

FACULTAD DE INGENIERÍA

Carrera de **INGENIERÍA DE SISTEMAS  
COMPUTACIONALES**

“IMPLEMENTACIÓN DE UNA SOLUCIÓN EN  
INTELIGENCIA DE NEGOCIOS PARA LA  
PREDICCIÓN EN LA GESTIÓN DE VENTA DE  
SEGUROS VEHICULARES DE UNA EMPRESA  
ASEGURADORA, 2020”

Tesis para optar el título profesional de:  
**Ingeniero de Sistemas Computacionales**

**Autores:**

Dayana Betzabel Chavarria Mendoza  
Ronald Alberto Leiva Alejos

**Asesor:**

Mg. Guido Trujillo Valdiviezo  
<https://orcid.org/0000-0002-3019-6599>

Lima - Perú

2023

**JURADO EVALUADOR**

Jurado 1 Presidente(a)	<b>Jorge Rosvin Narvaez Villacorta</b>	<b>41455569</b>
	Nombre y Apellidos	Nº DNI


Jurado 2	<b>Jorge Alfredo Bojórquez Segura</b>	<b>10318709</b>
	Nombre y Apellidos	Nº DNI

Jurado 3	<b>Eduardo Reyes Rodriguez</b>	<b>41212791</b>
	Nombre y Apellidos	Nº DNI

## INFORME DE SIMILITUD

### Tesis Final

#### INFORME DE ORIGINALIDAD



#### FUENTES PRIMARIAS

<b>1</b>	<b>repositorio.unp.edu.pe</b> Fuente de Internet	<b>9%</b>
<b>2</b>	<b>repositorio.ucv.edu.pe</b> Fuente de Internet	<b>2%</b>
<b>3</b>	<b>dspace.unitru.edu.pe</b> Fuente de Internet	<b>1%</b>
<b>4</b>	<b>Submitted to Universidad Privada del Norte</b> Trabajo del estudiante	<b>1%</b>
<b>5</b>	<b>repositorio.urp.edu.pe</b> Fuente de Internet	<b>1%</b>
<b>6</b>	<b>Submitted to Universidad Cesar Vallejo</b> Trabajo del estudiante	<b>1%</b>
<b>7</b>	<b>qdoc.tips</b> Fuente de Internet	<b>1%</b>
<b>8</b>	<b>hdl.handle.net</b> Fuente de Internet	<b>1%</b>
<b>9</b>	<b>repositorio.upn.edu.pe</b> Fuente de Internet	<b>&lt;1%</b>

## **DEDICATORIA**

Dedico esta tesis a mis padres y hermano por el constante apoyo y la ayuda que  
brindaron durante el trayecto de mi vida universitaria.

**Dayana Betzabel Chavarria Mendoza**

Dedico esta tesis a mis padres por su gran apoyo y por siempre haber estado ahí  
velando por nuestro bienestar y nuestra educación que siempre nos dieron durante toda  
nuestra carrera universitaria.

**Ronald Alberto Leiva Alejos**

## **AGRADECIMIENTO**

Agradezco a mis profesores que me enseñaron con dedicación, orientaciones que me dieron para mejorar y motivaciones para superarme constantemente.

**Dayana Betzabel Chavarria Mendoza**

Quiero agradecer a nuestros profesores de toda la carrera universitaria por sus enseñanzas y apoyo que han sido parte de nuestra formación académica todos estos años.

**Ronald Alberto Leiva Alejos**

## Tabla de contenido

<b>JURADO EVALUADOR.....</b>	<b>2</b>
<b>INFORME DE SIMILITUD.....</b>	<b>3</b>
<b>DEDICATORIA .....</b>	<b>4</b>
<b>AGRADECIMIENTO .....</b>	<b>5</b>
<b>Índice de tablas .....</b>	<b>7</b>
<b>Índice de figuras .....</b>	<b>8</b>
<b>RESUMEN .....</b>	<b>10</b>
<b>CAPÍTULO I: INTRODUCCIÓN.....</b>	<b>11</b>
<b>CAPÍTULO II: METODOLOGÍA .....</b>	<b>25</b>
<b>CAPÍTULO III: RESULTADOS.....</b>	<b>45</b>
<b>CAPÍTULO IV: DISCUSIÓN Y CONCLUSIONES .....</b>	<b>56</b>
<b>Referencias .....</b>	<b>60</b>
<b>Anexos .....</b>	<b>65</b>

## Índice de tablas

<b>Tabla 1 Lista de requerimientos .....</b>	<b>33</b>
<b>Tabla 2 Cronograma.....</b>	<b>33</b>
<b>Tabla 3 Prueba de normalidad de la exactitud de la predicción de las ventas de seguros vehiculares.....</b>	<b>49</b>
<b>Tabla 4 Prueba de Wilcoxon de la exactitud de la predicción.....</b>	<b>50</b>
<b>Tabla 5 Prueba de normalidad de la eficacia de la predicción de las ventas de seguros vehiculares.....</b>	<b>52</b>
<b>Tabla 6 Prueba de Wilcoxon de la eficiencia de la predicción .....</b>	<b>53</b>
<b>Tabla 7 Prueba de normalidad del crecimiento de las ventas de las ventas de seguros vehiculares.....</b>	<b>54</b>
<b>Tabla 8 Prueba de Wilcoxon del crecimiento de las ventas .....</b>	<b>55</b>
<b>Tabla 9 Matriz de operacionalización de la variable .....</b>	<b>65</b>

## Índice de figuras

<b>Figura 1 Ciclo de vida Ralph Kimball .....</b>	<b>22</b>
<b>Figura 2 Proceso de diseño del experimento.....</b>	<b>27</b>
<b>Figura 3 Diagrama de recolección de datos.....</b>	<b>34</b>
<b>Figura 4 Modelo lógico de la inteligencia de negocios.....</b>	<b>34</b>
<b>Figura 5 Modelo de base de datos en Power BI.....</b>	<b>35</b>
<b>Figura 6 Crear proyecto Python en anaconda.....</b>	<b>35</b>
<b>Figura 7 Conexión que usaremos en el Power BI.....</b>	<b>35</b>
<b>Figura 8 Conda activate pbi.....</b>	<b>36</b>
<b>Figura 9 Instalamos Matplotlib.....</b>	<b>36</b>
<b>Figura 10 Instalamos Pandas.....</b>	<b>37</b>
<b>Figura 11 Conectar Power BI con ambiente creado .....</b>	<b>37</b>
<b>Figura 12 Tabla calendario .....</b>	<b>38</b>
<b>Figura 13 Período .....</b>	<b>38</b>
<b>Figura 14 Pronóstico promedio móvil simple monto .....</b>	<b>38</b>
<b>Figura 15 Pronóstico promedio móvil simple cantidad .....</b>	<b>39</b>
<b>Figura 16 Pronóstico anual de la cantidad de seguros vehiculares.....</b>	<b>39</b>
<b>Figura 17 Pronóstico del precio de venta promedio de seguros vehiculares .....</b>	<b>40</b>
<b>Figura 18 Pre test Exactitud .....</b>	<b>41</b>
<b>Figura 19 Post test Exactitud .....</b>	<b>41</b>
<b>Figura 20 Pre test Eficacia.....</b>	<b>42</b>
<b>Figura 21 Post test Eficacia.....</b>	<b>42</b>
<b>Figura 22 Pre test Crecimiento de ventas.....</b>	<b>43</b>
<b>Figura 23 Post test Crecimiento de ventas.....</b>	<b>43</b>
<b>Figura 24 Análisis descriptivo del pretest de la exactitud de la predicción (2017-2020)</b> .....	<b>45</b>
<b>Figura 25 Análisis descriptivo del postest de la exactitud de la predicción (2021-2022)</b> .....	<b>46</b>



<b>Figura 26</b>	<b>Análisis descriptivo del pretest de la eficacia del pronóstico (2017-2020)</b>	<b>47</b>
<b>Figura 27</b>	<b>Análisis descriptivo del postest de la eficacia del pronóstico (2021-2022)</b>	<b>47</b>
<b>Figura 28</b>	<b>Análisis descriptivo del pretest del crecimiento de ventas (2017-2020) ....</b>	<b>48</b>
<b>Figura 29</b>	<b>Análisis descriptivo del postest del crecimiento de ventas (2021-2022) ...</b>	<b>48</b>
<b>Figura 30</b>	<b>Espina de Ishikawa.....</b>	<b>65</b>
<b>Figura 31</b>	<b>Pre test promedio de monto (2017-2020).....</b>	<b>66</b>
<b>Figura 32</b>	<b>Post test promedio de monto (2021-2022).....</b>	<b>66</b>
<b>Figura 33</b>	<b>Pre test promedio de cantidad (2017-2020).....</b>	<b>66</b>
<b>Figura 34</b>	<b>Post test promedio de cantidad (2021-2022).....</b>	<b>66</b>

## RESUMEN

El presente trabajo detalla el desarrollo de la implementación de una solución en inteligencia de negocios para la predicción en la gestión de venta de seguros vehiculares de una empresa aseguradora. El objetivo de esta es determinar cómo influye la implementación de una solución en inteligencia de negocios para la predicción en la gestión de ventas de seguros vehiculares.

La investigación realizada en este caso fue de tipo aplicada, con un enfoque cuantitativo y un diseño pre-experimental. La población estuvo constituida por el registro de ventas mensuales realizadas entre los años 2017 y 2022. Se empleó el análisis documental como método de recopilación de información, mientras que se utilizó una ficha de registro como herramienta para llevar a cabo dicha recolección de datos.

En esta implementación no hubo cambios significativos en la exactitud. En la eficacia se concluye que, en promedio, los valores mejoraron después de la implementación, lo que implica que sí influyó en la eficacia. Finalmente, para el crecimiento de las ventas no influyó.

**PALABRAS CLAVES:** Inteligencia de negocios, pronóstico, Power BI, Business Intelligence , ventas de seguros.

## CAPÍTULO I: INTRODUCCIÓN

### 1.1. Realidad problemática

En la actualidad, resulta crucial que las empresas sobresalgan por encima de sus competidores mediante la toma de decisiones empresariales más eficaces y ágiles en comparación con otras compañías (Prieto Morales, Meneses Villegas, & Vega Zepeda, 2015). En los tiempos competitivos actuales, es necesario buscar formas y soluciones para facilitar y simplificar el trabajo. En otras palabras, es importante encontrar soluciones efectivas para el proceso de gestión. Eso significa encontrar soluciones automatizadas que ahorren tiempo, sean productos más relevantes y reduzcan costos (Mesaros, y otros, 2016).

La gestión y administración de información es muy importante, ya que los datos pueden generar conocimiento valioso cuando se analizan adecuadamente. Por lo tanto, es crucial asegurarse de que la información esté limpia desde el principio, durante su procesamiento y carga, y que sean datos reales y confiables para obtener resultados precisos y útiles (Escobar Guanochanga, 2019). Para hacer pronósticos de ventas estables, es necesario contar con intuición, conocimiento y acceso a la información disponible. Estos son requisitos fundamentales para minimizar las variaciones en los pronósticos de ventas (Moreno Castro, 2019). Si la solución de BI implementada se usa de manera correcta y efectiva, entonces la compañía no solo puede hacer un mejor uso de las oportunidades de mercado, sino también identificar posibles informes operativos a tiempo, lo que le otorga fortaleza competitiva y un funcionamiento efectivo (Mesaros, y otros, 2016). Tener la información correcta en el momento oportuno es importante, porque la falta de acceso a la información adecuada puede resultar en la pérdida de oportunidades de negocios valiosas. (Salinas La Rosa, 2010)

Las empresas de seguros generan grandes cantidades de información, la mayor parte de esta información no aporta en las predicciones ni la toma de decisiones, con lo que es necesario transformar la información en conocimientos. Hay muchos peruanos que creen erróneamente que buscar y encontrar un seguro para su vehículo es una tarea difícil. Para abordar esta situación, se han desarrollado herramientas como los cotizadores de seguros vehiculares, que permiten a las personas descubrir de manera fácil y sencilla una cobertura adecuada a sus necesidades y contratarla.

Durante la década actual, se ha producido un aumento en las ventas de seguros para vehículos debido al incremento en la venta de automóviles nuevos. Sin embargo, lo que ha destacado en este mercado en los últimos años es la llegada de pólizas que ofrecen precios por debajo del promedio (EC, 2017).

En el contexto local, la empresa aseguradora que fue materia del estudio, comenzó sus operaciones en el año 1981 con un pequeño grupo de trabajadores. En 1994, tuvieron su primer local propio en Lima. La aseguradora actualmente cuenta con convenios de planes con Rimac Seguros, Seguro Mapfre Perú, La Positiva Seguros, Pacifico Seguros, HDI Seguros y Caja Sullana.

Cabe mencionar que existen factores que están afectando las ventas de los seguros vehiculares en la empresa, entre ellos tenemos una inadecuada atención al cliente, ya que las llamadas realizadas por los clientes, en su mayoría de veces, son atendidas por un robot de llamadas. También se tiene a las cotizaciones que son elevadas en comparación con los competidores, la oferta de los seguros vehiculares que la empresa brinda es muy limitada, lo cual no cubre las expectativas de su segmento de mercado, una plataforma de cotización

poco intuitiva y, finalmente, la empresa desconoce las necesidades de los clientes (ver Anexo 1).

Teniendo en cuenta lo anterior, para mejorar la predicción en la gestión de venta de seguros vehiculares de la empresa aseguradora se debe implementar una inteligencia de negocios y de esa manera, se logrará tomar mejores decisiones financieras.

