primer trimestre de 1983 a los tres trimestres de 2005, dando un total de 91 datos puntos.	Modelo de corrección de errores vectoriales	El modelo propuesto en su forma actual se puede utilizar para producir un pronóstico a mediano plazo de la demanda agregada de mano de obra. Sin embargo, los pronósticos desagregados requerirán una mayor construcción de modelos y una exhaustiva investigación que implica el modelado de dramáticos cambios en las ocupaciones de la construcción tales como cambio tecnológico, capacidad de producción y mezcla de carga de trabajo de la industria.	De hecho, el desarrollo de modelos ocupacionales y su vinculación con este modelo es el siguiente paso obvio, para la investigación posterior. Se prevé que los resultados de la fase siguiente se publicarán próximamente
4	Teicholz, P. (1993)	¿Se puede pronosticar el costo final y el presupuesto de un proyecto de construcción?	Presupuesto total y los datos de 1993 de costos, presupuestos y cantidades	Método de promedio móvil	Los resultados mostraron una mejora significativa en la precisión y la puntualidad (87% de aumento en la precisión y 54% de aumento en la puntualidad sobre los valores mostrados en los informes de costos). Estos resultados son importantes porque muestran que, mediante el uso de cálculos muy simples, se pueden obtener mejoras significativas en la previsión oportuna del costo final y la variación de un proyecto. Por lo tanto, se debe incluir un número suficiente de períodos en la media móvil para generar una tendencia estable. Este concepto genera un promedio móvil que va desde un mínimo de tres períodos hasta un máximo del total de períodos a la fecha.	Sería deseable determinar si la precisión del pronóstico se puede mejorar vinculando los datos del cronograma con los datos de costos, es decir, integrando el costo y el cronograma o mediante el uso de otras técnicas de análisis discutidas en la literatura de investigación.

Fuente: Elaboración propia con citas del sector internacional.

La evidencia internacional apenas es una pequeña introducción de lo que se analizará en el siguiente capítulo, donde se hablará más ampliamente del tema. Casos como la calidad del agua (Katimon, Ayob, Shamsuddin Shahid, and Morteza Mohsenipour. 2018), el tráfico de carreteras en tiempo real (Xu, Dong-wei, Yong-dong Wang, Li-min Jia, Yong Qin, and Hong-hui Dong. 2017) por citar algunos, permiten suponer que, a partir de la utilización de técnicas autorregresivas, la estimación y pronóstico del costo presupuestal de mano de obra de la Empresa Petrolera Mexicana, requiere datos históricos para su desarrollo y considera el componente estacional. En el siguiente apartado se explica de manera amplia las características y virtudes de dicha técnica para la construcción de un modelo que permita el alcance del objetivo de este trabajo.

<sup>10</sup> Estos conceptos se hablarán ampliamente en el capítulo 3 de este documento.

## Capítulo 3. Marco teórico

De acuerdo con el diagnóstico que se realizó, cobra importancia encontrar el mejor método de pronóstico que permita reducir la brecha entre el costo presupuestal de mano de obra de la EPM pronosticado y el observado, considerando los datos disponibles. En este capítulo inicialmente se hará una breve distinción entre métodos cuantitativos y cualitativos, así como una amplia caracterización de los modelos autorregresivos para tener elementos formales que sustenten la propuesta de esta investigación, y en consecuencia, el logro del objetivo planteado: diseñar un instrumento que permita pronosticar el costo presupuestal de mano de obra.

De acuerdo con Hanke, J. y Wichern, D. (2006) un pronóstico es una estimación cualitativa o cuantitativa de una o varias variables para tener visibilidad de un evento futuro, con base a información actual o histórica; tal como sucede con el costo de mano de obra de la EPM objeto de estudio, ya que se cuentan con datos históricos desde 2017 al 2020.

Para Render, B., Stair, R., Hanna, M. y Hale, T. (2016) los pronósticos se dividen en dos categorías: la primera categoría incluye los modelos cualitativos y la segunda categoría son de naturaleza cuantitativa, utilizan modelos matemáticos para desarrollar mejores pronósticos. A continuación, hablaremos de qué es un modelo cualitativo y cuantitativo, de manera breve, para dar el contexto necesario y abordar la descripción de la metodología que se tocará en el punto 3.2.

### 3.1 Tipos de pronósticos

#### 3.1.1 Modelos cualitativos

Render, B., Stair, R., Hanna, M. y Hale, T. (2016) son técnicas de pronósticos basadas en juicios o factores subjetivos, como es el caso de la introducción de un producto totalmente nuevo, el pronóstico de la demanda es muy difícil debido a la inexistencia de datos históricos de ventas para ese producto en particular o para alguno similar. La empresa debe

contar con la opinión de expertos, experiencias previas y juicios individuales, entre otros factores subjetivos. Entre los métodos más utilizados en diversos sectores de la actividad económica para el uso de estos modelos sobresalen el método Delphi y el jurado de opinión ejecutiva, ambos recurren a la opinión de expertos en el tema o a ejecutivos que, aunado al uso de métodos estadísticos, permite hacer pronósticos sobre la demanda (Urgell et al. 2018 y Vedia Urgell et al. 2018). Los métodos de composición de la fuerza de ventas y el estudio del mercado de consumo son técnicas que se basan, por un lado, en el conocimiento del personal de ventas y en las opiniones de potenciales consumidores para hacer pronósticos sobre la demanda.

### **3.1.2 Modelos cuantitativos**

Para Render, B., Stair, R., Hanna, M. y Hale, T. (2016) los modelos cuantitativos son aquellos que utilizan métodos matemáticos para desarrollar mejores pronósticos; estos se dividen en modelos causales y modelos de series de tiempo, que a diferencia de los cualitativos que consideran datos basados en elementos subjetivos, estos de diversos datos estadísticos.

En el caso del pronóstico del costo de mano de obra de una EPM, dada la naturaleza de los datos con los que se cuenta, en este trabajo se propone el uso de los modelos autorregresivos (Box-Jenkins ARIMA) la cual se describe a continuación.

### **3.2 Modelos autorregresivos (Box-Jenkins ARIMA)**

De acuerdo a Hanke, J. and Wichern, D. (2006) la metodología para identificar, ajustar y verificar los modelos ARIMA adecuados fue impulsada fuertemente por dos especialistas en estadística, G. E. P. Box y G. M. Jenkins. Por esta razón, los modelos ARIMA para la generación de pronósticos se conocen a menudo como metodología Box-Jenkins

“La metodología Box-Jenkins se refiere a un conjunto de procedimientos para identificar, ajustar y verificar modelos ARIMA con los datos de la serie de tiempo. Los pronósticos se derivan directamente de la forma de un modelo ajustado” (Hanke and Wichern, 2006).

Son modelos que generan pronósticos exactos con base en una descripción de patrones históricos de los datos. Los modelos autorregresivos integrados de promedio móvil (ARIMA) son una clase de modelos lineales que son capaces de representar tanto series de tiempo estacionarias como no estacionarias. Recuerde que los procesos estacionarios varían alrededor de un nivel fijo, en tanto que los procesos no estacionarios carecen de un nivel promedio constante natural. Los modelos autorregresivos en realidad son un subconjunto especial de los modelos ARIMA que resultan útiles para modelar series de tiempo estacionarias.

Algunas de las razones por las que se consideran convenientes para este trabajo son (Hanke and Wichern, 2006):

- ✓ No implican variables independientes en su construcción
- ✓ Utilizan información de la serie misma para generar los pronósticos (ejemplo: un modelo ARIMA para ventas mensuales proyectaría el patrón de ventas históricas para generar un pronóstico para las ventas del siguiente mes)
- ✓ Los modelos ARIMA dependen mucho de los patrones de autocorrelación en los datos.

Ya que se mencionaron algunas de las fortalezas del modelo ARIMA también es muy importante saber cómo es el funcionamiento del modelo, para así estar en condiciones de poder implementarlo de acuerdo con su funcionamiento como se menciona a continuación.

En cuanto al funcionamiento del modelo ARIMA (Hanke and Wichern, 2006):

- ✓ Es diferente de la mayoría de los métodos porque no supone ningún patrón particular en los datos históricos de las series que se van a pronosticar
- ✓ Se basa en un enfoque iterativo para identificar un modelo posible a partir de una clase general de modelos.
- ✓ El modelo seleccionado se coteja con los datos históricos para ver si describe la

serie con exactitud.

- ✓ El modelo está bien ajustado si los residuos son generalmente pequeños (cerca de cero), están distribuidos aleatoriamente y no contienen información útil.
- ✓ Si el modelo especificado no es satisfactorio, el proceso se repite usando un nuevo modelo diseñado para mejorar el original. Este procedimiento iterativo continúa hasta que se encuentra un modelo satisfactorio, es decir, que mejor se ajuste a nuestros datos. En ese momento, el modelo se considera útil para pronosticar. En la figura 1 se ilustra la estrategia de construcción de un modelo Box-Jenkins.

Fuente: Hanke and Wichern, 2006.




Figura 2. La metodología Box - Jenkins (ARIMA).

Ahora que ya conocemos las fortalezas y funcionamiento del modelo ARIMA, se puede intuir que los datos históricos con los cuales se cuenta para este trabajo, y la virtud de ser un modelo iterativo el cual permite implementar la mejora continua en el proceso de estimación del presupuesto de la mano de obra de la EPEM, se analizará en el siguiente apartado.

### 3.2.1 Modelos autorregresivos AR (p-ésimo orden)

Los modelos autorregresivos son modelos adecuados para series de tiempo estacionarias, y el coeficiente  $f_0$  está relacionado con el nivel constante de la serie. Si los datos varían alrededor de cero o se expresan como desviaciones de la media,  $Y_t - \bar{Y}$ , no se requiere el coeficiente  $f_0$ .