Las empresas aseguradoras están apostando por la implementación de una inteligencia de negocios, ya que ayudará en las predicciones, en la toma de decisiones y a obtener mejores resultados en las ventas de seguros vehiculares. En ese sentido, la aplicación permitirá tener un mejor control de las cotizaciones para los ejecutivos de ventas, dado que se minimizará el uso de recursos como el tiempo del proceso y con ello serán más eficientes en la generación de las cotizaciones.

El presente trabajo de tesis pretende aportar a las empresas aseguradoras en la implementación de inteligencia de negocios para la predicción en la gestión de ventas de seguros vehiculares y apoyo en la toma de decisiones.

### **1.1.1. Antecedentes internacionales**

Quimbia Loyo (2017) El estudio llevado a cabo se basó en enfoques cuantitativos, y su finalidad principal fue la implementación de una solución de Inteligencia de Negocios para el manejo de Indicadores claves de desempeño en ventas en las farmacias de la empresa Farmaenlace. Se utilizaron metodologías como KPI, BI Agile y QPM, y su técnica fue un grupo focal y entrevistas. La implementación se hizo con la herramienta Qlikview y se desarrollaron fases como especificaciones funcionales, diseño de arquitectura de datos, validación y pruebas, optimización, Revisión de documentación, implementación en producción y transferencia de conocimiento. Los resultados mostraron que esta

implementación de BI mejoró la toma de decisiones comerciales, y el autor recomendó mejorar la calidad de datos y establecer indicadores en cada farmacia. La tesis remarca la importancia de tener en cuenta el proceso actual, la productividad, el modelado de Inteligencia de Negocios, los indicadores y las herramientas antes de la implementación.

Parra Coba (2016) elaboró un estudio para crear una aplicación móvil en Android para la empresa Megakons que tuvo como objetivo mejorar los procesos de ventas y brindar un pedido sugerido basado en análisis de datos históricos de compras. El autor enfrentó el problema de la falta de aplicaciones móviles basadas en inteligencia de negocios y utilizó la metodología Kimball que fue creada para la minería de datos y Mobile-D para desarrollar la aplicación. La población fueron los clientes y los resultados fueron positivos con una mejora del 55% en los tiempos de ejecución de toma de pedidos y el porcentaje de aceptación del pedido que fue sugerido por el cliente fue del 42.08%. La aplicación es beneficiosa para los vendedores y brinda una interfaz sugerida para tomar mejores decisiones en la toma de pedidos. La recomendación final es tener un conocimiento adecuado en desarrollo de aplicaciones móviles y elegir una metodología acorde para lograr un desarrollo exitoso. Sobre la tesis mencionada, se puede destacar el desarrollo de una aplicación para predecir las compras de los clientes con base a su historial, beneficiando a los vendedores y anticipándose al pedido del cliente. Además, disminuyendo el tiempo para la toma de decisiones.

### **1.1.2. Antecedentes nacionales**

Vargas Pinto (2018) realizó un estudio para el crecimiento de ventas y el nivel de eficacia, que tuvo como objetivo establecer la influencia del Business Intelligence en la predicción de ventas en la empresa Zona Cel S.A.C. La investigación fue aplicada, con un

diseño preexperimental y enfoque cuantitativo, y utilizó la metodología HEFESTO. La técnica usada fue el registro y la población estuvo conformada por 11,503 ventas, con una muestra de 381 documentos estratificados. Los resultados mostraron un aumento del 11% en la eficacia y un 15.56% en el crecimiento de las ventas, y el autor concluyó que el uso de Business Intelligence aumenta la predicción de ventas. Se recomendó seguir mejorando la investigación e implementar Business Intelligence en los procesos para mejorar los resultados. De la tesis presentada se puede destacar el análisis y pruebas del pronóstico que se usó para hallar la eficacia y el crecimiento en las ventas haciendo uso de fórmulas estadísticas y la interpretación de los resultados obtenidos.

Encalada Sarmiento & Sánchez Crisóstomo (2019) elaboraron en la empresa Indurama una mejorará en el proceso de toma de decisiones para las ventas con la implementación de BI. Para eso los autores aplicaron una investigación aplicada y explicativa, implementaron la metodología Ralph Kimball y se centró en 30 flujos de procesos de toma de decisiones en el área de ventas. Se usaron las técnicas de entrevista y encuesta, con los instrumentos de ficha de observación y cuestionario. Los resultados mostraron que el uso de la inteligencia de negocios redujo significativamente el tiempo que se empleado en la carga de datos, elaboración de reportes y análisis de información. El autor recomienda capacitar y entrenar constantemente al personal en el uso de la herramienta y seguir mejorando su uso en otras áreas de la empresa. Los resultados fueron una reducción de tiempos de un 89% en procesar data, 85% generado de reporte y 86% en análisis de información. De la tesis presentada, se puede destacar el correcto análisis del negocio y el conocimiento de la situación para mejorar las necesidades más importantes de la empresa

que son la reducción en el proceso de carga, elaboración de reportes y análisis de la información. Además de la capacitación del personal en el uso de la herramienta.

Carhuallanqui Bastidas (2017) buscó diseñar una solución de inteligencia de negocios para el área de ventas de la empresa Dispefarma. La problemática era la falta de integración y análisis de la información. Para llevar a cabo la investigación se aplicó la metodología de Ralph Kimball, la cual implicó la recopilación de datos a través de encuestas, entrevistas y observación. Los resultados obtenidos demostraron una disminución significativa del 90.13% en el tiempo necesario para generar informes, así como también la identificación de los mejores clientes y los más leales. El autor de la tesis llegó a la conclusión de que la inteligencia de negocios resulta muy útil en la toma de decisiones en el área de ventas de Dispefarma. En resumen, se puede destacar la importancia de la inteligencia de negocios en las empresas, así como también la eficacia de la metodología de Ralph Kimball se emplea con el propósito de mejorar la toma de decisiones en el área de ventas.

Heredia Salinas (2018) tuvo como objetivo de estudio implementar una aplicación de inteligencia de negocios que se utilizó en la gestión de ventas de Procesados Amazónicos, involucrando a 6 personas de la gerencia y asistentes. La investigación realizada fue de tipo preexperimental y los resultados demostraron que la aplicación de la inteligencia de negocios permitió mejorar la toma de decisiones en el área de ventas, proporcionando información consolidada, actualizada y resumida. Además, se determinó que la implementación de esta herramienta mejoró la gestión de ventas con un nivel de confianza del 95%, gracias al efecto positivo de la aplicación. Los resultados de los 4 indicadores fueron 5.667 con una significancia de 0.042 en el nivel de consolidación, 7 con una significancia de 0.017 en el



nivel de tiempo de procesamiento, 15 con una significancia de 0.023 en el nivel de toma de decisiones y 8 con una significancia de 0.044 en la disponibilidad de información. La conclusión del autor fue que la inteligencia de negocios es una herramienta clave para mejorar las ventas y mantener una ventaja en la competencia. La tesis presentada es un ejemplo de que las empresas siempre tienen que estar mejorando, ya que se pueden perder clientes por la competencia. La inteligencia de negocios puede planear propuestas y ofrecer opciones de compra, mejorando las ventas.

Li Loo (2019) tuvo como objetivo principal analizar el impacto de la Inteligencia de Negocios en la predicción de ventas en el Centro Nacional de Servicios de Lima. Para ello, se llevó a cabo una investigación de tipo cuantitativo, con enfoque aplicado, nivel explicativo y diseño experimental. Para evaluar la afinidad del pronóstico se empleó la metodología de Jiro Kawakita. La población estudiada fue de 32 vendedores y se realizó una encuesta con un cuestionario. Los resultados fueron óptimos debido a que paso un nivel de 87.5% en la evaluación previa de 0.0% en la posterior, a un nivel de 0.0% en la evaluación previa y 75.0% en la evaluación posterior con un valor significativo de  $p < 0.05$ . El autor demostró un cambio positivo en la percepción de los vendedores sobre el pronóstico de ventas. Finalmente, se sugiere la implementación de soluciones de Inteligencia de Negocios en empresas similares, y tener en cuenta los indicadores relacionados con el conocimiento y diseño del pronóstico de ventas. En la tesis citada se evidencia un impacto positivo y relevante en la predicción de ventas de la compañía. Considerando los indicadores conocimiento y diseño del pronóstico de ventas. Además, en las conclusiones muestran el gran cambio que hubo en el pretest y post test.

### **1.1.3. Bases teóricas**

### **1.1.3.1. Inteligencia de negocios (Business intelligence)**

La Inteligencia de Negocios (BI) es un procedimiento interactivo que permite explorar y analizar información organizada de un determinado campo, con el objetivo de identificar patrones o tendencias que permitan obtener ideas y conclusiones relevantes (Guadaña Julón, 2019). Los sistemas informáticos guardan una gran cantidad de datos históricos sobre actividades registradas. La Inteligencia de Negocios aprovecha estos datos almacenados, los recopila, transforma, limpia y utiliza técnicas analíticas para obtener información valiosa de ellos. (Intriago & Castro, 2016)

La introducción de un sistema de Business Intelligence en una organización puede resultar muy ventajosa para la toma de decisiones en el departamento de ventas, dado que proporciona acceso a información relevante en tiempo real y desde cualquier lugar o momento (Escobar Guanochanga, 2019). Específicamente, se encontró que el uso de la inteligencia de negocios tiene un impacto significativo en la mejora del desempeño general y la competitividad de las empresas. (Mesaros, y otros, 2016)

Según (Salinas La Rosa, 2010) hay cinco estilos de inteligencia de negocios:

- Paneles de control y tablas de información:

Estas herramientas de seguimiento son creadas para satisfacer las necesidades de los usuarios que desean una visión completa de los indicadores contables, operativos y de rendimiento con el propósito de hacer seguimiento. Por medio de gráficos, diagramas e indicadores visuales, estos mecanismos permiten hacer seguimiento a las métricas de desempeño y comunicar al personal acerca de las tendencias y posibles decisiones que se deban tomar.

- Reporting Empresarial

Proporciona una amplia gama de informes operativos y empresariales, obtenidos de diversos sistemas de la empresa, como el ERP, CRM, PRM y facturación, entre otros, los cuales están disponibles para todos los niveles de la organización.

- Análisis avanzado y predictivo

Esta herramienta habilita a los usuarios para investigar el rendimiento del negocio a través del uso de análisis estadísticos avanzados y minería de datos, con el fin de tomar decisiones proactivas y mejorar la capacidad de respuesta ante posibles amenazas. El análisis predictivo puede incluir pruebas de hipótesis, pronósticos de incidentes, predicciones de oferta y demanda, y clasificación de clientes, con el objetivo de anticipar situaciones y sus resultados.

- Análisis de cubos - OLAP OLAP

Con esta herramienta, los usuarios tienen la capacidad de vincular conjuntos de datos y crear cubos que contienen información interrelacionada de manera interactiva y en tiempo real. Un ejemplo de su aplicación sería en el departamento de marketing, donde se podría obtener información de ventas de un producto en una región y período de tiempo determinados. Los cubos son útiles para que los usuarios puedan analizar la información de manera más eficiente, al permitirles segmentar y filtrar la información de diferentes maneras para obtener diferentes perspectivas.

- Notificaciones y alertas

Estas herramientas se emplean para compartir información de manera anticipada en diversos puntos de contacto con los usuarios. Brindan información objetiva y oportuna a los

responsables de la toma de decisiones para identificar áreas críticas que requieren atención. Este método de entrega de Inteligencia de Negocios de vanguardia garantiza que la organización se mantenga actualizada y alineada con los riesgos y oportunidades del negocio, incluso cuando los eventos son recientes, lo que posibilita la toma de decisiones oportunas.

### **1.1.3.2. Predicciones**

La predicción implica un análisis lógico y sistemático de las causas y efectos que generan y producen un sistema, objeto o fenómeno, lo que permite determinar su estado futuro (Cantoral, Molina, & Sánchez, 2014).

La predicción y la variación están íntimamente relacionadas, ya que para prever el estado futuro de un sistema es necesario medir y examinar los cambios en sus causas y efectos, y utilizarlos para crear modelos matemáticos que nos permitan anticipar las consecuencias. Por lo tanto, la variación se vuelve una herramienta de análisis esencial para hacer pronósticos (Cantoral, Molina, & Sánchez, 2014).

Moreno Castro (2019) dice que la necesidad de ofrecer una amplia gama de productos ha aumentado, lo que ha llevado a los productores a implementar planes y programas de producción más precisos y flexibles. La meta consiste en optimizar el uso de los recursos físicos y humanos, asegurando el cumplimiento de los plazos de entrega y reduciendo los gastos. Para lograrlo, es necesario hacer una estimación de las ventas futuras, y para ello se utilizan fuentes de datos como la información de ventas históricas.

### **1.1.3.3. Toma de decisiones**

Las empresas han adoptado la inteligencia de negocio para mejorar su toma de decisiones basándose en datos. A medida que estas prácticas analíticas se han vuelto más comunes, las empresas se han interesado en aprovechar de manera efectiva la información del cliente y han desarrollado iniciativas para recopilar más datos, como programas de fidelización (Conesa Caralt, Bartrolí Muñoz, Braulio Gil, Curto Díaz, & Puigvert Pell, 2015).

Como BI es el mejor conductor de la toma de decisiones, repetir la toma de decisiones requiere la repetición de la aplicación de BI. Por lo tanto, la reforma o la nueva innovación de BI se vuelve imprescindible para repetir la decisión de realizar los cambios que ocurren (Shaheb, Shah J., & Shahadat, 2017).

#### **1.1.3.4. Modelos de predicción**

##### **Promedio móvil simple**

El enfoque de promedios móviles implica calcular el promedio de los valores más recientes de una serie temporal y utilizarlo como una estimación del valor para el siguiente periodo. El adjetivo "móvil" se refiere a que a medida que se disponen de nuevas observaciones, estas reemplazan a las más antiguas en el cálculo del promedio, lo que da lugar a un promedio que cambia o se desplaza con el tiempo (Villarreal, 2016).

Para suavizar los datos históricos, se utiliza el método de promediar los valores de los últimos periodos y luego proyectar el último valor promedio hacia el futuro. Este método es especialmente útil para datos que presentan mucha variabilidad sin mostrar una tendencia clara ni patrones estacionales. Como resultado, se obtiene una previsión plana y sin curvas (Promedio móvil simple (SMA), s.f.).

$$\frac{P_1 + P_2 + P_3 + \dots + P_n}{n}$$

$P$  = Promedio en período

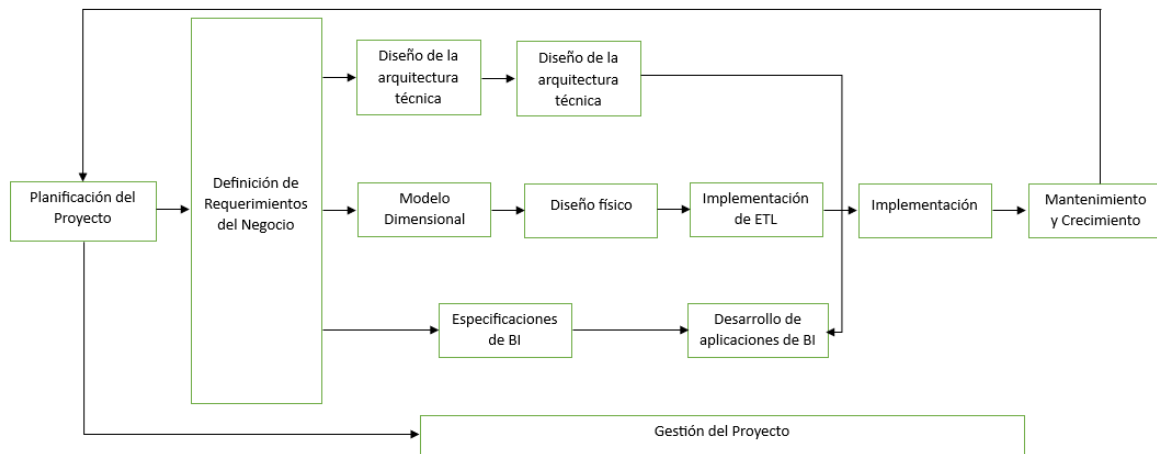
$n$  = Cantidad de períodos

### 1.1.3.5. Metodología Ralph Kimball

El enfoque de Kimball es una metodología utilizada en las empresas para construir modelos analíticos que apoyen los objetivos estratégicos. Es importante comprender cómo estos conceptos pueden ser aplicados en las misiones de la organización y cómo su correcta utilización puede garantizar la calidad de la información necesaria para la toma de decisiones estratégicas. La correcta aplicación de la metodología puede contribuir significativamente al logro de los objetivos estratégicos (Forero Castañeda & Sánchez Garcia, 2021).

**Figura 1**

*Ciclo de vida Ralph Kimball*



## 1.2. Formulación del problema

### 1.2.1. Pregunta general

¿Cómo influye la implementación de una solución en inteligencia de negocios en la predicción en la gestión de venta de seguros vehiculares en una empresa aseguradora?

### **1.2.2. Preguntas específicas**

¿Cómo influye la implementación de una solución en inteligencia de negocios en la exactitud de la predicción de venta de seguros vehiculares?

¿Cómo influye la implementación de una solución en inteligencia de negocios en la eficacia de la predicción de venta de seguros vehiculares?

¿Cómo influye la implementación de una solución en inteligencia de negocios en el crecimiento de ventas en la predicción de seguros vehiculares?

## **1.3. Objetivos**

### **1.3.1. Objetivo general**

Determinar cómo influye la implementación de una solución en inteligencia de negocios para la predicción en la gestión de ventas de seguros vehiculares.

### **1.3.2. Objetivos específicos**

Determinar cómo influye la implementación de una solución en inteligencia de negocios en la exactitud de la predicción de venta de seguros vehiculares.

Determinar cómo influye la implementación de una solución en inteligencia de negocios en la eficacia de la predicción de venta de seguros vehiculares.

Determinar cómo influye la implementación de una solución en inteligencia de negocios en el crecimiento de ventas en la predicción de seguros vehiculares.

## **1.4. Hipótesis**

#### **1.4.1. Hipótesis general**

La implementación de una solución en inteligencia de negocios influye en la predicción de la gestión de ventas de seguros vehiculares.

#### **1.4.2. Hipótesis específicas**

La implementación de una solución en inteligencia de negocios influye en la exactitud de la predicción de las ventas de seguros vehiculares.

La implementación de una solución en inteligencia de negocios influye en la eficacia de la predicción de las ventas de seguros vehiculares.

La implementación de una solución en inteligencia de negocios influye en el crecimiento de las ventas en la predicción de seguros vehiculares.



## **CAPÍTULO II: METODOLOGÍA**

### **2.1. Tipo de investigación**

#### **2.1.1. Tipo de investigación**

La investigación aplicada está estrechamente vinculada a la investigación básica, debido a que su éxito depende de los avances y logros de esta última. Esto es claro si tenemos en cuenta que toda investigación aplicada requiere una base teórica sólida (Supo Condori & Cavero Aybar, 2014).

La investigación fue de tipo aplicada, porque existe problemas que están afectado las ventas de las cotizaciones de los seguros vehiculares, y se plantea una solución a ello, mediante la inteligencia de negocios.

#### **2.1.2 Enfoque de investigación**

Según Supo Condori & Cavero Aybar (2014) la investigación cuantitativa implica la recolección y análisis de datos numéricos sobre variables. Su objetivo principal es determinar la correlación o asociación entre variables, así como generalizar y objetivar los resultados utilizando una muestra para inferir conclusiones sobre la población de donde se obtuvo dicha muestra.

La investigación fue de enfoque cuantitativa, puesto que, la predicción de ventas es una variable en que se medirá a través de instrumentos de recolección de datos, lo cual nos llevará a analizar datos numéricos mediante la estadística.

#### **2.1.3 Nivel de investigación**

Según Supo Condori & Cavero Aybar (2014) la investigación explicativa se basa en la combinación de varios métodos, como el analítico, sintético, deductivo e inductivo, con el objetivo de explicar las razones detrás del objeto de estudio. Esta investigación se enfoca en demostrar las relaciones causales entre variables.

La investigación fue de nivel explicativa, puesto que, se logra encontrar una relación entre la variable de inteligencias de negocios (independiente) y predicción de ventas (dependiente).

#### **2.1.4. Diseño de investigación**

Según Cuadros Del Carpio (2022), el método experimental se divide en tres tipos: experimento puro, cuasi experimental y preexperimental. La investigación preexperimental implica la realización de una prueba antes y después del experimento en un solo grupo sin presencia del grupo de control.

Para el desarrollo del trabajo se empleará una investigación preexperimental. En primer lugar, se analizaron los datos y se evaluó la situación. Luego, se desarrolló y se tomaron en cuenta los objetivos del negocio. Finalmente, se verificó si el sistema implementado logró predecir con exactitud las ventas de seguros vehiculares, si la rentabilidad aumentó y si se mejoró la toma de decisiones.

**Figura 2**

*Proceso de diseño del experimento*



### **2.1.5. Población:**

Según Tamayo (2004), se define como población al conjunto completo de unidades de análisis que conforman un fenómeno objeto de estudio, y que deben ser medidas o cuantificadas en un estudio específico. La población se representa por la letra N y se compone de un grupo de entidades que comparten ciertas características. La población es esencial en la investigación ya que representa el total de la variable que se está estudiando y es fundamental para determinar las muestras necesarias y obtener conclusiones significativas a partir de los resultados.

El universo poblacional estuvo conformado por la cantidad de ventas de seguros vehiculares realizadas desde enero del 2017 hasta diciembre del 2022.

### **2.1.6. Muestra:**

Existen diversas razones por las que la muestra resulta relevante. Una de las cuestiones más evidentes al trabajar con muestras es la posibilidad de utilizar los valores obtenidos para inferir los valores que se presentarían en una población determinada (Argibay, 2009).

La investigación no ha utilizado muestra ni muestreo, dado que se está trabajando con toda la población de estudio.

## 2.2. Materiales, instrumentos y métodos

### 2.2.1. Materiales

Los materiales que se utilizó para desarrollar el presente trabajo son las siguientes:

Computadoras/Laptop:

Las computadoras Macintosh de Apple y las PC compatibles con IBM son las dos plataformas más utilizadas para producir y distribuir proyectos de multimedia. Estas computadoras son las más comunes para el desarrollo y presentación de materiales multimedia en la actualidad (Fournier García, Rouquette Alvarado, & Ariza Gómez, 2019).

Power BI

Accede a los datos y representa gráficamente a través de una plataforma escalable y unificada para la inteligencia empresarial (BI) de autoservicio y empresarial, la cual es sencilla de utilizar y permite obtener información valiosa a partir de los datos (Microsoft, s.f.).

Python

Según Van Rossum (2008), Python es un lenguaje de programación potente y sencillo de aprender, que ofrece estructuras de datos de alto nivel y eficientes, así como un enfoque simple pero efectivo en la programación orientada a objetos. Gracias a su sintaxis elegante y a su tipado dinámico, junto con su interpretación, Python es un lenguaje muy adecuado para la elaboración de scripts y para el desarrollo rápido de aplicaciones en diversas áreas y plataformas.

Ejecución de scripts de Python en Power BI Desktop

Es posible ejecutar scripts escritos en Python directamente en Power BI Desktop, y luego importar los datos obtenidos como resultado en un modelo de datos en esta herramienta. A partir de este modelo, se pueden crear informes y compartirlos mediante el servicio Power BI (Microsoft, 2023).

 Matplotlib

Se trata de una interfaz para Matplotlib que opera en base a estados. Su función es permitir la representación gráfica de manera implícita, similar a lo que se realiza en MATLAB. Además, esta interfaz abre figuras en la pantalla y cumple con la función de administrador de la interfaz gráfica de usuario para las figuras (Matplotlib 3.5.3 documentation, s.f.).

 Pandas

El objetivo principal de Pandas es ser el componente esencial para llevar a cabo análisis de datos prácticos de alta calidad en Python. Asimismo, su intención es convertirse en la herramienta de código abierto más versátil y potente para la manipulación y el análisis de datos, superando a cualquier otro programa de este tipo en cualquier lenguaje de programación (pandas Python Data Analysis Library, s.f.).

 SQL Server

Es un sistema de gestión de datos gratis, confiable y potente que provee un depósito de datos confiable y rico en contenido para aplicaciones de escritorio y sitios web livianos. (Microsoft, s.f.)

 Power Query

Según Microsoft (2022), Power Query es una herramienta que se emplea para la preparación y transformación de datos, la cual tiene una interfaz gráfica que permite obtener datos de diversas fuentes, además de un editor que se utiliza para aplicar transformaciones a los mismos. Este motor está presente en diversos productos y servicios, y el lugar donde se almacenan los datos dependerá del uso que se le dé a Power Query. Con esta herramienta, podemos aplicar ETL.

#### Power Pivot

Power Pivot y Excel son herramientas útiles para dar forma y modelar los datos que se han importado. Ambos se utilizan para explorar y visualizar datos mediante tablas dinámicas, gráficos dinámicos y Power BI (Microsoft, 2022).

### **2.2.2. Técnica**

El análisis documental está ganando cada vez más importancia debido al gran volumen de información al que se enfrenta en la actualidad. El volumen actual de información es considerablemente mayor que el de décadas pasadas, en gran medida debido al uso extenso de TIC, que han posibilitado la creación de redes para el intercambio de información. Estas tecnologías han revolucionado las capacidades de servicios de información y procesamiento en las unidades (Peña Vera & Pirela Morillo, 2007).

Observación directa cuando la persona que está recopilando información a través de este método lo hace poniéndose en contacto directo con el hecho en cuestión y la observación indirecta cuando esa persona se pone en contacto con el hecho a través de observaciones de otras personas (Salinas López, 2015).

### **2.2.3. Instrumentos**

## Ficha de registros

Según Costa, la ficha de registro es una propuesta que constituye la base del inicio de un proceso metodológico sistematizado en el estudio del arte rupestre. La ficha cumple dos funciones: la de unificar los datos y ser, a su vez, un proceso ordenado y planificado del trabajo de campo (Costa, 2007).

La ficha de registro medirá el error, la eficacia y la cantidad de ventas vehiculares, con las siguientes fórmulas:

Para el error absoluto

$$\frac{\sum |ventas reales - ventas pronosticadas|}{ventas reales} \times 100$$

Exactitud del pronóstico

$$100\% - Error\ Absoluto\%$$

Para la eficacia

$$\frac{ventas reales}{ventas pronosticadas} \times 100$$

Cantidad de ventas

$$\left( \left( \frac{ventas realizadas}{ventas anteriores} \right) - 1 \right) \times 100$$

La investigación no utiliza validez ni confiabilidad de los instrumentos, puesto que estos son registros en los cuales se llena información recopilada de la base de datos, y son utilizados para la predicción mediante la inteligencia de negocios.