El modelo autorregresivo de orden  $p$  tiene la siguiente Ecuación 1:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad \text{Ecuación 1. Modelo autorregresivo AR}$$

Donde

$Y_t$	variable de respuesta (o dependiente) en el tiempo t
$Y_{t-1}, Y_{t-2}, Y_{t-p}$	variable de respuesta en los tiempos de retraso de tiempo t – 1, t – 2, ..., t – p <sup>11</sup> , respectivamente; estas Y desempeñan el papel de variables independientes.
$\phi_0, \phi_1, \phi_2, \dots, \phi_p$	coeficientes que sean estimados <sup>12</sup>
$\varepsilon_t$	término de error en el tiempo t, el cual representa los efectos de variables no explicadas por el modelo. Los supuestos acerca del término del error son los mismo del modelo de regresión estándar <sup>13</sup> .

Los modelos autorregresivos (AR), son de orden diverso en función del número de rezagos en el tiempo, por ejemplo, cuando se habla de un modelo AR de orden 1, se refiere a un rezago en el tiempo y para el AR de orden 2, por consiguiente, son dos retrasos en el tiempo. En términos gráficos, para la ecuación de un modelo AR de orden 1 y de un modelo AR de orden 2, se presenta en la Figura 2. Para el modelo AR (1) se observa las diferencias en el comportamiento de las funciones de autocorrelación y autocorrelación parcial. Los coeficientes de autocorrelación se aproximan gradualmente hacia cero, mientras que los coeficientes de autocorrelación parcial caen a cero después del primer retraso de tiempo. Para un modelo AR (2) los coeficientes de autocorrelación tienden a cero, mientras que los coeficientes de autocorrelación parcial caen a cero después del segundo retraso de tiempo. Este tipo de patrón generalmente se mantendrá para cualquier modelo AR (p). Debe recordarse que las funciones de autocorrelación muestrales van a diferir de estas funciones teóricas a causa de las variaciones de la muestra.

---

<sup>11</sup> Donde p es el número de términos de valores pasados que se incluirán en el pronóstico de la siguiente observación.


<sup>12</sup> El coeficiente está relacionado con la media del proceso.

<sup>13</sup> Hanke, J. and Wichern, D. (2006) dicen que la variable dependiente está relacionada con la variable independiente.


### Autocorrelación

### Autocorrelación parcial


AR (1)



AR (1)



AR (2)



AR (2)



Figura 3. Comportamiento de la autocorrelación y autocorrelación parcial en modelos de orden AR (1) y AR (2).

Los modelos autorregresivos AR utilizan la función lineal desde el punto de vista con número finito de valores pasados; por lo tanto, es interesante analizar los modelos de promedios móviles MA ya que utilizan la función lineal, pero desde el punto de vista de número finito de errores pasados. Esto quedara más detallado en el siguiente apartado.

### 3.2.2 Modelos de promedios móviles MA (q-ésimo orden)

Los modelos de promedio móvil (MA) permiten hacer pronósticos de  $Y_t$  con base en una combinación lineal de un número finito de errores pasados, mientras que los modelos autorregresivos (AR) pronostican  $Y_t$  como una función lineal de un número finito de valores pasados de  $Y_t$ .

El modelo de promedio móvil de orden q – ésimo tiene la forma de la Ecuación 2:

$$Y_t = \mu + \varepsilon_t - \omega_1 \varepsilon_{t-1} - \omega_2 \varepsilon_{t-2} - \dots - \omega_q \varepsilon_{t-q} \quad \text{Ecuación 2. Modelo promedios móviles MA}$$

Donde


$Y_t$	variable de respuesta (o dependiente) en el tiempo t
$\mu$	proceso constante en el proceso
$\omega_1, \omega_2, \dots, \omega_q$	coeficientes que sean estimados
$\varepsilon_t$	término de error en el tiempo t, el cual representa los efectos de variables no explicadas por el modelo.
$\varepsilon_{t-1}$	Errores en periodos anteriores, que para el tiempo t, se incorpora a la respuesta, $Y_t$

Los términos de error se pueden agregar en secuencia para obtener un MA(q), donde q es el número de términos de error pasados que se incluirán en el pronóstico de la siguiente observación. Del modelo MA (1) se observa que las funciones de autocorrelación y autocorrelación parcial de los modelos AR y MA se comportan de formas muy diferentes. Esto es una ventaja, porque así los modelos AR y MA pueden distinguirse por sus patrones de autocorrelación y autocorrelación parcial. La Figura 3 presenta las ecuaciones de un modelo MA (1) y un modelo MA (2).


Los coeficientes de autocorrelación para el modelo MA (1) caen a cero después del primer retraso, mientras que los coeficientes de autocorrelación parcial tienden a cero gradualmente, esto permite que el modelo sea más preciso en pronóstico de los valores requeridos. Además, los coeficientes de autocorrelación del modelo MA (2) se vuelven cero después del segundo retraso de tiempo, mientras que las autocorrelaciones parciales tienden gradualmente a cero. Otra vez, debemos mencionar que las funciones de autocorrelación muestrales van a diferir de estas funciones teóricas a causa de la variación de la muestra.

### Autocorrelación

MA (1)




MA (2)



### Autocorrelación parcial

MA (1)



MA (2)




Figura 4. Comportamiento de la autocorrelación y autocorrelación parcial en modelos de orden MA (1) y MA (2).

Una vez revisado, de manera general el modelo autorregresivo AR y modelo de promedios móviles MA, surge la pregunta si se pueden combinar para así poder considerar en un mismo modelo el número de finto de valores pasados y número finito de errores pasados; lo anterior es importante para considerar las dos variables en este modelo y así tener mejor pronóstico; y para ello se debe de analizar los modelos de promedio móviles autorregresivos ARMA.

### 3.2.3 Modelos de promedio móvil autorregresivos ARMA (p,q)

Un modelo con términos autorregresivos se puede combinar con un modelo que tenga términos de promedio móvil para obtener un modelo “mixto” de promedio móvil autorregresivo; ya que nos permitirá un número finito tanto de valores pasados como de errores pasados para así tener mayor precisión considerando esos dos conceptos. Para representar estos modelos, es conveniente utilizar la notación ARMA (p, q), donde p es el orden de la parte autorregresiva y q es el orden de la parte del promedio móvil.

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t - \omega_1 \epsilon_{t-1} - \omega_2 \epsilon_{t-2} - \dots - \omega_q \epsilon_{t-q}$$

*Ecuación 3. Ecuación general del ARMA (p, q)*


Un modelo ARMA (p, q) tiene la forma general de la Ecuación 3. Los modelos ARMA (p, q) pueden describir una gran variedad de comportamientos de las series de tiempo estacionarias. Los pronósticos generados por un modelo ARMA (p, q) dependen de los valores actuales y pasados de la respuesta, Y, así como de los valores actuales y pasados de los errores (residuos), e.

La Figura 4 presenta la ecuación de un modelo ARMA (1, 1) y los posibles comportamientos de las autocorrelaciones y autocorrelaciones parciales teóricas. En este caso, tanto las autocorrelaciones como las autocorrelaciones parciales se desvanecen<sup>14</sup>; ninguna termina de manera abrupta.


Fuente: Hanke and Wichern, 2006.

### Autocorrelación

MA (1)




MA (2)



### Autocorrelación parcial

MA (1)



MA (2)




Figura 5. Comportamiento de la autocorrelación y autocorrelación parcial en modelos de orden ARMA (1) y ARMA (2).

Los patrones de autocorrelación y autocorrelación parcial de los procesos de promedio móvil autorregresivos se resumen como sigue:

<sup>14</sup> Se aproximan gradualmente al valor de cero.

Tabla 3. Patrones de autocorrelación y auto correlación parcial.

	<b>Autocorrelaciones</b>	<b>Autocorrelaciones parciales</b>
<b><math>MA(q)</math></b>	Terminan después del orden $q$ del proceso	Se desvanecen
<b><math>AR(p)</math></b>	Se desvanecen	Terminan después del orden $p$ del proceso
<b><math>ARMA(p,q)</math></b>	Se desvanecen	Se desvanecen

Fuente: Hanke and Wichern, 2006.

Es importante señalar que los modelos autorregresivos AR, modelo de promedios móviles MA y ARMA, utilizan los valores actuales y pasados, así como también los errores actuales y pasados. Debido a lo anterior las autocorrelaciones y autocorrelación parcial tienden a cero gradualmente, es decir se desvanecen; pero hay un componente que se debe considerar y es la estacionalidad de la cual analizaremos en el siguiente tema de ARIMA para datos estacionales.

### 3.2.4 Modelos ARIMA para datos estacionales

Hanke, J. and Wichern, D. (2006) dice que los datos estacionales tienen un patrón distintivo que se repite cada año. Para datos mensuales con un patrón estacional anual, las observaciones para los mismos meses en años diferentes deben estar correlacionadas. De esta manera, no sólo hay observaciones dentro del año relacionadas entre sí (correlacionadas), sino que también hay observaciones entre los años que están relacionadas unas con otras (correlacionadas). Si la duración del periodo estacional es  $S$ , de manera que  $S=12$  para datos mensuales y  $S=4$  para datos trimestrales, las autocorrelaciones y autocorrelaciones parciales para procesos estacionales son diferentes de cero en retrasos cortos (asociación dentro de un año) y en retrasos que son múltiplos del periodo estacional  $S$  (asociación entre años). Las interpretaciones de las autocorrelaciones y de las autocorrelaciones parciales en retrasos estacionales son las mismas que las interpretaciones de las autocorrelaciones y autocorrelaciones parciales en retrasos cortos.