### 2.2.4. Proceso de análisis de datos

El análisis de datos para las ventas de seguros vehiculares fue realizado en Excel y se utilizó Python para mostrar los resultados del pretest y postest de las tres variables (exactitud, eficacia y crecimiento de ventas) en la cual se utilizó la librería Matplotlib para crear las gráficas. Las gráficas que se utilizaron fueron las gráficas de dispersión. Para el análisis inferencial, es decir para probar las hipótesis de la investigación se utilizó el software estadístico SPSS.

### **2.3. Procedimiento de recolección de datos**

Para la implementación de Business Intelligence (BI), utilizaremos la metodología de Ralph Kimball, ampliamente reconocida en la industria. La información necesaria para el análisis se recopiló de las cotizaciones realizadas en la plataforma de cotizador web, así como por otras vías de ventas como llamadas o correos, y posteriormente se almacenó en una base de datos SQL Server (ver Anexo 3). Luego, a través de Power BI, se conectó a la base de datos, se exportaron las tablas necesarias y se modelaron para mostrar la información en los gráficos utilizando código DAX. Para el análisis del pretest y postest, se exportaron los datos a Power BI y se utilizó la herramienta Anaconda para crear un proyecto en Python, donde se instaló la librería Matplotlib y Pandas para la manipulación de datos y gráficos dinámicos. Posteriormente, se utilizó un script de Python para mostrar las gráficas de dispersión con relación a nuestro pronóstico, utilizando las tres variables de exactitud, eficacia y crecimiento de ventas.



**Tabla 1**

*Lista de requerimientos*

N	Requerimientos
1	Se requiere visualizar las predicciones de ventas de seguros
2	Se requiere visualizar las predicciones de monto de las ventas de seguros vehiculares
3	Se requiere visualizar las predicciones de ventas promedio con relación al crecimiento de ventas
4	Se requiere visualizar las predicciones de monto promedio de las ventas con relación a la eficacia
5	Se requiere visualizar las predicciones de monto promedio de las ventas con relación a la exactitud

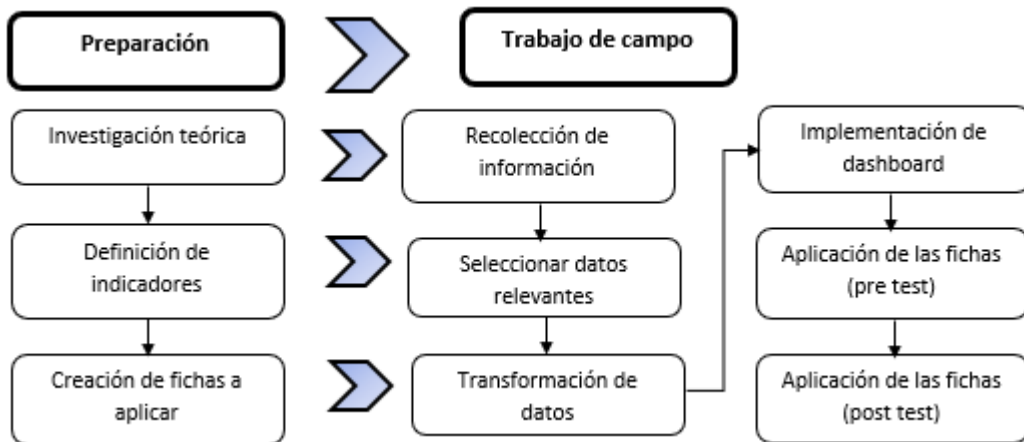
**Tabla 2**

*Cronograma*

Id	Nombre de tarea	Duración	Comienzo	Fin	Predecesor
<b>1</b>	<b>Gestión del Proyecto</b>	<b>82 días</b>	<b>jue. 1/10/20</b>	<b>mié. 30/12/20</b>	
<b>2</b>	<b>Fase de planificación del proyecto</b>	<b>4 días</b>	<b>jue. 1/10/20</b>	<b>lun. 5/10/20</b>	
3	Definición del problema y alcance	2 días	jue. 1/10/20	vie. 2/10/20	
4	Elaboración del plan de trabajo	1 días	sáb. 3/10/20	sáb. 3/10/20	3
5	Revisión general	1 días	lun. 5/10/20	lun. 5/10/20	4
<b>6</b>	<b>Fase de análisis de los requerimientos</b>	<b>2 días</b>	<b>mar. 6/10/20</b>	<b>mié. 7/10/20</b>	
7	Definición de los requerimientos	1 días	mar. 6/10/20	mar. 6/10/20	
8	Revisión general	1 días	mié. 7/10/20	mié. 7/10/20	7
<b>9</b>	<b>Fase de diseño de la arquitectura</b>	<b>3 días</b>	<b>jue. 8/10/20</b>	<b>sáb. 10/10/20</b>	
10	Definición de la arquitectura	1.5 días	jue. 8/10/20	vie. 9/10/20	
11	Revisión general	1 días	vie. 9/10/20	sáb. 10/10/20	10
<b>12</b>	<b>Fase de modelado dimensional</b>	<b>14 días</b>	<b>lun. 12/10/20</b>	<b>lun. 26/10/20</b>	
13	Definición de las dimensiones	5 días	lun. 12/10/20	vie. 16/10/20	
14	Identificar medidas	7 días	vie. 16/10/20	sáb. 24/10/20	13
15	Revisión general	2 días	sáb. 24/10/20	lun. 26/10/20	14
<b>16</b>	<b>Fase de diseño físico</b>	<b>4 días</b>	<b>mar. 27/10/20</b>	<b>vie. 30/10/20</b>	
17	Creación de sentencias de tablas	2 días	mar. 27/10/20	mié. 28/10/20	
18	Revisión general	2 días	jue. 29/10/20	vie. 30/10/20	17
<b>19</b>	<b>Fase de implementación ETL</b>	<b>20 días</b>	<b>lun. 2/11/20</b>	<b>lun. 23/11/20</b>	
20	Diseño de ETL	5 días	lun. 2/11/20	vie. 6/11/20	
21	Elaboración de lógicas	5 días	vie. 6/11/20	jue. 12/11/20	20
22	Diseño ETL carga tabla y dimensiones	7 días	jue. 12/11/20	jue. 19/11/20	21
23	Revisión general	3 días	jue. 19/11/20	lun. 23/11/20	22
<b>24</b>	<b>Fase de especificaciones y desarrollo de aplicaciones de BI</b>	<b>4 días</b>	<b>mar. 24/11/20</b>	<b>vie. 27/11/20</b>	
25	Realizar reportes específicos	4 días	mar. 24/11/20	vie. 27/11/20	
<b>26</b>	<b>Fase de implementación</b>	<b>3 días</b>	<b>mar. 1/12/20</b>	<b>jue. 3/12/20</b>	
27	Revisión general del proyecto	3 días	mar. 1/12/20	jue. 3/12/20	
28	Análisis de las pruebas y resultados	<b>28 días</b>	vie. 4/12/20	<b>lun. 4/01/21</b>	27

**Figura 3**

Diagrama de recolección de datos

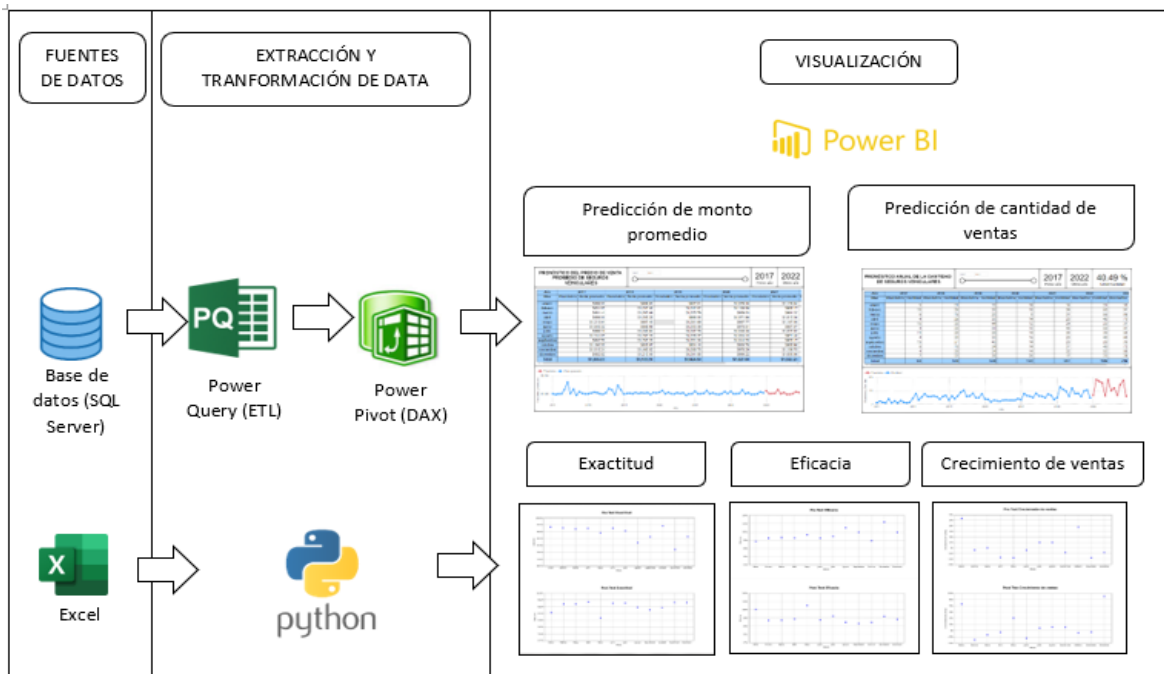


## 2.4. Procedimiento tecnológico

### 2.4.1. Proceso de recolección de datos

**Figura 4**

Modelo lógico de la inteligencia de negocios

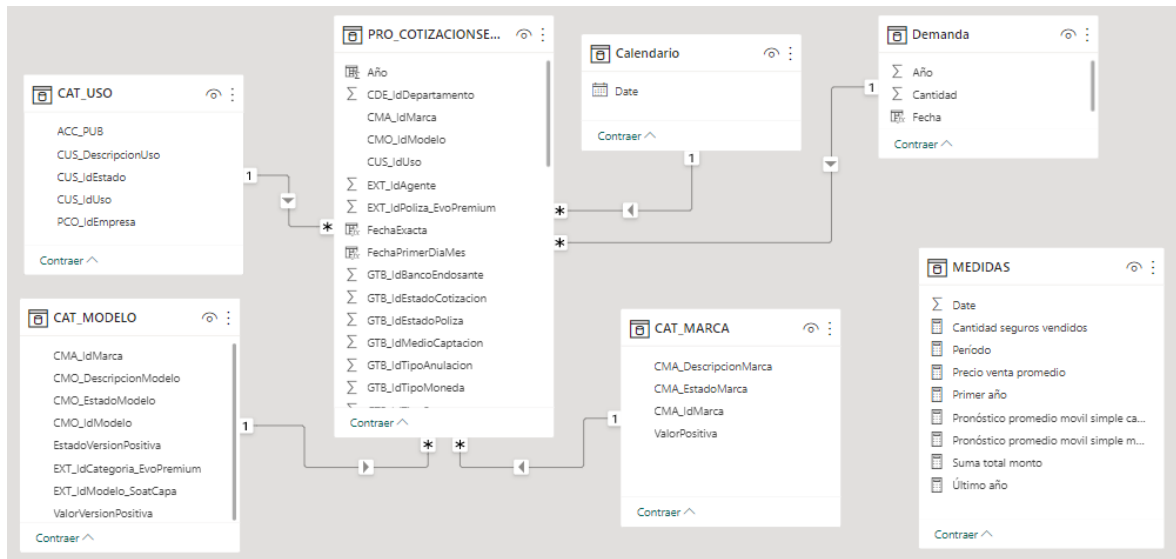


Para el proceso de recolección de datos, se inició con la investigación de los conceptos que se utilizarán en el proyecto. Se definieron las dimensiones e indicadores con

sus respectivos instrumentos, y se procedió a crear las fichas correspondientes. Para la población, se tomaron en cuenta las ventas de seguros vehiculares realizadas desde enero de 2017 hasta diciembre de 2022.