Los modelos estacionales ARIMA contienen términos autorregresivos regulares y de

promedios móviles que explican la correlación en retrasos cortos y términos autorregresivos estacionales y de promedio móvil que explican la correlación en retrasos estacionales. Además, para series estacionales no estacionarias, se requiere una diferencia estacional adicional para especificar completamente el modelo.

La misma estrategia empleada para la construcción de modelos no estacionales se utiliza para modelos estacionales. Una vez que se ha establecido un modelo adecuado<sup>15</sup>, este se puede usar para pronosticar.

Palma, W. (2016) expresa los modelos ARIMA estacionales (SARIMA) en las siguientes ecuaciones:

Un proceso simple integrado estacionalmente con período  $s$  se puede escribir como

$$(1 - B^s)y_t = \varepsilon_t \quad \text{Ecuación 4. Ecuación integrado estacional}$$

Donde  $\varepsilon_t$  es una secuencia de ruido blanco, o equivalentemente,

$$y_t = y_{t-s} + \varepsilon_t \quad \text{Ecuación 5. Equivalencia de ruido blanco}$$

Este modelo básico establece que la observación en el tiempo  $t$  es igual que la observación en el tiempo  $t - s$  excepto por un ruido aditivo.

De manera más general, un SARIMA  $(p, d, q) \times (P, D, Q)$ <sup>16</sup> modelo con un componente estacional se puede escribir como

$$\phi(B)\theta(B^s)(1 - B)^d(1 - B)^D y_t = \phi(B)\theta(B^s)\varepsilon_t \quad \text{Ecuación 6. SARIMA con componente estacional}$$

donde  $\varepsilon_t$  es una secuencia de ruido blanco con media cero y varianza  $\sigma^2$  y los polinomios respectivos están dados por

---

<sup>15</sup> Que se ajuste lo más posible a los datos históricos de los cuales cuento para el propósito del trabajo.

<sup>16</sup> Para  $p$  es el número de valores pasados,  $d$  son diferencias regulares,  $q$  errores pasados,  $P, D, Q$  son la contraparte, pero para los valores estacionales (Hanke and Wichern, 2006).

$$\begin{aligned}\phi(B) &= 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p, \\ \phi(B^S) &= 1 - \phi_1 B^S - \phi_2 B^{2S} - \dots - \phi_p B^{pS}, \\ \phi(B) &= 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_q B^q, \\ \phi(B^S) &= 1 - \phi_1 B^S - \phi_2 B^{2S} - \dots - \phi_q B^{qS},\end{aligned}$$

Ecuación 7. Polinomios para ruido blanco y varianza

Como se puede observar, en los polinomios se representa la parte pura del modelo ARIMA y la parte SARIMA, considerando la variable S de estacionalidad. Esto nos permitirá considerar la estacionalidad de datos históricos dentro del modelo SARIMA.

Por lo anterior, además, podemos darnos cuenta de que pueden tener más de un componente estacional, por lo que es necesario considerarlo por medio del siguiente tema varios componentes estacionales.

### Varios componentes estacionales

Los modelos SARIMA también se pueden extender para manejar más de un período estacional. Por ejemplo, podemos escribir un SARIMA  $(p, d, q) \times (P_1, D_1, Q_1)_{sm} \times (P_m, D_m, Q_m)$  modelo con m componente estacional que se puede escribir como

$$\begin{aligned}\phi(B)\phi_1(B^{S^1}) \dots \phi_m[B^{sm}(1 - B)^d(1 - B^{S^1})^{D^1} \dots (1 - B^{sm})^{D^m}]y_t \\ = \phi(B)\phi_1(B^{S^1}) \dots \phi_m(B^{2m})\varepsilon_t\end{aligned}$$

Ecuación 8. Modelo para varios componentes de un período.

Donde  $\varepsilon_t$  es una secuencia de ruido blanco con media cero y varianza  $\sigma^2$  y

$$\begin{aligned}\phi(B) &= 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p, \\ \phi_i(B^{S^i}) &= 1 - \phi_{i1} B^{S^i} - \phi_{i2} B^{2S^i} - \dots - \phi_{ip} B^{pS^i}, \\ \phi(B) &= 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_q B^q,\end{aligned}$$

Ecuación 9. Polinomios que representan media cero y varianza cuadrada

$$\phi_i(B^{si}) = 1 - \phi_{i1}B^{si} - \phi_{i2}B^{2si} - \dots - \phi_{iQ}B^{Qsi},$$

En suma, el hecho de que los modelos ARIMA consideran la variable de estacionalidad para datos históricos, permite suponer su conveniencia para el desarrollo de un modelo, utilizando los datos de la EPM que permitirán caracterizarlos considerando el componente de estacionalidad. Sin embargo, la estacionalidad no es el único criterio para considerar para la elección de la técnica de modelación, sino también la solidez para elegir el mejor modelo ARIMA con estacionalidad con base en los criterios Akaike (AIC) y bayesiano (BIC), que se explican a continuación.

### 3.2.5 Criterios de selección

Hanke, J. and Wichern, D. (2006) dice que es posible identificar (seleccionar) los modelos ARIMA, examinando una gráfica de la serie y al establecer una correspondencia entre los patrones de las autocorrelaciones de la muestra y las autocorrelaciones parciales de la muestra con los patrones teóricos, conocidos de los procesos ARIMA. Sin embargo, existe cierta subjetividad implicada en este procedimiento, y es posible que dos (o más) modelos iniciales sean congruentes con los patrones de las autocorrelaciones de la muestra y las autocorrelaciones parciales de la muestra; más aún, después de la estimación y verificación, ambos modelos pueden representar adecuadamente los datos.

Si los modelos contienen el mismo número de parámetros, el modelo con menor error cuadrático medio,  $s^2$ , es por lo general el seleccionado. Si los modelos contienen diferentes números de parámetros, el principio de parsimonia conduce a la selección del modelo más sencillo. Sin embargo, el modelo con más parámetros puede tener un error cuadrático medio considerablemente menor, ya que contempla más aspectos que impactan al modelo. Por lo anterior, se desarrolló un método para la selección del modelo que considere tanto el ajuste del modelo como el número de parámetros.

El criterio de información de Akaike (1974), o AIC, selecciona el mejor modelo de un grupo que minimiza.

$$AIC = \ln \hat{\sigma}^2 + \frac{2}{n} r \quad \text{Ecuación 10. Criterio AIC}$$

Donde

$\ln$  = logaritmo natural

$\hat{\sigma}^2$  = suma residual de cuadrados dividida entre el número de observaciones

$n$  = número de observaciones (residuos)

$r$  = número total de parámetros (incluyendo el término constante) en el modelo

El criterio de información bayesiano que desarrolló Schwarz (1978), o BIC, selecciona el modelo que minimiza

$$BIC = \ln \hat{\sigma}^2 + \frac{\ln n}{n} r \quad \text{Ecuación 11. Criterio BIC}$$

El segundo término tanto en el criterio AIC como en el criterio BIC es un factor que “penaliza” la inclusión de parámetros adicionales en el modelo. Como el criterio BIC impone una penalización mayor para el número de parámetros que el criterio AIC, el uso del BIC mínimo para la selección del modelo tendrá como resultado un modelo cuyo número de parámetros no será mayor que el seleccionado por el AIC. A menudo los dos criterios producen el mismo resultado. El AIC y el BIC deben considerarse como procedimientos adicionales para ayudar en la selección del modelo.

Mas allá de la justificación teórica existe un conjunto de estudios que ha utilizado modelos como los planteados anteriormente para analizar diversas en distintos sectores; entre ellos hay referentes al petróleo en general, pero particularmente con el pronóstico presupuestal de la mano de obra de una EPM.

### 3.3 Evidencia empírica del uso de diferentes técnicas de pronósticos

Algunos autores aplicaron este método en diferentes áreas a la petrolera para el análisis y pronosticar: calidad del agua (Katimon, Ayob, Shamsuddin Shahid, and Morteza Mohsenipour. 2018), el tráfico de carreteras en tiempo real (Xu, Dong-wei, Yong-dong Wang, Li-min Jia, Yong Qin, and Hong-hui Dong. 2017), ahorro de energía en sensores inalámbricos (Li, Guorui, and Ying Wang. 2013) de tiempo de degradación de circuitos TTL (Gorlov, M. I., and A. V. Strogonov. 2007) y ocupación de camas en un brote como el SARS (Earnest, Arul, Mark I. Chen, Donald Ng, and Yee Sin Leo. 2005); utilizando datos históricos y modelos ARIMA estacionales como se detalla en la siguiente Tabla 4:

**Tabla 4. Artículos internacionales de modelos ARIMA en diferentes áreas.**

No.	Artículo	Pregunta de investigación	Datos	Métodos	Variables dependientes	Recomendaciones
1	Satish Kumar, K., and E. Venkata Rathnam. 2019	¿Se puede pronosticar las variaciones subterráneas con ARIMA y Mann Kendall (MK)?	Datos de la variación mensual, anual y estacional del agua subterránea del distrito de Warangal (2000-2015) para cuarenta pozos de observación	Modelado de series de tiempo ARIMA y métodos no paramétricos de Mann Kendall (MK)	Los pozos 2, 17, 22, 33, 38, 39, 40 notaron fuertes tendencias negativas significativas. Usando MK-1 / MK-2 / MK-3 / MK-4 para series mensuales, alrededor del 23/33/23/23% de los casos exhibieron tendencias positivas (significativas e insignificantes) y 77/67/77/77% de los casos mostraron tendencias negativas. El estudio concluye que las tendencias negativas dominan las tendencias positivas en casi 37 pozos de observación y los modelos ARIMA generaron mejores resultados para la región seleccionada.	
2	Katimon, Ayob, Shamsuddin Shahid, and Morteza Mohsenipour. 2018	¿Se puede hacer el modelado de calidad del agua y las variables hidrológicas para el río Johor, Malasia?	Datos de variables hidrológicas, a saber, precipitaciones y descargas de ríos, para el río Johor, Malasia, registrado para el período 2004–2007	Modelado de series de tiempo ARIMA	Los resultados mostraron que, excepto Al3 +, Fe2 +, NH4 + y la lluvia, todas las demás variables son estacionarias. Las series de tiempo no estacionarias se pueden ajustar con ARIMA (p, 1, q) <sup>17</sup> , mientras que las series de tiempo estacionarias se pueden ajustar con el modelo AR con intervalos de tiempo de 1 a 5. Las autocorrelaciones de todas las muestras se encontraron dentro de los límites de confianza del 95% y se encontró que los residuos del modelo seguían una distribución de probabilidad normal, lo que indica que son idóneos los modelos.	Los modelos pueden ser muy beneficiosos para la cuenca donde la calidad del agua de los ríos es un problema importante debido a los rápidos cambios en el uso de la tierra en los últimos años. Información obtenida de la serie temporal
3	Xu, Dong-wei, Yong-dong Wang, Li-min Jia, Yong Qin, and Hong-hui Dong. 2017	¿Se puede pronosticar el tráfico de carretera en tiempo real basado en ARIMA y filtro Kalman <sup>18</sup> ?	Base de datos históricos de tráfico por carretera 2011	Modelado de series de tiempo ARIMA y filtro Kalman	La predicción del estado del tráfico basada en el modelo ARIMA-Kalman se desempeña admirablemente en el seguimiento de tendencias en la variación del estado del tráfico. La suma de cuadrados del error relativo medio significa que el algoritmo propuesto es más estable que el modelo ARIMA puro y el filtro de Kalman. El algoritmo propuesto es fácil de implementar en una computadora.	Teniendo en cuenta el notable rendimiento del algoritmo propuesto, exploraremos la predicción del estado del tráfico basada en correlaciones espaciotemporales en nuestro próximo estudio.
4	Li, Guorui, and Ying Wang. 2013	¿Es posible disminuir los datos transmitidos entre nodos y agregadores para el ahorro de energía de los sensores inalámbricos mediante ARIMA?	Datos reales de consumo de energía de los sensores inalámbricos	Modelado de series de tiempo ARIMA <sup>19</sup>	El esquema propuesto puede ahorrar efectivamente la valiosa energía de la batería de los nodos de sensores inalámbricos mientras mantiene los valores de datos predichos de los agregadores dentro del umbral de error definido por la aplicación. Su simulación y análisis indican que los valores predichos de nuestro esquema propuesto se ajustan muy bien a los valores reales detectados y se requieren menos mensajes para transmitir entre el nodo sensor y el agregador.	Como trabajo futuro, nos gustaría mejorar nuestro esquema de agregación de datos propuesto utilizando características de correlación de datos espaciales y temporales juntas.
5	Gorlov, M. I., and A. V. Strogonov. 2007	Se puede pronosticar el tiempo de degradación de circuitos TTL <sup>20</sup> con ARIMA?	Datos de longitudes de prueba son 110 000-150 000 h de vida	Modelado de series de tiempo ARIMA	Los pronósticos de intervalo para 106LB1 y 134LB1 indican una vida útil más corta que el valor de garantía 150 000 h. Los de los modelos 133LR3 y 133LA8 son compatibles con la vida útil de la garantía de 200 000 h en condiciones de poca carga	
6	Earnest, Arul, Mark I. Chen, Donald Ng, and Yee Sin Leo. 2005	¿Con un modelo ARIMA se puede pronosticar la ocupación de camas durante un brote de SARS en un hospital de Singapur?	Los datos de hospitalización y ocupación de las camas de aislamiento se recopilaron del hospital Tan Tock Seng durante el período del 14 de marzo de 2003 al 31 de mayo de 2003.	Modelado de series de tiempo ARIMA	Encontramos que el modelo ARIMA (1,0,3) fue capaz de describir y predecir bien el número de camas ocupadas durante el brote de SRAS. El error porcentual absoluto medio (MAPE) para el conjunto de entrenamiento y el conjunto de validación fue del 5,7% y del 8,6% respectivamente, lo que consideramos razonable para su uso en el entorno hospitalario. Además, el modelo también proporcionó previsiones de tres días sobre el número de camas necesarias.	

Fuente: Elaboración propia con citas del sector internacional.

<sup>17</sup> Los resultados de los modelos ajustados indican que las series AL3 +, FE2 +, NH4 + y RAINFALL del río Johor pueden ser imitadas por ARIMA y las series MN2 +, pH, COLOR, FLOW, TURB y SS pueden ser modeladas por procesos AR.

<sup>18</sup> El filtro de Kalman se ha aplicado ampliamente en análisis de datos estacionarios y no estacionarios debido a su desempeño favorable. El modelo también es computacionalmente eficiente, ya que solo requiere una capacidad de almacenamiento extremadamente pequeña y es adecuado para la predicción del volumen de tráfico en tiempo real.

<sup>19</sup> Primero se presenta el modelo de predicción ARIMA y luego se describe cómo el modelo de predicción ARIMA podría construirse y aplicarse en un esquema de agregación de datos para disminuir la cantidad de mensajes transmitidos dentro de la red.

<sup>20</sup> Transistor- Transistor Logic

Otros artículos hablan del ramo petrolero pero dirigidos a modelos para predecir el: precio del petróleo utilizando datos históricos de una de 30 años y utilizando diferentes técnicas como ARMA, AR, VAR (Funk, Christoph. 2018; Li, Jinchao, Shaowen Zhu, and Qianqian Wu. 2019; Wang, Yudong, Li Liu, and Chongfeng Wu. 2017), inteligencia artificial (Ramyar, S., & Kianfar, F. (2019)), LASSO (Zhang, Yaojie, Feng Ma, and Yudong Wang. 2019), red elástica (Zhang, Yaojie, Feng Ma, and Yudong Wang. 2019) y clasificador Gamma (Sheremetov, L. (2013)), en la Tabla 5 se detalla más sobre los casos mencionados:

**Tabla 5. Artículos internacionales de modelos utilizados en el área petrolera.**

No.	Artículo	Pregunta de investigación	Datos	Métodos	Variables dependientes	Recomendaciones
1	Funk, Christoph. 2018	¿Es posible generar un pronóstico preciso del precio real del petróleo y cómo se puede mejorar utilizando combinaciones de pronóstico?	Datos históricos del precio del petróleo desde 1974 a 2017.	Promedio móvil autorregresivo (AR), autorregresivo (ARMA), modelo VAR, basado en inventarios, movimientos de precios con acciones sensibles al petróleo, Punto de referencia sin cambios, futuros	Por lo tanto, una combinación que consta de cuatro modelos, p. "Futuros", "Inventarios de la OCDE", "VAR CLI" y el "Índice CRB" han demostrado tener una relación MSPE <sup>21</sup> (índice de bolsa de valores) más baja que los mejores modelos individuales a medio plazo y, además, son notablemente estables a lo largo del tiempo.	La investigación futura debería concentrarse más en la incertidumbre del pronóstico asociada con los modelos individuales, ya que hay margen de mejora.
2	Li, Jinchao, Shaowen Zhu, and Qianqian Wu. 2019	¿Se puede pronosticar mensualmente el precio del petróleo usando descomposición en modo variacional?	Datos históricos de los precios del petróleo del West Texas Intermediate (WTI) y Brent desde 1994 al 2018	Técnicas de descomposición en modo variacional e inteligencia artificial (AI)	Los resultados del análisis empírico demuestran que los modelos híbridos basados en VMD tienen un mejor rendimiento de predicción en comparación con los modelos basados en EEMD anteriormente populares y los modelos únicos para la predicción del precio del petróleo crudo, lo que sugiere que el algoritmo VMD es una herramienta prometedora para la predicción de series de tiempo complejas.	Entonces, en nuestro trabajo futuro, podemos considerar los factores estocásticos a corto plazo de la variación del precio del petróleo crudo y mejorar aún más la precisión del pronóstico.
3	Wang, Yudong, Li Liu, and Chongfeng Wu. 2017	¿Son mejores las combinaciones de métodos de pronósticos para sobre modelos de parámetros variables en el tiempo?	Datos históricos del precio del petróleo desde 1986 a 2014.	Regresiones predictivas	TVP no necesariamente se desempeña mejor que su contraparte CC. Ninguno de los modelos individuales puede superar el punto de referencia del modelo sin cambios para pronosticar los precios reales del petróleo en todos los horizontes. La predictibilidad robusta y consistente se encuentra cuando se emplean las combinaciones de pronóstico sobre los modelos TVP. Las estrategias FC-TVP también generan pronósticos de precios del petróleo más precisos que las estrategias FC-CC bajo los dos criterios de MSPE y precisión direccional.	Se pueden emplear datos financieros de alta frecuencia y utilizar modelos de parámetros variables en el tiempo para pronosticar el precio del petróleo. En segundo lugar, además de las variables fundamentales, los indicadores técnicos también pueden considerarse como predictores de cambios en el precio del petróleo.
4	Zhang, Yaojie, Feng Ma, and Yudong Wang. 2019	¿Puede LASSO seleccionar predictores potentes?	Datos históricos del precio del petróleo desde 1986 al 2016.	LASSO, red elástica	Los resultados fuera de la muestra indican que los modelos de red elástica superan a una serie de modelos competidores ampliamente utilizados en términos de R-cuadrado fuera de la muestra y tasa de éxito. Los métodos de red elástica se encuentran para seleccionar predictores poderosos y aquellos que pueden proporcionar información complementaria.	
5	Zhang, Yaojie, Feng Ma, Benshan Shi, and Dengshi Huang. 2018	¿Puede una combinación iterada pronosticar precios del petróleo?	Datos históricos del precio del petróleo desde 1986 al 2016.	Modelos de regresión, combinación iterada	Los resultados empíricos muestran que el enfoque de combinación iterada supera al enfoque de combinación estándar tanto dentro como fuera de la muestra. Específicamente, los pronósticos de combinación iterados siempre producen valores R2 fuera de la muestra significativamente mayores y tasas de éxito más altas que los pronósticos de combinación estándar correspondientes.	
6	Ramyar, S., & Kianfar, F. (2019)	¿Es posible pronosticar los precios del petróleo comparando una red neuronal artificial y un modelo autorregresivo vectorial?	Datos históricos del precio del petróleo desde 1980 a 2014.	Modelo autorregresivo neuronal artificial, Redes	Se concluyó que mediante una selección cuidadosa de los impulsores clave de los precios del petróleo crudo y una red neuronal MLP con un número suficientemente grande de neuronas en su capa oculta, se pueden obtener estimaciones más confiables del precio del petróleo crudo en comparación con las estimaciones del modelo VAR propuesto.	Para trabajos futuros pueden investigar empíricamente el poder de predictibilidad fuera de la muestra de los modelos de pronóstico VAR y ANN.
7	Sheremetov, L. (2013)	¿Es predecible pronosticar series temporales con el clasificador Gamma para pronosticar producción del petróleo?	Se utilizan datos históricos del petróleo de 30 años	Clasificador Gamma	El modelo se basa en el clasificador Gamma, que se inspira en las memorias asociativas Alfa-Beta, tomando los operadores alfa y beta como base para el operador gamma. El objetivo es reproducir y predecir la producción futura de petróleo en diferentes escenarios en una ventana de tiempo ajustable. Las características distintivas del conjunto de datos experimentales son picos, cambios abruptos y discontinuidades frecuentes, que disminuyen considerablemente la precisión de los métodos tradicionales de predicción.	