**Figura 5**

*Modelo de base de datos en Power BI*



## Pasos de instalación para conectar Python con Power BI

**Figura 6**

*Crear proyecto Python en anaconda*

```

Anaconda Prompt
(base) C:\Users\Ronald>conda create --name pbi python=3.6
Collecting package metadata (current_repodata.json): done
Solving environment: failed with repodata from current_repodata.json, will retry with next repodata source.
Collecting package metadata (repodata.json): done
Solving environment: done
  
```

**Figura 7**

*Conexión que usaremos en el Power BI*

```

(base) C:\Users\Ronald>conda env list
# conda environments:
#
base          * C:\Users\Ronald\anaconda3
pbi           C:\Users\Ronald\anaconda3\envs\pbi
  
```

Figura 8

Conda activate pbi

```
Anaconda Prompt
(base) C:\Users\Ronald>conda activate pbi

(pbi) C:\Users\Ronald>pip install pandas
Collecting pandas
  Downloading pandas-1.1.5-cp36-cp36m-win_amd64.whl (8.7 MB)
    |#####| 8.7 MB ...
Collecting pytz>=2017.2
  Using cached pytz-2023.3-py2.py3-none-any.whl (502 kB)
Collecting python-dateutil>=2.7.3
  Using cached python_dateutil-2.8.2-py2.py3-none-any.whl (247 kB)
Collecting numpy>=1.15.4
  Downloading numpy-1.19.5-cp36-cp36m-win_amd64.whl (13.2 MB)
    |#####| 13.2 MB 6.4 MB/s
Collecting six>=1.5
  Using cached six-1.16.0-py2.py3-none-any.whl (11 kB)
Installing collected packages: six, pytz, python-dateutil, numpy, pandas
Successfully installed numpy-1.19.5 pandas-1.1.5 python-dateutil-2.8.2 pytz-2023.3 six-1.16.0
```

Figura 9

Instalamos Matplotlib

```
Anaconda Prompt
(pbi) C:\Users\Ronald>pip install matplotlib
Collecting matplotlib
  Downloading matplotlib-3.3.4-cp36-cp36m-win_amd64.whl (8.5 MB)
    |#####| 8.5 MB 6.8 MB/s
Collecting kiwisolver>=1.0.1
  Downloading kiwisolver-1.3.1-cp36-cp36m-win_amd64.whl (51 kB)
    |#####| 51 kB ...
Requirement already satisfied: numpy>=1.15 in c:\users\ronald\anaconda3\envs\pbi\lib\site-packages (from matplotlib) (1.19.5)
Collecting cyclor>=0.10
  Using cached cyclor-0.11.0-py3-none-any.whl (6.4 kB)
Requirement already satisfied: python-dateutil>=2.1 in c:\users\ronald\anaconda3\envs\pbi\lib\site-packages (from matplotlib) (2.8.2)
Collecting pyparsing!=2.0.4,!=2.1.2,!=2.1.6,>=2.0.3
  Using cached pyparsing-3.0.9-py3-none-any.whl (98 kB)
Collecting pillow>=6.2.0
  Downloading Pillow-8.4.0-cp36-cp36m-win_amd64.whl (3.2 MB)
    |#####| 3.2 MB 6.8 MB/s
Requirement already satisfied: six>=1.5 in c:\users\ronald\anaconda3\envs\pbi\lib\site-packages (from python-dateutil>=2.1->matplotlib) (1.16.0)
Installing collected packages: pyparsing, pillow, kiwisolver, cyclor, matplotlib
Successfully installed cyclor-0.11.0 kiwisolver-1.3.1 matplotlib-3.3.4 pillow-8.4.0 pyparsing-3.0.9

(pbi) C:\Users\Ronald>pip install seaborn
Collecting seaborn
  Downloading seaborn-0.11.2-py3-none-any.whl (292 kB)
    |#####| 292 kB 6.8 MB/s
Requirement already satisfied: numpy>=1.15 in c:\users\ronald\anaconda3\envs\pbi\lib\site-packages (from seaborn) (1.19.5)
Requirement already satisfied: matplotlib>=2.2 in c:\users\ronald\anaconda3\envs\pbi\lib\site-packages (from seaborn) (3
```

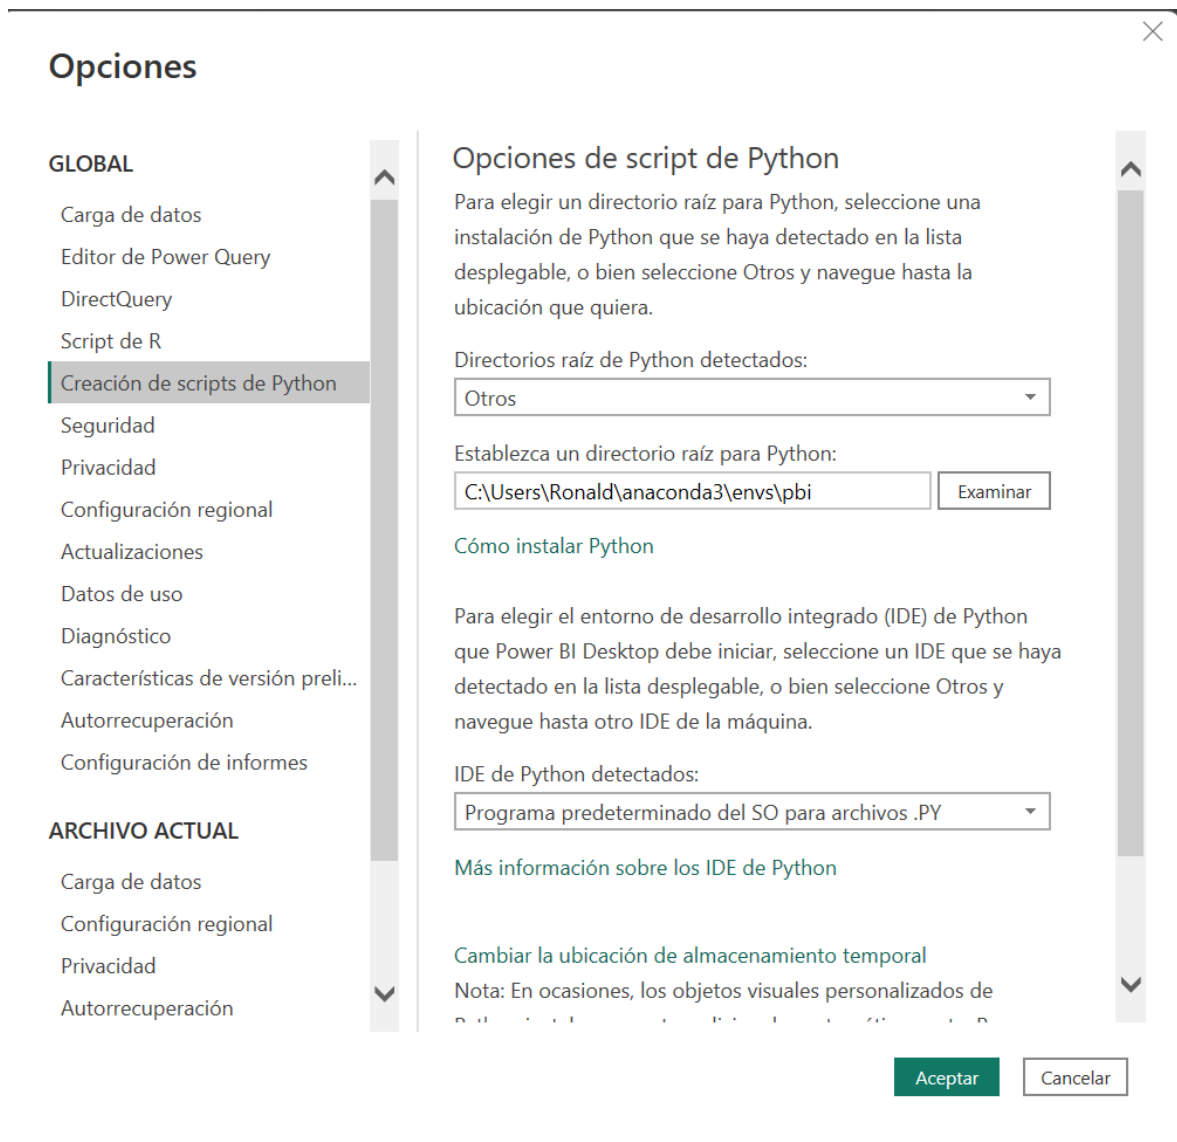
Figura 10

Instalamos Pandas

```
C:\WINDOWS\system32\cmd.exe
(pbi) C:\Users\Ronald>pip install pandas
Requirement already satisfied: pandas in c:\users\ronald\anaconda3\envs\pbi\lib\site-packages (1.1.5)
Requirement already satisfied: python-dateutil>=2.7.3 in c:\users\ronald\anaconda3\envs\pbi\lib\site-packages (from pandas) (2.8.2)
Requirement already satisfied: numpy>=1.15.4 in c:\users\ronald\anaconda3\envs\pbi\lib\site-packages (from pandas) (1.19.5)
Requirement already satisfied: pytz>=2017.2 in c:\users\ronald\anaconda3\envs\pbi\lib\site-packages (from pandas) (2023.3)
Requirement already satisfied: six>=1.5 in c:\users\ronald\anaconda3\envs\pbi\lib\site-packages (from python-dateutil>=2.7.3->pandas) (1.16.0)
(pbi) C:\Users\Ronald>
```

Figura 11

Conectar Power BI con ambiente creado



Se creó una tabla calendario donde se tendrá registro de todas las fechas, se usó el siguiente código DAX:

**Figura 12**

*Tabla calendario*

```

1 Calendario = CALENDAR(
2   DATE(FIRSTNONBLANK (
3     ALL ( PRO_COTIZACIONSEGURO[PCO_FechaRegistroCotizacion].[Año] ),
4     CALCULATE ( SUM ( PRO_COTIZACIONSEGURO[PCO_PrimaTotal] ), PRO_COTIZACIONSEGURO[GTB_IdEstadoCotizacion] = 11 )
5   ),1,1),
6   DATE(LASTNONBLANK (
7     ALL ( PRO_COTIZACIONSEGURO[PCO_FechaRegistroCotizacion].[Año] ),
8     CALCULATE ( SUM ( PRO_COTIZACIONSEGURO[PCO_PrimaTotal] ), PRO_COTIZACIONSEGURO[GTB_IdEstadoCotizacion] = 11 )
9   )+1,12,31))

```

Para la predicción se usaron las siguientes fórmulas:

1. Fórmula del período

**Figura 13**

*Período*

```

1 Período = ([Último año]-[Primer año])*12

```

2. Fórmula del pronóstico promedio móvil simple monto

**Figura 14**

*Pronóstico promedio móvil simple monto*

```

1 Pronóstico promedio movil simple monto = CALCULATE(
2   AVERAGE(
3     PRO_COTIZACIONSEGURO[PCO_PrimaTotal],
4     DATESINPERIOD(
5       Calendario[Date],
6       LASTDATE(Calendario[Date]),
7       -[Período],
8       MONTH
9     )
10  )

```

3. Fórmula del pronóstico promedio móvil simple cantidad

**Figura 15**

*Pronóstico promedio móvil simple cantidad*

```

1 Pronóstico promedio movil simple cantidad = CALCULATE(
2     AVERAGEX(FILTER(Demanda, Demanda[Fecha].[Año] <> 2023), Demanda[Cantidad]),
3     DATESINPERIOD(
4         Demanda[Fecha],
5         LASTDATE(Demanda[Fecha]),
6         -[Período],
7         MONTH
8     )
9 )

```

**Figura 16**

*Pronóstico anual de la cantidad de seguros vehiculares*

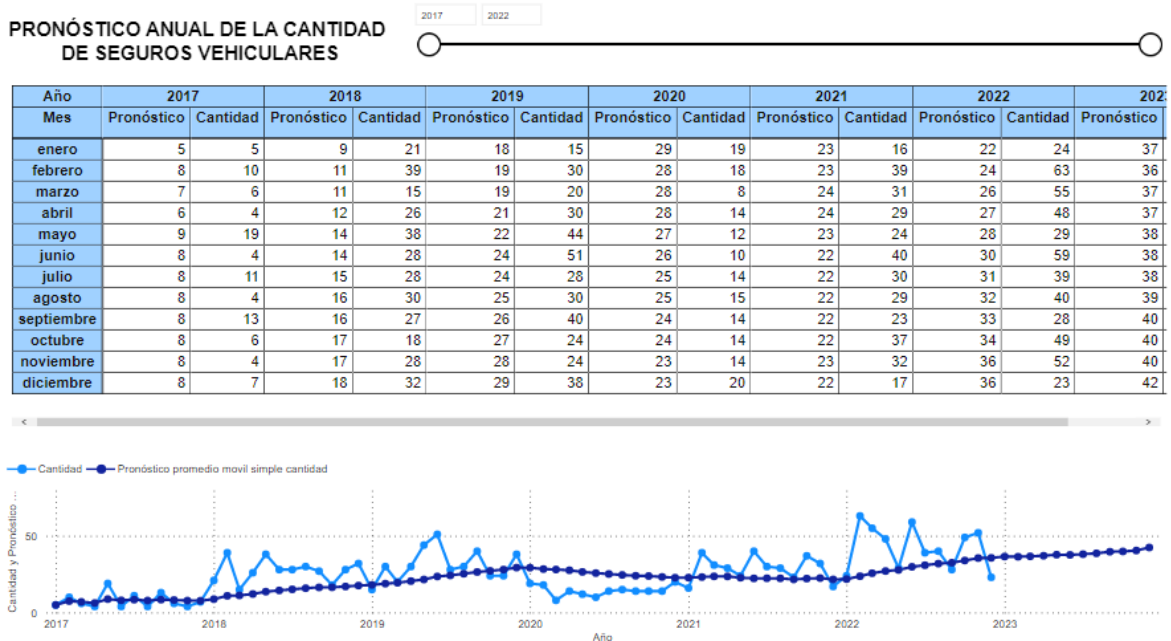
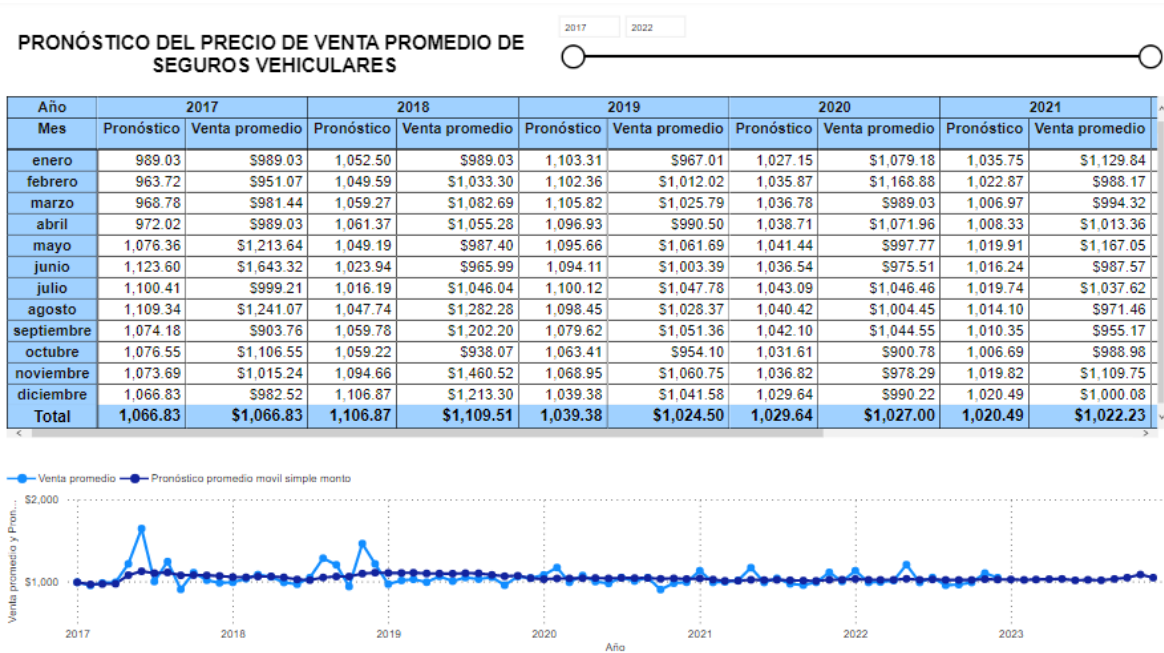


Figura 17

Pronóstico del precio de venta promedio de seguros vehiculares



Después de recolectar la información de los datos de la muestra, se procederá a procesar y analizar los datos. Se calcularán las predicciones y se elaborarán gráficos estadísticos. Finalmente, se discutirán los resultados de los datos y las predicciones de las ventas, y se tomarán decisiones en base a ellos.