Fuente: Elaboración propia con citas del sector internacional.

<sup>21</sup> Índice bursátil MSCI Pan Euro (MSPE)

En suma, los modelos autorregresivos (AR) que utilizan valores pasados y actuales, y los de promedios móviles (MA) que consideran los errores pasados y actuales, dan lugar a los modelos ARMA que, al agregar el componente estacional de las series a considerar, dan paso a los modelos SARIMA el cual, dentro de sus parámetros, toma en cuenta la estacionalidad y es el método que se ajustaría de acuerdo con los datos históricos con los que cuenta la **EPM** para poder pronosticar el presupuesto necesario para la mano de obra de manera anual, dado que cumple las características que dichos modelos exigen y que se describirán en el siguiente apartado.

### **3.4 Elección del método para el pronóstico**

Para el pronóstico del costo presupuestal de mano de obra de la EP (EPM) se va a utilizar los siguientes datos:

- ✓ Ejercicio presupuestal histórico de 2017 a 2020 en términos reales, tomando como referencia el IPNC cuyo año base es el 2020.
- ✓ Las ponderaciones (porcentajes) que se mencionaron en el Capítulo 1 fondo de ahorro, aguinaldo, vacaciones y buen fin.

Para los datos históricos de ejercicio presupuestal se utilizó el modelo autorregresivo Box-Jenkins (ARIMA), dado que los datos a considerar se tiene una muestra histórica de 2017 a 2020 y además cuenta con estacionalidad, lo cual considera dicho modelo.

Para el desarrollo y análisis del modelo hay que tomar en cuenta que:

1. El pronóstico se hace sobre la misma variable de los datos históricos del ejercicio presupuestal, en consecuencia;
2. Se consideran variables independientes.
3. Es un método iterativo que permite la mejora continua en cada inserción de datos nuevos.

El desarrollo del modelo toma en cuenta las características de las series de tiempo de acuerdo con Damodar N. Gujarati., Dawn C. Porter. (2010):

1. **Estacionarias:** una serie de tiempo es estacionaria si su media y varianza no varían sistemáticamente con el tiempo.
2. **Estacionalidad:** Muchas series de tiempo económicas que se basan en datos mensuales o trimestrales presentan pautas estacionales (movimiento oscilatorio regular), por ejemplo, las ventas de las tiendas de departamentos en la época de Navidad y otras festividades importantes; la demanda de dinero (saldos de efectivo) por parte de las familias en época de vacaciones; la demanda de helado y bebidas gaseosas durante el verano y los precios de los cultivos justo después de la época de cosecha; la demanda de viajes en avión, etc.
3. **Tendencia:** si la tendencia de una serie de tiempo es del todo predecible y no variable, se le llama tendencia determinista; si no es predecible, se le llama tendencia estocástica.
4. **Ruido blanco:** es un término de error aleatorio no correlacionado con media cero y varianza constante.

## Capítulo 4. Solución propuesta e implementación.

### Propuesta

Derivado de lo anterior, surge la necesidad de implementar un proceso de pronóstico, basado en el mejor modelo autorregresivo<sup>22</sup> que integre el proceso generador de datos para el pronóstico del costo de la mano de obra de la EPM que nos ayudará de la siguiente manera:

- ✓ Tener los recursos presupuestales para enfrentar el costo de mano de obra del anteproyecto presupuestal<sup>23</sup> del siguiente año, con base en el gasto del año en curso.
- ✓ Tener los recursos necesarios en la cobertura de plazas temporales que se crean en función de los requerimientos de la EPM a lo largo del año, así como para la estructura o reestructura de nuevas áreas que sean creadas de acuerdo con las estructuras autorizadas por el consejo de EPM.
- ✓ La estandarización del proceso y la capacidad de ajustar más fácilmente el modelo ante cambios dramáticos en algunas de las variables.

Por lo tanto, se utilizarán las herramientas informáticas institucionales vigentes en la EPM en el momento de la implementación:

1. Microsoft SQL Server R2 2008: es donde tendremos los datos históricos para el pronóstico, se hará un histórico de los pronósticos del costo presupuestal de mano de obra de la EP y servirá para alimentar la página web.
2. Programación R: software libre donde se crearán los diferentes escenarios de la metodología Box-Jenkins ARIMA estacional (SARIMA) y que, por supuesto cuenta con las herramientas de suavizado exponencial, estacionalidad, tendencia y descomposición

---

<sup>22</sup> La mejor opción de proceso autorregresivo es aquel que mejor se ajusta a los datos históricos.

<sup>23</sup> El anteproyecto presupuestal se realiza a partir del presupuesto que se va a impactar al siguiente año, y esa base sirve de justificación ante SHCP para que otorgue los recursos presupuestales para EPM.

3. Microsoft Power BI: se utilizará para crear la página web donde se mostrará el pronóstico del costo presupuestal de mano de obra de la EP que se alimentará de los datos almacenados en la base de datos de Microsoft SQL R2 2008.

Se modelarán varios escenarios con programación R y se seleccionará con base a las siguientes pruebas estadísticas:

1. Transformación de los datos nominales a reales año con año base 2020.
2. Conversión de los datos al multiplicarlos y dividirlos sobre un valor fijo, ya que por la competencia que existe por varias empresas en el país que se dedican al ramo petrolero es de suma importancia guardar el tema de confidencialidad.<sup>24</sup>
3. Para identificar el modelo de manera visual se utilizarán pruebas gráficas de los datos como mecanismo inicial para la selección del tipo de Proceso Autorregresivo que mejor se ajusta a los datos.
4. Prueba de normalidad
  - a. De manera gráfica, para verificar las propiedades de una serie con distribución normal.
  - b. Mediante, “Si el ***p-value***, cuyo criterio de decisión es, para un  $\alpha=0.05$ , se rechaza ***H0*** y existe evidencia en la muestra que  $\epsilon_t$ , no se distribuye de forma normal.”
  - c. Prueba de heteroscedasticidad de manera estadística; “Si el ***p-value*** es menor al nivel  $\alpha=0.05$ , se rechaza ***H0*** de homoscedasticidad y se asume que existe heteroscedasticidad en los datos.”
  - d. Prueba de estacionariedad mediante, “***p-value***, es menor al nivel  $\alpha=0.05$ , se rechaza ***H0*** y existe evidencia que  $\epsilon_t$  es un proceso estacionario.”
5. Prueba de autocorrelación (ACF<sup>25</sup> y PACF<sup>26</sup>) de manera gráfica, nos indica qué tipo de Proceso Autorregresivo puede ajustarse mejor a los datos y si los datos históricos existe un vínculo con los rezagos.

---

<sup>24</sup> Es un convenio de confidencialidad del trabajador con la empresa donde no se debe divulgar información fuera del área de trabajo.

<sup>25</sup> Función de autocorrelación por sus siglas en ingles ACF

<sup>26</sup> Función de correlación parcial por sus siglas en ingles PACF

6. Probar si el proceso tiene estacionalidad es básicamente identificar si las variables independientes tienen alguna estacionalidad para ser considerada en el modelo seleccionado.
7. Probar si el proceso tiene volatilidad es identificar en el modelo seleccionado si tiene valores que se encuentran muy alejados de las bandas de confianza, de acuerdo con los datos históricos.

A partir de la construcción de la base con las características planteadas anteriormente, se pretende modelar cinco escenarios a comparar y seleccionar el modelo que se comporte mejor de acuerdo con los datos históricos, es decir, verificar qué modelo se acerca más a los valores observados de mano de obra de EPM, lo más cercano a la realidad.