Figura 18

*Pre test Exactitud*

```

1 import pandas as pd
2 import matplotlib.pyplot as plt
3 import matplotlib.ticker as mtick
4 # Crear un DataFrame a partir de los datos de entrada
5 df = pd.DataFrame({'NMes': dataset.NMes, 'Exactitud': dataset.Exactitud})
6 meses = ['Enero', 'Febrero', 'Marzo', 'Abril', 'Mayo', 'Junio', 'Julio', 'Agosto', 'Septiembre', 'Octubre', 'Noviembre', 'Diciembre']
7 # Crear la figura y los ejes
8 fig, ax = plt.subplots(figsize=(25,5))
9 # Graficar los datos usando el DataFrame
10 scatter = ax.plot(df['NMes'], df['Exactitud'], "bo")
11 # Configurar otros elementos del gráfico
12 ax.set_ylim([0.7, 1.05])
13 yticklabels = [f"{i}%" for i in range(70, 106, 20)]
14 ax.set_yticklabels(yticklabels)
15 ax.yaxis.set_major_formatter(mtick.PercentFormatter(xmax=1.05))
16 ax.set_xticks(range(1, 13))
17 ax.set_xticklabels(meses)
18 plt.xlabel("Meses")
19 plt.ylabel("Exactitud")
20 plt.suptitle("Pre Test Exactitud", fontsize=16, fontweight='bold')
21 plt.grid()
22 # Agregar tooltips manualmente usando ax.annotate()
23 for i in range(len(df)):
24     ax.annotate(f"{df['Exactitud'][i]*100:.2f}%",
25               xy=(df['NMes'][i], df['Exactitud'][i]),
26               xytext=(df['NMes'][i], df['Exactitud'][i]+0.02),
27               arrowprops=dict(facecolor='black', arrowstyle='->'),
28               ha='center', fontsize=16)
29 plt.show()

```

Figura 19

*Post test Exactitud*

```

1 import pandas as pd
2 import matplotlib.pyplot as plt
3 import matplotlib.ticker as mtick
4 # Crear un DataFrame a partir de los datos de entrada
5 df = pd.DataFrame({'NMes': dataset.NMes, 'Exactitud': dataset.Exactitud})
6 meses = ['Enero', 'Febrero', 'Marzo', 'Abril', 'Mayo', 'Junio', 'Julio', 'Agosto', 'Septiembre', 'Octubre', 'Noviembre', 'Diciembre']
7 # Crear la figura y los ejes
8 fig, ax = plt.subplots(figsize=(25,5))
9 # Graficar los datos usando el DataFrame
10 scatter = ax.plot(df['NMes'], df['Exactitud'], "bo")
11 # Configurar otros elementos del gráfico
12 ax.set_ylim([0.7, 1.05])
13 yticklabels = [f"{i}%" for i in range(70, 106, 20)]
14 ax.set_yticklabels(yticklabels)
15 ax.yaxis.set_major_formatter(mtick.PercentFormatter(xmax=1.05))
16 ax.set_xticks(range(1, 13))
17 ax.set_xticklabels(meses)
18 plt.xlabel("Meses")
19 plt.ylabel("Exactitud")
20 plt.suptitle("Post Test Exactitud", fontsize=16, fontweight='bold')
21 plt.grid()
22 # Agregar tooltips manualmente usando ax.annotate()
23 for i in range(len(df)):
24     ax.annotate(f"{df['Exactitud'][i]*100:.2f}%",
25               xy=(df['NMes'][i], df['Exactitud'][i]),
26               xytext=(df['NMes'][i], df['Exactitud'][i]+0.02),
27               arrowprops=dict(facecolor='black', arrowstyle='->'),
28               ha='center', fontsize=16)
29 plt.show()

```

Figura 20

*Pre test Eficacia*

```

1 import pandas as pd
2 import matplotlib.pyplot as plt
3 import matplotlib.ticker as mtick
4 # Crear un DataFrame a partir de los datos de entrada
5 df = pd.DataFrame({'NMes': dataset.NMes, 'Eficacia': dataset.Eficacia})
6 meses = ['Enero', 'Febrero', 'Marzo', 'Abril', 'Mayo', 'Junio', 'Julio', 'Agosto', 'Septiembre', 'Octubre', 'Noviembre', 'Diciembre']
7 # Crear la figura y los ejes
8 fig, ax = plt.subplots(figsize=(25,5))
9 # Graficar los datos usando el DataFrame
10 scatter = ax.plot(df['NMes'], df['Eficacia'], "bo")
11 # Configurar otros elementos del gráfico
12 ax.set_ylim([0.7, 1.3])
13 yticklabels = [f"{i}%" for i in range(70, 130, 20)]
14 ax.set_yticklabels(yticklabels)
15 ax.yaxis.set_major_formatter(mtick.PercentFormatter(xmax=1.05))
16 ax.set_xticks(range(1, 13))
17 ax.set_xticklabels(meses)
18 plt.xlabel("Meses")
19 plt.ylabel("Eficacia")
20 plt.suptitle("Pre Test Eficacia", fontsize=16, fontweight='bold')
21 plt.grid()
22 # Agregar tooltips manualmente usando ax.annotate()
23 for i in range(len(df)):
24     ax.annotate(f"{df['Eficacia'][i]*100:.2f}%",
25               xy=(df['NMes'][i], df['Eficacia'][i]),
26               xytext=(df['NMes'][i], df['Eficacia'][i]+0.02),
27               arrowprops=dict(facecolor='black', arrowstyle='->'),
28               ha='center', fontsize=16)
29 plt.show()

```

Figura 21

*Post test Eficacia*

```

1 import pandas as pd
2 import matplotlib.pyplot as plt
3 import matplotlib.ticker as mtick
4 # Crear un DataFrame a partir de los datos de entrada
5 df = pd.DataFrame({'NMes': dataset.NMes, 'Eficacia': dataset.Eficacia})
6 meses = ['Enero', 'Febrero', 'Marzo', 'Abril', 'Mayo', 'Junio', 'Julio', 'Agosto', 'Septiembre', 'Octubre', 'Noviembre', 'Diciembre']
7 # Crear la figura y los ejes
8 fig, ax = plt.subplots(figsize=(25,5))
9 # Graficar los datos usando el DataFrame
10 scatter = ax.plot(df['NMes'], df['Eficacia'], "bo")
11 # Configurar otros elementos del gráfico
12 ax.set_ylim([0.7, 1.3])
13 yticklabels = [f"{i}%" for i in range(70, 130, 20)]
14 ax.set_yticklabels(yticklabels)
15 ax.yaxis.set_major_formatter(mtick.PercentFormatter(xmax=1.05))
16 ax.set_xticks(range(1, 13))
17 ax.set_xticklabels(meses)
18 plt.xlabel("Meses")
19 plt.ylabel("Eficacia")
20 plt.suptitle("Post Test Eficacia", fontsize=16, fontweight='bold')
21 plt.grid()
22 # Agregar tooltips manualmente usando ax.annotate()
23 for i in range(len(df)):
24     ax.annotate(f"{df['Eficacia'][i]*100:.2f}%",
25               xy=(df['NMes'][i], df['Eficacia'][i]),
26               xytext=(df['NMes'][i], df['Eficacia'][i]+0.02),
27               arrowprops=dict(facecolor='black', arrowstyle='->'),
28               ha='center', fontsize=16)
29 plt.show()

```

Figura 22

Pre test Crecimiento de ventas

```

1 import pandas as pd
2 import matplotlib.pyplot as plt
3 import matplotlib.ticker as mtick
4 # Crear un DataFrame a partir de los datos de entrada
5 df = pd.DataFrame({'NMes': dataset.NMes, 'CrecimientoVentas': dataset.CrecimientoVentas})
6 meses = ['Enero', 'Febrero', 'Marzo', 'Abril', 'Mayo', 'Junio', 'Julio', 'Agosto', 'Septiembre', 'Octubre', 'Noviembre', 'Diciembre']
7 # Crear la figura y los ejes
8 fig, ax = plt.subplots(figsize=(25,5))
9 # Graficar los datos usando el DataFrame
10 scatter = ax.plot(df['NMes'], df['CrecimientoVentas'], "bo")
11 # Configurar otros elementos del gráfico
12 ax.set_ylim([-0.3, 0.60])
13 yticklabels = [f"{i}%" for i in range(-30, 60, 20)]
14 ax.set_yticklabels(yticklabels)
15 ax.yaxis.set_major_formatter(mtick.PercentFormatter(xmax=1.05))
16 ax.set_xticks(range(1, 13))
17 ax.set_xticklabels(meses)
18 plt.xlabel("Meses")
19 plt.ylabel("Crecimiento de ventas")
20 plt.suptitle("Pre Test Crecimiento de ventas", fontsize=16, fontweight='bold')
21 plt.grid()
22 # Agregar tooltips manualmente usando ax.annotate()
23 for i in range(len(df)):
24     ax.annotate(f"{df['CrecimientoVentas'][i]*100:.2f}%",
25               xy=(df['NMes'][i], df['CrecimientoVentas'][i]),
26               xytext=(df['NMes'][i], df['CrecimientoVentas'][i]+0.02),
27               arrowprops=dict(facecolor='black', arrowstyle='->'),
28               ha='center', fontsize=16)
29 plt.show()

```

Figura 23

Post test Crecimiento de ventas

```

1 import pandas as pd
2 import matplotlib.pyplot as plt
3 import matplotlib.ticker as mtick
4 # Crear un DataFrame a partir de los datos de entrada
5 df = pd.DataFrame({'NMes': dataset.NMes, 'CrecimientoVentas': dataset.CrecimientoVentas})
6 meses = ['Enero', 'Febrero', 'Marzo', 'Abril', 'Mayo', 'Junio', 'Julio', 'Agosto', 'Septiembre', 'Octubre', 'Noviembre', 'Diciembre']
7 # Crear la figura y los ejes
8 fig, ax = plt.subplots(figsize=(25,5))
9 # Graficar los datos usando el DataFrame
10 scatter = ax.plot(df['NMes'], df['CrecimientoVentas'], "bo")
11 # Configurar otros elementos del gráfico
12 ax.set_ylim([-0.4, 1.20])
13 yticklabels = [f"{i}%" for i in range(-40, 120, 20)]
14 ax.set_yticklabels(yticklabels)
15 ax.yaxis.set_major_formatter(mtick.PercentFormatter(xmax=1.05))
16 ax.set_xticks(range(1, 13))
17 ax.set_xticklabels(meses)
18 plt.xlabel("Meses")
19 plt.ylabel("Crecimiento de ventas")
20 plt.suptitle("Post Test Crecimiento de ventas", fontsize=16, fontweight='bold')
21 plt.grid()
22 # Agregar tooltips manualmente usando ax.annotate()
23 for i in range(len(df)):
24     ax.annotate(f"{df['CrecimientoVentas'][i]*100:.2f}%",
25               xy=(df['NMes'][i], df['CrecimientoVentas'][i]),
26               xytext=(df['NMes'][i], df['CrecimientoVentas'][i]+0.02),
27               arrowprops=dict(facecolor='black', arrowstyle='->'),
28               ha='center', fontsize=16)
29 plt.show()

```

## 2.5. Aspectos éticos

En este estudio se están tomando en cuenta los siguientes aspectos éticos:

La correcta citación de las fuentes en formato APA, la preservación de la confidencialidad de información sensible de la empresa, el respeto por la integridad y privacidad de los datos personales de clientes y otros individuos relacionados con la organización.