### **Ventajas de la propuesta:**

El uso de procesos autorregresivos permite de manera continua<sup>27</sup> seleccionar el mejor modelo que se ajuste a los datos reales del costo de mano de obra de EPM; en consecuencia, tener un mejor control de los rezagos que se presenten en tiempo real, por lo tanto, se tienen las siguientes ventajas:

1. Se realizará una base de datos histórica (4 años) de lo ejercido en mano de obra y también del año en curso y así ir alimentando nuestra base histórica con los años futuros para poder tener un mejor pronóstico, ya que en el método actual no está contemplada.
2. En programación R se realizarán las pruebas estadísticas para identificar el mejor modelo de acuerdo con los datos, para así evitar la incertidumbre de los promedios, como actualmente se lleva a cabo.
3. El desarrollo de un modelador de escenarios estandarizado, que cualquier usuario puede utilizar.
4. Las variables que impactan para realizar el pronóstico del costo de mano de obra estarán consideradas en el proceso autorregresivo que se seleccionará. Actualmente no se cuenta con un modelo cercano a los datos reales.
5. Se ahorrará tiempo en el pronóstico y en consecuencia será más acertado, ya que en el método actual les lleva más de un día realizarlo.

---

<sup>27</sup> Es decir, se realiza un ciclo de mejora continua cada que existen nuevos datos a lo largo del año

Con base en lo anterior, la ejecución de las decisiones tomadas a nivel ejecutivo será más acertadas, cercanas a lo real, lo que equivaldría a un nivel de confianza del 95%.

## Proceso del pronóstico de Mano de obra de Empresa Mexicana Petrolera

Fuente: Elaboración propia con datos de la Empresa Petrolera vigente al 2021.

En programación R es donde tenemos el modelo del pronóstico de Mano de obra la cual recibe datos históricos de 2017 a 2020 para poder calcular el modelo y de acuerdo con modelo encontrado sirve para alimentar la Base de datos de SQL y así ajustar la base datos al pronóstico seleccionado.

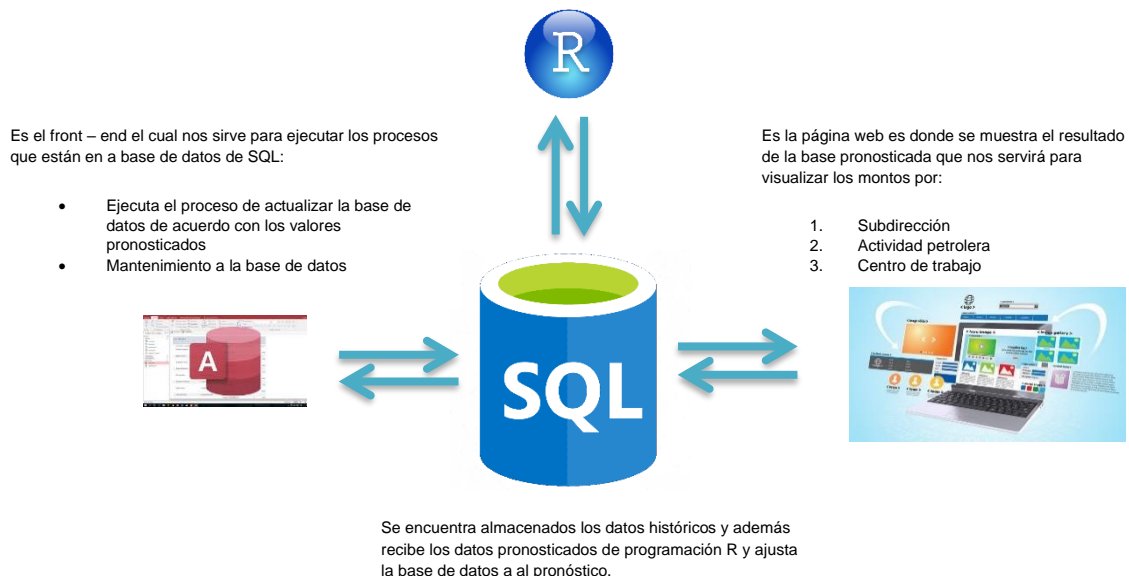


Figura 4. Funcionamiento de la implementación en la EPM.

## Implementación

Utilizando la metodología SARIMA. Como se describió en el capítulo de marco teórico, la implementación consta de cuatro puntos esenciales:

- A. Base de datos: se almacenan los datos históricos del ejercicio presupuestal que sirven de entrada a nuestro programa; se guardará el vector resultante del modelo seleccionado en programación R.

B. Programación R: se creó un programa donde se ejecuta con base en criterios estadísticos; se selecciona el modelo que se ajuste a la serie de tiempo original, que a su vez alimentará una base de datos.

C. Microsoft Access: se crea un Front-end que servirá para dar mantenimiento a la base de datos y además ajustará el resultado al vector resultante pronosticado en programación R

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.

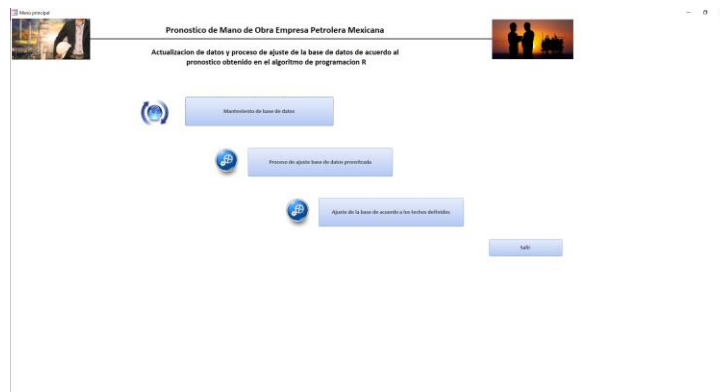


Figura 5. Front end de ejecución de armado de información para la página web.

D. Power BI: es donde se desarrolla la página web para visualizar los datos reales y pronosticados de acuerdo con el modelo seleccionado en programación R

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.



Figura 6. Página web del pronóstico.

## Capítulo 5. Resultados, análisis e interpretación.

A continuación, se describen los pasos en programación R que realiza el programa, donde se desarrolló la prueba con modelos como los que se muestran:

- SARIMA (2,1,2) (2,1,1)
- SARIMA (3,1,3) (2,1,2)
- SARIMA (3,1,3) (1,1,2)
- SARIMA (1,1,0) (1,1,1)
- SARIMA (0,1,2) (0,1,1)

El modelo seleccionado es el SARIMA (0,1,2) (0,1,1), ya que es el que mejor se ajustó a los datos históricos y a continuación se muestran los resultados de dicho modelo de acuerdo a lo siguiente:

1. Se utilizan datos históricos del ejercicio presupuestal del 2017 al 2020
2. Se grafican cómo se observan los datos históricos mencionados en el punto 1

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.

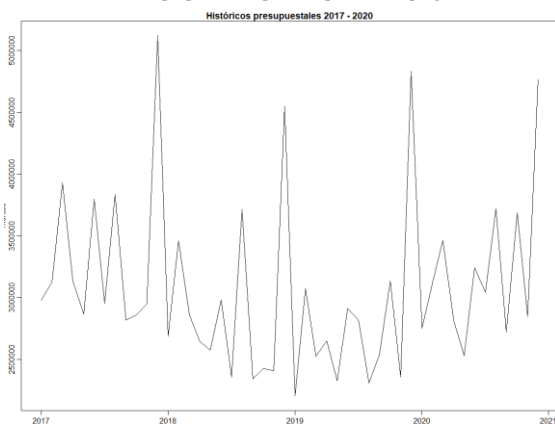


Figura 7. Gráfica del horizonte de valores del 2017 – 2020.

3. Se aplica un logaritmo a la serie para ajustar y tratar de llevarla a un comportamiento de manera normal

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.

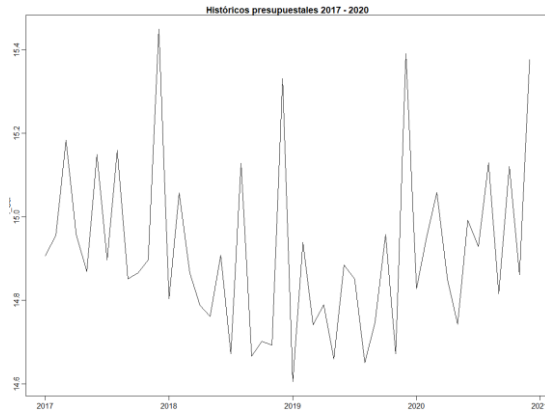


Figura 8. Gráfica aplicando logaritmo al horizonte de valores 2017 – 2020.

4. Se aplica una diferencia de logaritmo ya que como se observa en la gráfica anterior no se comporta de manera normal

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.




Figura 9. Gráfica aplicando diferencia de logaritmo al horizonte de valores 2017 – 2020.

5. Por regla también se debe aplicar una diferencia estacional ya que la serie contiene datos estacionales, porque los picos de la Figura 9 en cada año se observan de la misma similitud.

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.

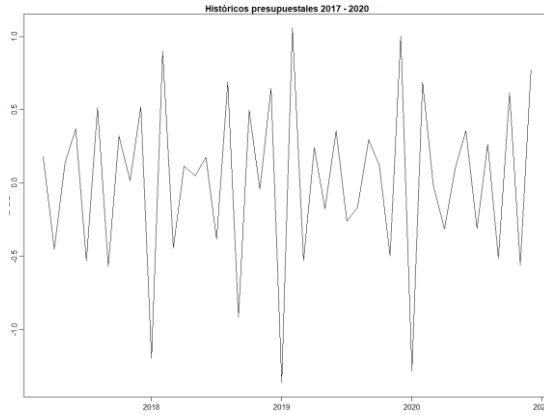


Figura 10. Gráfica aplicando diferencia estacional al horizonte de valores 2017 – 2020.