## CAPÍTULO III: RESULTADOS

### 3.1. Análisis descriptivo

#### 3.1.1. Análisis descriptivo de la exactitud de la predicción de venta de seguros vehiculares.

Analizamos el primer indicador para investigar cómo influye la implementación de una solución de inteligencia de negocios en la exactitud de las predicciones de venta de seguros de vehículos. Se utilizó la siguiente fórmula:


$$\frac{\sum |ventas\ realizadas - ventas\ pronosticadas|}{ventas\ realizadas} \times 100\%$$

- Ventas realizadas: El valor de las ventas en soles del periodo establecido en las fichas.
- Ventas pronosticadas: El pronóstico calculado en Power BI.

$$100\% - Error\ Absoluto\%$$

**Figura 24**


*Análisis descriptivo del pretest de la exactitud de la predicción (2017-2020)*



Como indica esta figura, muestra el indicador de la exactitud de la predicción para los años 2017-2020 tiene una variabilidad en sus datos, puesto que en enero se tuvo un valor de 98,53%, en mayo fue de 94,06%, en noviembre bajó a 82%, y en diciembre fue de 91,40%.

**Figura 25**

*Análisis descriptivo del postest de la exactitud de la predicción (2021-2022)*



Como indica esta figura, muestra como el indicador de la exactitud de la predicción para los años 2021-2022 tiene una variabilidad en sus datos, puesto que en enero se tuvo un valor de 90,62%, en mayo bajó a 86,80%, en noviembre fue de 98,15%, y finalmente en diciembre fue de 98,12%.

**3.1.2. Análisis descriptivo de la eficacia de la predicción de venta de seguros vehiculares.**


El segundo indicador que se analizó fue para determinar cómo influye la implementación de una solución en inteligencia de negocios en la eficacia de la predicción de venta de seguros vehiculares. Se utilizó la siguiente fórmula:

$$\frac{\text{ventas reales}}{\text{ventas pronosticadas}} \times 100$$

Se empleo la fórmula para calcular la eficacia, los datos que se usaron fueron las ventas realizadas y las ventas pronosticadas.

**Figura 26**


*Análisis descriptivo del pretest de la eficacia del pronóstico (2017-2020)*



Como indica esta figura, se observa que el indicador de la eficacia de la predicción para los años 2017-2020 presenta variabilidad en sus datos. En enero, se tuvo un valor de 98,55%, mientras que en mayo fue de 106,32%, en noviembre aumentó a 121,95%, y en diciembre disminuyó a 109,41%.

**Figura 27**

*Análisis descriptivo del postest de la eficacia del pronóstico (2021-2022)*



Como indica esta figura muestra como el indicador de la eficacia de la predicción para los años 2021-2022 tiene una variabilidad en sus datos, puesto que, en enero se tuvo un valor de 110,35%, en mayo bajo a 115,20%, en noviembre fue de 101,88%, y finalmente en diciembre fue de 98,15%.


### 3.1.3. Análisis descriptivo del crecimiento de las ventas de seguros vehiculares.

El tercer indicador que se analizó fue para determinar cómo influye la implementación de una solución en inteligencia de negocios en el crecimiento de venta de seguros vehiculares. Se uso la siguiente fórmula:

$$\left( \frac{\text{ventas realizadas}}{\text{ventas anteriores}} - 1 \right) \times 100$$

**Figura 28**


*Análisis descriptivo del pretest del crecimiento de ventas (2017-2020)*



Como indica esta figura, el indicador de crecimiento de las ventas de la predicción para los años 2017-2020 muestra una variabilidad en sus datos. En enero, se registró un valor del 53,33%, pero en mayo se redujo a un -17,86%. En noviembre, el valor se mantuvo en -17,86%, y finalmente en diciembre fue de -8,33%.

**Figura 29**

*Análisis descriptivo del postest del crecimiento de ventas (2021-2022)*



Como indica esta figura muestra como el indicador del crecimiento de las ventas de la predicción para los años 2021-2022 tiene una variabilidad en sus datos, puesto que, en



enero se tuvo un valor de 85%, en mayo bajo a 40,74%, en noviembre fue de -4,76%, y finalmente en diciembre fue de 110%.

### 3.2. Análisis inferencial

#### 3.2.1. Análisis de la hipótesis específica 1

La implementación de una solución en inteligencia de negocios influye en la exactitud de la predicción de las ventas de seguros vehiculares.

##### 3.2.1.1. Prueba de normalidad

Ho: La información de la exactitud de la predicción de las ventas de seguros vehiculares antes como después de la implementación de una solución en inteligencia de negocios corresponden a una distribución normal

Ha: La información de la exactitud de la predicción de las ventas de seguros vehiculares antes como después de la implementación de una solución en inteligencia de negocios no corresponden a una distribución normal

#### Regla de decisión

Si  $p\_valor > 5\%$ , la distribución normal es la que describe la información

Si  $p\_valor \leq 5\%$ , la distribución normal no es la que describe la información

**Tabla 3**

*Prueba de normalidad de la exactitud de la predicción de las ventas de seguros vehiculares*

	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Exactitud_pre	0,212	12	0,144	0,850	12	<b>0,037</b>
Exactitud_post	0,265	12	0,020	0,836	12	<b>0,024</b>

La primera tabla muestra los valores de significancia estadística obtenidos mediante la prueba de Shapiro Wilk fueron 0,037 y 0,024, lo que indica que los valores están por debajo del 5% y se puede concluir que los datos de la exactitud de la predicción de las ventas de seguros vehiculares provienen de una distribución diferente a la normal. En conclusión, se decidió utilizar la prueba de Wilcoxon como prueba estadística para contrastar la hipótesis.

### 3.2.1.2. Contraste de la hipótesis

**Ha:** La implementación de una solución en inteligencia de negocios influye en la exactitud de la predicción de las ventas de seguros vehiculares.

**Ho:** La implementación de una solución en inteligencia de negocios no influye en la exactitud de la predicción de las ventas de seguros vehiculares.

### Regla de decisión

Si  $p\_valor > 5\%$ , la hipótesis nula ( $H_0$ ) no es rechazada

Si  $p\_valor \leq 5\%$ , la hipótesis nula ( $H_0$ ) es rechazada

**Tabla 4**

*Prueba de Wilcoxon de la exactitud de la predicción*

	Exactitud_post – Exactitud_pre
Z	-0,471a
Sig. asintót. (bilateral)	<b>0,638</b>

a. Basado en los rangos negativos.

b. Prueba de los rangos con signo de Wilcoxon

La tabla 2 muestra que el valor de significación estadística obtenido mediante la prueba de Wilcoxon fue de 0,638, lo cual es superior al 5%. Por lo tanto, no se rechaza la hipótesis nula., concluyendo que la implementación de una solución en inteligencia de negocios no influye en la exactitud de la predicción de las ventas de seguros vehiculares.

### 3.2.2. Análisis de la hipótesis específica 2

La implementación de una solución en inteligencia de negocios influye en la eficacia de la predicción de las ventas de seguros vehiculares.

#### 3.2.2.1. Prueba de normalidad

Ho: La información de la eficacia de la predicción de las ventas de seguros vehiculares antes como después de la implementación de una solución en inteligencia de negocios corresponden a una distribución normal.

Ha: La información de la eficacia de la predicción de las ventas de seguros vehiculares antes como después de la implementación de una solución en inteligencia de negocios no corresponden a una distribución normal.

#### **Regla de decisión**

Si  $p\_valor > 5\%$ , la distribución normal es la que describe la información

Si  $p\_valor \leq 5\%$ , la distribución normal no es la que describe la información

**Tabla 5**

*Prueba de normalidad de la eficacia de la predicción de las ventas de seguros vehiculares*

	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
eficacia_pre	0,179	12	0,200*	0,890	12	<b>0,118</b>
eficacia_post	0,260	12	0,024	0,835	12	<b>0,024</b>

a. Corrección de la significación de Lilliefors

\*. Este es un límite inferior de la significación verdadera.

La tabla 3 presenta los resultados de la prueba de Shapiro Wilk, donde se obtuvieron valores de significancia estadística de 0,118 y 0,024. Estos valores son inferiores al 5%, lo que sugiere que los datos de eficacia de predicción de ventas de seguros vehiculares siguen una distribución normal. Como resultado, se decidió utilizar la prueba estadística de Wilcoxon para contrastar la hipótesis.

### 3.2.2.2. Contraste de la hipótesis

**Ha:** La implementación de una solución en inteligencia de negocios influye en la eficacia de la predicción de las ventas de seguros vehiculares.

**Ho:** La implementación de una solución en inteligencia de negocios no influye en la eficacia de la predicción de las ventas de seguros vehiculares.

### **Regla de decisión**

Si  $p\_valor > 5\%$ , la hipótesis nula ( $H_0$ ) no es rechazada

Si  $p\_valor \leq 5\%$ , la hipótesis nula ( $H_0$ ) es rechazada

**Tabla 6**

*Prueba de Wilcoxon de la eficiencia de la predicción*

	Eficacia_post – Eficacia_pre
Z	-1,804a
Sig. asintót. (unilateral)	<b>0,04</b>

a. Basado en los rangos negativos.

b. Prueba de los rangos con signo de Wilcoxon

La tabla 4 muestra que el valor de significación estadística obtenido mediante la prueba de Wilcoxon fue de 0,04, lo cual es inferior al 5%. Por lo tanto, se rechaza la hipótesis nula y se concluye que la implementación de una solución de inteligencia de negocios influye en la eficacia de la predicción de ventas de seguros vehiculares.

### 3.2.3. Análisis de la hipótesis específica 3

La implementación de una solución en inteligencia de negocios influye en el crecimiento de las ventas en la predicción de seguros vehiculares.

#### 3.2.3.1. Prueba de normalidad

Ho: la información del crecimiento de las ventas de seguros vehiculares antes como después de la implementación de una solución en inteligencia de negocios corresponden a una distribución normal.

Ha: la información del crecimiento de las ventas de seguros vehiculares antes como después de la implementación de una solución en inteligencia de negocios no corresponden a una distribución normal.

### **Regla de decisión**

Si  $p\_valor > 5\%$ , la distribución normal es la que describe la información

Si  $p\_valor \leq 5\%$ , la distribución normal no es la que describe la información

**Tabla 7**

*Prueba de normalidad del crecimiento de las ventas de las ventas de seguros vehiculares*

	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
crecimiento_pre	0,215	12	0,130	0,832	12	<b>0,022</b>
crecimiento_post	0,285	12	0,008	0,837	12	<b>0,025</b>

a. Corrección de la significación de Lilliefors

La tabla 5 indica que los resultados de la prueba de Shapiro-Wilk para los datos de crecimiento de ventas de seguros vehiculares arrojaron valores de 0,022 y 0,025, respectivamente. Estos valores sugieren que los datos provienen de una distribución normal, ya que ambos son inferiores al nivel de significancia del 5%. En consecuencia, se decidió utilizar la prueba estadística de Wilcoxon para contrastar la hipótesis.

### 3.2.3.2. Contraste de la hipótesis

**Ha:** La implementación de una solución en inteligencia de negocios influye en el crecimiento de las ventas de seguros vehiculares.

**Ho:** La implementación de una solución en inteligencia de negocios no influye en el crecimiento de las ventas de seguros vehiculares.

### **Regla de decisión**

Si  $p\_valor > 5\%$ , la hipótesis nula ( $H_0$ ) no es rechazada

Si  $p\_valor \leq 5\%$ , la hipótesis nula ( $H_0$ ) es rechazada

**Tabla 8**

*Prueba de Wilcoxon del crecimiento de las ventas*

	Eficacia_post – Eficacia_pre
Z	-0,589a
Sig. asintót. (unilateral)	<b>0,566</b>

a. Basado en los rangos negativos.

b. Prueba de los rangos con signo de Wilcoxon

La tabla 6 muestra que la prueba estadística de Wilcoxon encontró un valor de significación estadística de 0,566, lo que está por encima del nivel de significancia del 5%. Por lo tanto, no se rechaza la hipótesis nula y se concluye que la implementación de una solución en inteligencia de negocios no influye en el crecimiento de las ventas de seguros vehiculares.

## CAPÍTULO IV: DISCUSIÓN Y CONCLUSIONES

### 4.1. Discusión de resultados

El primer objetivo que se buscó fue determinar cómo influyó la implementación de una solución en inteligencia de negocios en la exactitud de la predicción de venta de seguros vehiculares usando una fórmula para determinar el error absoluto. Dicha fórmula consistía en una aproximación al cero cuando la predicción es más exacta. El estudio encontró que la exactitud para el pretest fue del 94.06% y para el postest fue del 95.20%. Dicho resultado se basó en las fórmulas de Azañero Burga & Ramirez Sipion, (2019), quienes en su estudio utilizaron algoritmos con 5 fórmulas, entre ellas el MAPE, para analizar el error. En el promedio móvil usaron 2 meses, teniendo un error del 22%, lo cual les daría una exactitud del 78%.

El segundo objetivo que se buscó fue determinar cómo influye la implementación de una solución en inteligencia de negocios en la eficacia de la predicción de venta de seguros vehiculares. Para el pretest se encontró una eficacia del 106.25% y para el postest de 100.02%. Estos resultados concuerdan con los encontrados por Vargas Pinto (2018), cuyo valor de la eficacia se incrementó en un 11% aplicando la inteligencia de negocios para el pronóstico de las ventas de la empresa Zona Cel. Asimismo, se pueden comparar con los encontrados por Parra (2016), quien muestra que la implementación de la inteligencia de negocios logró mejorar en un 55% los tiempos de ejecución de la toma de pedidos.



El tercer objetivo que se buscó fue determinar cómo influye la implementación de una solución en inteligencia de negocios en el crecimiento de ventas en la predicción de venta de seguros vehiculares. Los resultados encontrados fueron un crecimiento de ventas del 2.72% para el pretest y del 15.22% para el posttest. Esto concuerda con lo encontrado por Vargas Pinto (2018), quien implementó una solución de inteligencia de negocios logrando un incremento del 15.56% en el crecimiento de las ventas. Asimismo, se utilizó la misma fórmula, la cual consistía en que a mayor sea el resultado, mayor es el incremento y a menor resultado, menor es el incremento.