6. Con base a los criterios de Bayes y Akaike, el mejor modelo es el que tenga valores más negativos posibles en ambos criterios.

Tabla 6. Resultado de los modelos SARIMA en base al criterio BIC y AIC.

Número	Modelo	BIC	AIC	Observación
1	SARIMA (2,1,2) (2,1,1)	-0.4706813	-0.8261894	
2	SARIMA (3,1,3) (2,1,2)	-0.3537995	-0.8426232	
3	SARIMA (3,1,3) (1,1,2)	-0.4046749	-0.8490601	
4	SARIMA (1,1,0) (1,1,1)	-0.3517438	-0.5294978	
5	SARIMA (0,1,2) (0,1,1)	-0.7335749	-0.911329	Este es el modelo elegido porque los criterios de Bayes y Akaike son los más negativos posibles

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.

7. Una vez seleccionado el modelo se hace el pronóstico para los años 2021 y 2022, de acuerdo con lo siguiente:
  - i. En la gráfica se pueden observar los valores históricos del ejercicio de un horizonte del 2017 – 2020, que dan pie a los valores pronosticados del modelo seleccionado.
  - ii. La línea de color rojo son los valores pronosticados con el modelo seleccionado con base a los datos históricos del ejercicio.

- iii. Las bandas de color gris claro son de un nivel de confianza bajo y alto del 80%, esto quiere decir que los valores pronosticados (línea roja) pueden oscilar hasta esos valores de confianza.
- iv. Las bandas de color gris fuerte son de un nivel de confianza bajo y alto del 95%, esto quiere decir que los valores pronosticados (línea roja), pueden oscilar hasta esos valores de confianza.

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.




Figura 11. Grafica de los valores pronosticados para el 2021 y 2022.

- 8. Los valores pronosticados para los años 2021 y 2022 con un nivel de confianza de bajos y alto de entre 80% y 95% son los siguientes que se utilizarán para alimentar la base de datos en SQL Server R2 2008 y posteriormente para visualizar los datos en la página web.

**Tabla 7. Valores pronosticados para el 2021 y 2022.**

Mes	Año	Pronostico	Nivel de confianza			
			Lo 80	Hi 80	Lo 95	Hi 95
Enero	2021	3,116,663	2,606,478	3,626,848	2,336,402	3,896,924
Febrero	2021	3,437,524	2,925,972	3,949,076	2,655,173	4,219,875
Marzo	2021	3,437,769	2,902,433	3,973,106	2,619,044	4,256,495
Abril	2021	3,052,510	2,494,402	3,610,617	2,198,957	3,906,062
Mayo	2021	2,804,787	2,224,801	3,384,773	1,917,775	3,691,799
Junio	2021	3,461,624	2,860,555	4,062,693	2,542,369	4,380,879
Julio	2021	3,086,363	2,464,927	3,707,799	2,135,958	4,036,768
Agosto	2021	3,630,825	2,989,667	4,271,982	2,650,259	4,611,390
Septiembre	2021	2,871,597	2,211,308	3,531,887	1,861,771	3,881,423
Octubre	2021	3,394,690	2,715,807	4,073,573	2,356,428	4,432,952
Noviembre	2021	2,905,282	2,208,302	3,602,262	1,839,343	3,971,221
Diciembre	2021	5,075,919	4,362,283	5,789,554	3,984,507	6,167,330
Enero	2022	3,018,119	2,229,215	3,807,024	1,811,594	4,224,645
Febrero	2022	3,486,300	2,684,911	4,287,689	2,260,681	4,711,919
Marzo	2022	3,486,545	2,658,216	4,314,875	2,219,724	4,753,366
Abril	2022	3,101,285	2,246,864	3,955,706	1,794,561	4,408,010
Mayo	2022	2,853,563	1,973,824	3,733,302	1,508,118	4,199,008
Junio	2022	3,510,400	2,606,051	4,414,749	2,127,318	4,893,482
Julio	2022	3,135,139	2,206,833	4,063,445	1,715,417	4,554,860
Agosto	2022	3,679,601	2,727,940	4,631,261	2,224,161	5,135,040
Septiembre	2022	2,920,373	1,945,918	3,894,828	1,430,072	4,410,674
Octubre	2022	3,443,466	2,446,736	4,440,195	1,919,100	4,967,831
Noviembre	2022	2,954,058	1,935,542	3,972,574	1,396,372	4,511,743
Diciembre	2022	5,124,694	4,086,094	6,163,295	3,536,292	6,713,097

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.

9. Se muestran los elementos de la página web que está dividida en cinco secciones, que es la que utilizarán para la toma de decisiones a nivel dirección para la asignación de presupuesto de cada año y para así mostrar por áreas, municipios y clave de campos petroleros como se distribuye el presupuesto de mano de obra en las diferentes áreas de exploración y producción que es donde se destinarán los recursos presupuestales excedentes de acuerdo modelo estadístico implementado.

i. En la primera sección se observa por subdirección como está

conformada la mano de obra por los presupuestado 2021 (lo pronosticado por ponderaciones), el ejercicio 2021 (lo que se gastó real), pronosticado por el modelo SARIMA los años 2021 y 2022.

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.

Subdirección	PPTO	EJER	2021	2022
Sede	22,682,684.64	19,987,014.62	20,600,433.63	20,820,852.25
Producción Región Sur	3,516,018.46	3,100,722.28	3,197,779.25	3,233,515.78
Producción Región Norte	3,776,970.65	3,331,780.30	3,435,718.90	3,473,877.45
Producción Región Marina Suroeste	4,154,204.74	3,654,611.94	3,783,932.11	3,824,239.10
Producción Región Marina Noreste	8,209,206.07	7,235,032.04	7,469,330.52	7,552,538.22
Exploración	1,965,480.13	1,731,689.23	1,788,358.59	1,808,520.19
<b>Total</b>	<b>44,304,564.69</b>	<b>39,040,850.42</b>	<b>40,275,553.00</b>	<b>40,713,543.00</b>

Figura 12. Comparativo a nivel subdirección de los presupuestado, ejercido del 2021 y pronosticado por el modelo SARIMA para el 2021 y 2022.

- ii. En la segunda sección se muestra únicamente el ejercicio 2021 de lo que se gastó real a nivel de subdirecciones de la mano de obra.

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.



Figura 13. Grafica del ejercicio del año 2021.

- iii. La sección tres nos permite observar a través de un mapa como está distribuido el presupuesto de mano de obra 2021, pronosticado por nuestro modelo SARIMA.

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.



Figura 14. Mapa por estado de la distribución del presupuesto pronosticado 2021 por el modelo SARIMA.

- iv. En la sección cuatro se observa el pronóstico del año 2021 por el modelo SARIMA cómo está distribuido el presupuesto a nivel subdirección.

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.

### Pronóstico para el año 2021.




Figura 15. Grafica por subdirecciones de la distribución del presupuesto pronosticado 2021 por el modelo SARIMA.

- v. En la sección cuatro se observa el pronóstico del año 2022 por el modelo SARIMA cómo está distribuido el presupuesto a nivel subdirección.

Fuente: Elaboración propia de la captura de pantalla del programa desarrollado.

### Pronóstico para el años 2022.




Figura 16. Grafica por subdirecciones de la distribución del presupuesto pronosticado 2022 por el modelo SARIMA.

## Capítulo 6: Conclusiones.

1. El área de Exploración y Producción (EP) es el Core Business de la EPM; representa los mayores ingresos dentro de la empresa y cuenta con mayor plantilla de personal dividida en empleados de confianza y sindicalizados, tiene asignados el 63% del presupuesto dentro de la EPM.
2. La metodología actual para el pronóstico del costo de la mano de obra de EP, basada en el uso de ponderaciones de los rendimientos, el “Buen fin”, bono, fondo de ahorro y aguinaldo hace que la estimación tenga imprecisiones; la aplicación de este proceso daba lugar a una brecha entre lo presupuestado (proyectado) y lo ejercido (gasto real) en el año, que ha llegado a ser del 15.58%, dicha brecha representa un excedente sobre el monto pronosticado en el costo de mano de obra. Tales recursos, de optimizarse el proceso de cálculo, podrían ser direccionados al Core Business de la EPM.
3. Dado el peso que tienen el área de Exploración y Producción (EP) de la EPM cobra relevancia contar con una herramienta formal para el pronóstico del costo presupuestal de mano de obra, minimice la diferencia entre el gasto presupuestado y el ejercicio. Para ello, este trabajo propuso una metodología basada en técnicas estadísticas, computacionales, tales como sistemas autorregresivos que den certeza sobre el uso de los recursos disponibles en el año en cuestión; además de hacer más confiable la estimación del costo presupuestal de mano de obra. Su implementación a nivel institucional mediante una política interna representaría la estandarización de los criterios utilizados en todas las áreas.
4. De acuerdo con el diagnóstico que se realizó, cobra importancia encontrar el mejor método de pronóstico que permita reducir la brecha entre el costo presupuestal de mano de obra de la EPM pronosticado y el observado, considerando los datos disponibles de los cuales encontramos que algunas variables cuentan con estacionalidad.

5. A partir de la revisión y comparación de técnicas cuantitativas y cualitativas, se concluyó que los métodos autorregresivos, en general, y los modelos ARIMA, en particular, con componentes de estacionalidad, serían la herramienta adecuada para el análisis de los datos históricos con los que se estima el costo de mano de obra de la EPM, dado que el modelo se ajusta perfectamente a las necesidades de la EPM.
  
6. Además de la revisión de técnicas para el manejo de bases de datos con componente de estacionalidad, se revisaron las experiencias que utilizaron modelos autorregresivos con componentes de estacionalidad alrededor del mundo, entre los que se encontraron diversos trabajos con escasa evidencia para el área petrolera. Entre los casos encontrados en la literatura empírica sobresale el uso en temas como:
  - a. Calidad del agua (Katimon, Ayob, Shamsuddin Shahid, and Morteza Mohsenipour. 2018)
  - b. El tráfico de carreteras en tiempo real (Xu, Dong-wei, Yong-dong Wang, Li-min Jia, Yong Qin, and Hong-hui Dong. 2017)
  - c. Ahorro de energía en sensores inalámbricos (Li, Guorui, and Ying Wang. 2013) de tiempo de degradación de circuitos TTL (Gorlov, M. I., and A. V. Strogonov. 2007)
  - d. Ocupación de camas en un brote como el SARS (Earnest, Arul, Mark I. Chen, Donald Ng, and Yee Sin Leo. 2005);

Mientras que, en el área petrolera, los trabajos empíricos se concentran principalmente en el pronóstico del precio del petróleo. No se encontró evidencia o antecedentes de su utilización para la estimación del presupuesto del costo de mano de obra en el sector.

7. Los modelos autorregresivos ARIMA con estacionalidad, tienen la peculiaridad de

probar entre varios modelos y así determinar el mejor modelo que se ajustara a los datos históricos, mediante los criterios de selección de AIC y BIC cuyo criterio de decisión es seleccionar los que presenten los indicadores más negativos para así obtener el modelo cuyos valores se ajusten a las bandas de confiabilidad del 80 y 95% según sea el caso.

8. El modelo que se seleccionó como el más adecuado fue SARIMA (0,1,2) (0,1,1) que cumplía con los criterios AIC y BIC. Una vez que se verificaron los parámetros del modelo se realizó el pronóstico del 2021 y al compararlo con el ejercido, la brecha observada fue de apenas 3%, lo cual representa una disminución considerable con respecto al 15.58% que existía con el método anterior. Esto muestra la capacidad del modelo seleccionado para predecir el presupuesto, así como su capacidad para ajustarse con los datos históricos, gracias a que se considera la estacionalidad.
9. Para almacenar los históricos que servirán de entrada para nuestro SARIMA con estacionalidad y los resultados arrojados utilizamos Microsoft Sql Server 2008 R2, aprovechando los convenios con que cuenta la empresa y así maximizar recursos, a partir de lo cual se creó una página web en Power BI.
10. La reducción de la brecha obtenida en este trabajo podría estar por debajo del 3% que existe de brecha con el modelo propuesto. Se propone investigar en los modelos ARCH ya que consideran la volatilidad y así poder concentrarse en los valores que quedan fuera de las bandas de confiabilidad y encontrar un nuevo modelo en conjunto con el ARIMA con estacionalidad con el cual ya se implantó en la EPM; sin embargo, el análisis de otras herramientas, a partir de los resultados de esta investigación, podrían hacer que se encuentre un modelo más apropiado para los datos históricos con los cuales contamos.
11. En general la EPM se encuentra satisfecha con el modelo seleccionado, ya que al reducir considerablemente la desviación que existía entre lo pronosticado y lo que

se ejercía de forma real, se podrán utilizar dichos recursos excedentes en las actividades de exploración y extracción que ayudarán a mantener o ser la punta de lanza para incrementar la producción e implementar nueva tecnología que ayude a dicho propósito.

Por el momento, el proceso está implementado al área de Exploración y Producción; sin embargo, su utilización podría llevarse en toda la Empresa Petrolera Mexicana para realizar los pronósticos presupuestales y así tener una mejor asertividad en dicho proceso, pero seguramente es un trabajo que llevará tiempo ya que cada área tiene sus variables de entrada y salida, lo que exige la adaptación y análisis de la metodología para cada una de las áreas.

## Referencias bibliográficas

1. Damodar N. Gujarati., Dawn C. Porter. (2010). “Econometría quinta edición”. Editorial McGRAW-HILL
2. Madrigal, S. (2017). Modelos para pronosticar series estacionales con poca información histórica: un estudio comparativo. Ciencia UANL, 20(86). <http://cienciauanl.uanl.mx/?p=7386>
3. Corres, G., Passoni, I., Zárate, C. & Esteban, A. (2014). Estudio comparativo de modelos de pronóstico de ventas. Iberoamerican Journal of Industrial Engineering, Florianópolis, SC, Brasil. 6(11), 113-134. <http://stat.saudeetransformacao.incubadora.ufsc.br/index.php/IJIE/article/view/2659>
4. Hanke, J. and Wichern, D. (2006). “Pronósticos en los negocios”. Editorial Pearson. México. <https://pearsonha.vitalsource.com/#/books/9786074427004/>
5. Palma, W. (2016). Time series analysis. ProQuest Ebook Central <https://ebookcentral.proquest.com>
6. Render, B., Stair, R., Hanna, M. and Hale, T. (2016). “Métodos Cuantitativos para los negocios”. Editorial Pearson. México. <https://pearsonha.vitalsource.com/#/books/9786073237611/>
7. Gavilán, I. G. R. (2019). “La carrera digital”. Editorial ExLibric. Retrieved from <https://ebookcentral.proquest.com>
8. Martín, D. P. M. (2005). *Aplicaciones de las redes neuronales artificiales a problemas de predicción y clasificación financiera*. Retrieved from <https://ebookcentral.proquest.com>

9. Satish Kumar, K., and E. Venkata Rathnam. 2019. "Analysis and Prediction of Groundwater Level Trends Using Four Variations of Mann Kendall Tests and ARIMA Modelling." *Journal of the Geological Society of India* 94 (3): 281–89. <https://doi.org/10.1007/s12594-019-1308-4>.
10. Katimon, Ayob, Shamsuddin Shahid, and Morteza Mohsenipour. 2018. "Modeling Water Quality and Hydrological Variables Using ARIMA: A Case Study of Johor River, Malaysia." *Sustainable Water Resources Management* 4 (4): 991–98. <https://doi.org/10.1007/s40899-017-0202-8>.
11. Xu, Dong-wei, Yong-dong Wang, Li-min Jia, Yong Qin, and Hong-hui Dong. 2017. "Real-Time Road Traffic State Prediction Based On." *Frontiers of Information Technology & Electronic Engineering* 18 (2): 287–302.
12. Li, Guorui, and Ying Wang. 2013. "Automatic ARIMA Modeling-Based Data Aggregation Scheme in Wireless Sensor Networks." *Eurasip Journal on Wireless Communications and Networking* 2013 (1): 1–13. <https://doi.org/10.1186/1687-1499-2013-85>.
13. Gorlov, M. I., and A. V. Strogonov. 2007. "ARIMA Models Used to Predict the Time to Degradation Failure of TTL ICs." *Russian Microelectronics* 36 (4): 261–70. <https://doi.org/10.1134/S1063739707040063>.
14. Earnest, Arul, Mark I. Chen, Donald Ng, and Yee Sin Leo. 2005. "Using Autoregressive Integrated Moving Average (ARIMA) Models to Predict and Monitor the Number of Beds Occupied during a SARS Outbreak in a Tertiary Hospital in Singapore." *BMC Health Services Research* 5: 1–8. <https://doi.org/10.1186/1472-6963-5-36>.

15. Economist, The. 1992. "Vol.9, No.2, 1992" 9 (2): 185–205.
16. Wong, James M.W., Albert P.C. Chan, and Y. H. Chiang. 2007. "Forecasting Construction Manpower Demand: A Vector Error Correction Model." *Building and Environment* 42 (8): 3030–41. <https://doi.org/10.1016/j.buildenv.2006.07.024>.
17. Li, Jinchao, Shaowen Zhu, and Qianqian Wu. 2019. "Monthly Crude Oil Spot Price Forecasting Using Variational Mode Decomposition." *Energy Economics* 83: 240–53. <https://doi.org/10.1016/j.eneco.2019.07.009>.
18. Funk, Christoph. 2018. "Forecasting the Real Price of Oil - Time-Variation and Forecast Combination ." *Energy Economics* 76: 288–302. <https://doi.org/10.1016/j.eneco.2018.04.016>.
19. Wang, Yudong, Li Liu, and Chongfeng Wu. 2017. "Forecasting the Real Prices of Crude Oil Using Forecast Combinations over Time-Varying Parameter Models." *Energy Economics* 66: 337–48. <https://doi.org/10.1016/j.eneco.2017.07.007>.
20. Zhang, Yaojie, Feng Ma, and Yudong Wang. 2019. "Forecasting Crude Oil Prices with a Large Set of Predictors: Can LASSO Select Powerful Predictors?" *Journal of Empirical Finance*. <https://doi.org/10.1016/j.jempfin.2019.08.007>.
21. Zhang, Yaojie, Feng Ma, Benshan Shi, and Dengshi Huang. 2018. "Forecasting the Prices of Crude Oil: An Iterated Combination Approach." *Energy Economics* 70: 472–83. <https://doi.org/10.1016/j.eneco.2018.01.027>.
22. Sheremetov, L. (2013). Associative Model for the Forecasting of Time Series Based on the Gamma Classifier. 304–313.
23. Ramyar, S., & Kianfar, F. (2019). Forecasting Crude Oil Prices: A Comparison Between Artificial Neural Networks and Vector Autoregressive Models. *Computational Economics*, 53(2), 743–761. <https://doi.org/10.1007/s10614-017-9764-7>
24. Lee, T. H. (Ed.). (2010). *Agricultural economics : New research : new research*. ProQuest Ebook Central <https://ebookcentral.proquest.com>

**Anexos.**