## **4.2. Conclusiones y limitaciones**

### **4.2.1. Conclusiones**

Se concluye que la implementación aplicada no influyó en la exactitud del pronóstico de la venta de seguros vehiculares, ya que se obtuvo un resultado de 1.14%.

En cuanto a la eficacia, se concluye que en promedio los valores mejoraron un 6.23% con la implementación, lo que implica que sí influyó en la eficacia.

Finalmente, para el crecimiento de las ventas, se observó un aumento del 12.49%. Este valor se debe a que las ventas del primer año fueron bajas y el año 2020, afectado por la pandemia, fue tomado antes de la implementación, lo que implica que no influyó en el crecimiento de ventas.

### **4.2.2. Limitaciones**

Durante el estudio, se encontró una limitación importante al intentar predecir las ventas de seguros vehiculares por la pandemia del covid 19. La empresa aseguradora

experimentó una disminución en las ventas, lo que afectó la precisión de los datos en la base de datos y dificultó la predicción de las ventas futuras.

La implementación de una solución en el ámbito de la inteligencia de negocios puede necesitar de conocimientos y competencias técnicas que el investigador o el equipo de la compañía de seguros no tengan. La carencia de experiencia en áreas como la extracción de información relevante de los datos o el procesamiento automático de datos puede obstaculizar la eficacia de la solución.

La rapidez con la que varía el contexto empresarial puede tener consecuencias sobre la eficiencia de la solución aplicada. Transformaciones en la situación económica, la competencia, las innovaciones tecnológicas y las políticas gubernamentales tienen el potencial de afectar el triunfo de la solución.

### **4.3. Aplicaciones y futuras investigaciones**

#### **4.3.1. Aplicaciones prácticas**

El objetivo del estudio fue determinar cómo influyó la predicción en la gestión de ventas de seguros vehiculares a través de un análisis en la exactitud, eficacia y crecimiento de ventas.

Una vez estandarizados los indicadores e informes administrativos, se recomienda usar Power BI en los demás procesos de las partes operativas para que todas las mediciones e indicadores sean realizados por la herramienta Power BI.

La medición constante de la satisfacción del cliente es importante ya que lleva a la organización a alcanzar sus metas de fidelización de sus colaboradores y clientes. Y así,

puede identificar de manera más precisa los errores que pueden existir en la relación con sus clientes.

#### **4.3.2. Recomendaciones para futuras investigaciones**

En relación con las investigaciones futuras, recomendamos tener una base de datos completa, bien estructurada y suficientemente grande como para poder dar un valor explicativo más decisivo a los resultados.

Se sugiere adquirir un mayor conocimiento en Power BI para poder utilizar al máximo esta herramienta, por ejemplo, en la capacidad de enlazar con varias fuentes de datos externas. Al profundizar en los datos, el usuario final podrá aumentar sus conocimientos y contribuir al crecimiento de la organización.

## Referencias

- Argibay, J. C. (2009). *Muestra en investigación cuantitativa*. Obtenido de [http://www.scielo.org.ar/scielo.php?pid=S1852-73102009000100001&script=sci\\_arttext&tlng=en](http://www.scielo.org.ar/scielo.php?pid=S1852-73102009000100001&script=sci_arttext&tlng=en)
- Azañero Burga, J. A., & Ramirez Sipion, R. J. (2019). *Análisis comparativo de algoritmos de pronóstico de ventas para su implementación en mypes del sector ferretería de Chiclayo*.
- Barrera Freire, E. R. (2019). *Implementación de puntos de inspección y control con la aplicación de fichas de observación en una empresa de servicios*.
- Cantoral, R., Molina, J. G., & Sánchez, M. (2014). Socioepistemología de la Predicción.
- Carhuallanqui Bastidas, J. L. (2017). Diseño de una solución de inteligencia de negocios como herramienta de apoyo a la toma de decisiones en el área de ventas de la empresa farmacéutica Dispefarma.
- Conesa Caralt, J., Bartrolí Muñoz, Á., Braulio Gil, N., Curto Díaz, J., & Puigvert Pell, F. (2015). Nuevas tendencias tecnológicas en BI.
- Costa, P. (2007). *Propuesta de una ficha de registro para el Arte Rupestre*.
- Cuadros Del Carpio, J. A. (2022). *Metodologías de la investigación y desarrollo de tesis*.
- Díaz Fernández, S. M. (2014). *Desarrollo de una ficha de observación para el análisis y evaluación de experiencias educativas en mundos virtuales*.

- Ec, R. (14 de Abril de 2017). ¿Por qué esta aumentando la venta de seguros vehiculares? *El Comercio Perú*. Obtenido de <https://elcomercio.pe/economia/dia-1/aumentando-venta-seguros-vehiculares-414349-noticia/>
- Encalada Sarmiento, J. V., & Sánchez Crisóstomo, A. G. (2019). “Implementación de Business Intelligence, basado en la metodología Ralph Kimball, para mejorar el proceso de toma de decisiones gerenciales del área de ventas de Indurama.
- Escobar Guanochanga, C. A. (2019). Detección de patrones y tendencia mediante business Intelligence en el área de ventas en la Pasteurizadora Quito planta Tulcán.
- Forero Castañeda, D. A., & Sánchez Garcia, J. A. (2021). *Introducción a la inteligencia de negocios basado en la metodología Kimball*. Obtenido de <https://revistas.udistrital.edu.co/index.php/tia/article/view/18082/17993>
- Fournier García, M. d., Rouquette Alvarado, J. O., & Ariza Gómez, E. (2019). *Uso de material educativo por computadora para estudiantes de la carrera de Administración*.
- Guadaña Julón, B. (2019). Implementación de una data mart como solución de inteligencia de negocios, para optimizar la toma de decisiones en el área comercial de la empresa Pisacom S.A.C.
- Heredia Salinas, E. W. (2018). Implementación de Business Intelligence en la gestión de ventas de la empresa Procesados Amazónicos del distrito de Tarapoto, 2018.
- Intriago, E., & Castro, Y. (2016). *Sistemas de Inteligencia de Negocio para apoyar la toma de decisiones en Medicina Veterinaria*.
- Li Loo, F. F. (2019). *Inteligencia de Negocios en el Pronóstico de Ventas*, Centro Nacional de Servicios, Lima, 2019.

*matplotlib.pyplot.* (s.f.). Obtenido de

[https://matplotlib.org/3.5.3/api/\\_as\\_gen/matplotlib.pyplot.html](https://matplotlib.org/3.5.3/api/_as_gen/matplotlib.pyplot.html)

Mesaros, P., Carnicky, S., Mandicak, T., Habinakova, M., Mackova, D., & Spisakova, M. (2016). Business Intelligence impact on corporate performance in Slovak enterprises – a case study.

Mesaros, P., Mandicak, T., Mackova, D., Carnicky, S., Habinakova, M., & Spisakova, M. (2016). Model of key success factors for Business Intelligence implementation.

Microsoft. (21 de 09 de 2022). Obtenido de Microsoft: <https://learn.microsoft.com/es-es/power-query/power-query-what-is-power-query>

Microsoft. (22 de 03 de 2023). Ejecución de scripts de Python en Power BI Desktop. Obtenido de <https://learn.microsoft.com/es-es/power-bi/connect-data/desktop-python-scripts>

Microsoft. (s.f.). *Microsoft® SQL Server® 2014 Express*. Obtenido de Microsoft® SQL Server® 2014 Express: <https://www.microsoft.com/es-es/download/details.aspx?id=42299#:~:text=Microsoft%20SQL%20Server%202014%20Express,y%20los%20sitios%20web%20ligeros.&text=SQL%20Server%202014%20Express%20incluye,SQL%20Server%202014%20Management%20Studio>.

Microsoft. (s.f.). *Qué es Power BI Microsoft Power BI*. Obtenido de Qué es Power BI Microsoft Power BI: <https://powerbi.microsoft.com/es-es/what-is-power-bi/>

Moreno Castro, T. F. (2019). *El pronóstico de ventas en los negocios Modelos y Aplicaciones*. (Vol. Primera edición). RIL editores.

Oracle. (s.f.). Obtenido de

[https://docs.oracle.com/cloud/help/es/pbcs\\_common/CSPPU/single\\_moving\\_average\\_sma.htm](https://docs.oracle.com/cloud/help/es/pbcs_common/CSPPU/single_moving_average_sma.htm)

*pandas Python Data Analysis Library*. (s.f.). Obtenido de <https://pandas.pydata.org/about/>

Parra Coba, J. D. (2016). Desarrollo de una aplicación móvil para la recepción de pedidos apoyada en predicciones de negocio con Business Intelligence para la empresa MEGAKONS S.A.

Peña Vera, T., & Pirela Morillo, J. (2007). *La complejidad del análisis documental*.

Prieto Morales, R., Meneses Villegas, C., & Vega Zepeda, V. (2015). Análisis comparativo de modelos de madurez en inteligencia de negocio.

Quimbia Loyo, R. (2017). Modelo de Inteligencia de Negocios (BI), para el manejo de indicadores clave de desempeño (KPI) en ventas para la toma de decisiones en los retails de farmacias de la empresa farmaenlace cía. Ltda.

Salinas La Rosa, A. (2010). *Inteligencia de Negocios. Auditoria y control. Prototipo de herramienta de calidad de datos*.

Salinas López, C. (2015). *Programación y evaluación aplicadas a la gestión cultural*.

Shaheb, A., Shah J., M., & Shahadat, K. (2017). Analysis of Interaction between Business Intelligence and SMEs: Learn from Each Other.

Supo Condori, F., & Cavero Aybar, H. (2014). *Fundamentos teóricos y procedimentales de la investigación científica en ciencias sociales*.

Tamayo, M. (2004). *El proceso de la investigación científica*. Editorial Limusa.

Van Rossum, G. (2008). *El tutorial de Python*.

Vargas Pinto, D. J. (2018). *Business Intelligence para el pronóstico de ventas en la empresa zona Cel S.A.C.*

Villarreal, F. (2016). *Introducción a los Modelos de Pronósticos.*



**Anexos**

**Anexo 1**

**Figura 30**

*Espina de Ishikawa*



**Anexo 2**

**Tabla 9**

*Matriz de operacionalización de la variable*

Variables	Definición Conceptual	Dimensiones	Indicadores	Instrumentos
Inteligencia de negocios / Business Intelligence	Business Intelligence es una herramienta que asiste en la toma de decisiones. (Mesaros, y otros, 2016)			
Predicción de ventas	La predicción se considera significativa debido a que ha demostrado ser un factor clave en el avance de los conceptos matemáticos, especialmente en el campo del cálculo. (Cantoral, Molina, & Sánchez, 2014)	Exactitud de la predicción	Error	Ficha de registro de ventas
		Eficacia	Cumplimiento de objetivos	
		Crecimiento de ventas	Cantidad de ventas	

### Anexo 3

#### Scripts de SQL

##### Figura 31

*Pre test promedio de monto (2017-2020)*

```
SELECT MONTH(PCO_FechaRegistroCotizacion) Mes, AVG(PCO_PrimaTotal) PromedioMonto FROM dbo.PRO_COTIZACIONSEGURO  
WHERE GTB_IdEstadoCotizacion = 11 AND YEAR(PCO_FechaRegistroCotizacion) BETWEEN 2017 AND 2020  
GROUP BY MONTH(PCO_FechaRegistroCotizacion)  
ORDER BY MONTH(PCO_FechaRegistroCotizacion)
```

##### Figura 32

*Post test promedio de monto (2021-2022)*

```
SELECT MONTH(PCO_FechaRegistroCotizacion) Mes, AVG(PCO_PrimaTotal) PromedioMonto FROM dbo.PRO_COTIZACIONSEGURO  
WHERE GTB_IdEstadoCotizacion = 11 AND YEAR(PCO_FechaRegistroCotizacion) BETWEEN 2021 AND 2022  
GROUP BY MONTH(PCO_FechaRegistroCotizacion)  
ORDER BY MONTH(PCO_FechaRegistroCotizacion)
```

##### Figura 33

*Pre test promedio de cantidad (2017-2020)*

```
SELECT MONTH(PCO_FechaRegistroCotizacion) Mes, COUNT(PCO_PrimaTotal) Cantidad, (COUNT(PCO_PrimaTotal)*1.0)/4 PromedioCantidad  
FROM dbo.PRO_COTIZACIONSEGURO  
WHERE GTB_IdEstadoCotizacion = 11 AND YEAR(PCO_FechaRegistroCotizacion) BETWEEN 2017 AND 2020  
GROUP BY MONTH(PCO_FechaRegistroCotizacion)  
ORDER BY MONTH(PCO_FechaRegistroCotizacion)
```

##### Figura 34

*Post test promedio de cantidad (2021-2022)*

```
SELECT MONTH(PCO_FechaRegistroCotizacion) Mes, COUNT(PCO_PrimaTotal) Cantidad, (COUNT(PCO_PrimaTotal)*1.0)/2 PromedioCantidad  
FROM dbo.PRO_COTIZACIONSEGURO  
WHERE GTB_IdEstadoCotizacion = 11 AND YEAR(PCO_FechaRegistroCotizacion) BETWEEN 2021 AND 2022  
GROUP BY MONTH(PCO_FechaRegistroCotizacion)  
ORDER BY MONTH(PCO_FechaRegistroCotizacion)
```