

**ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL**



**Facultad de Ingeniería en Electricidad y Computación**

**Maestría en Sistemas de Información Gerencial**

“IMPLEMENTACIÓN DE UN MODELO DE RECOMENDACIÓN DE  
PRODUCTOS APLICANDO MINERÍA DE DATOS PARA LA MEJORA DEL  
PROCESO DE ATENCIÓN AL CLIENTE EN UNA EMPRESA DE COMIDA  
RÁPIDA DE CONSUMO MASIVO”

**TRABAJO DE TITULACIÓN**

Previo a la obtención el título de:

**MAGISTER EN SISTEMAS DE INFORMACIÓN GERENCIAL**

**Autor:**

Simón José Dávila Solórzano

Guayaquil – Ecuador

2021

## AGRADECIMIENTO

Agradezco principalmente a Dios por permitirme crecer y aprender cada día, guiándome en cada paso que doy, agradezco a mis padres y a mi esposa por la constancia y la preocupación, por sus palabras de aliento y sobre todo por ayudarme a llegar a la culminación exitosa de este proyecto.

Agradezco a mi tutor, a los docentes que formaron parte de mi cátedra y me formaron tanto en virtudes como en profesionalismo sin ellos no hubiera podido avanzar en el proceso de este proyecto también agradezco a mis amigos que siempre me han acompañado.



---

Ing. Simón Dávila Solórzano

## DEDICATORIA

Dedico este trabajo de titulación a Dios porque con su ayuda cada día y en cada percance no podría salir victorioso, a mi esposa por ser una inagotable inspiración de lucha y trabajo en conjunto levantándome de cada tropiezo, a mis padres por su ejemplo y constante amor en todos los aspectos de la vida, ya que me han enseñado y acompañado en cada momento y levantándome cada día a pesar de todos mis errores.

## TRIBUNAL DE SUSTENTACIÓN



---

MSIG. LENIN FREIRE COBO  
COORDINADOR MSIG



---

MSIG. JUAN CARLOS GARCÍA  
DIRECTOR DEL TRABAJO DE TITULACIÓN



---

MSIG. OMAR MALDONADO DAÑIN  
MIEMBRO DEL TRIBUNAL

## **RESUMEN**

El presente proyecto de titulación tiene como objetivo implementar un modelo de recomendación de productos aplicando minería de datos para la mejora del proceso de atención al cliente en una empresa de comida rápida de consumo masivo mediante el análisis cuantitativo y cualitativo realizados a los datos históricos de dicha empresa, observando el proceso de compra del cliente que generalmente no tiene idea de que pedir lo cual conlleva a la demora del proceso en diferentes casos.

El modelo de recomendación de productos reconoce al cliente por medio de su número de cédula para luego filtrar sus compras pasadas en base a variables como sucursal, mes, producto, entre otros, por medio de la minería de datos y así se podrá recomendar una mejor y precisa opción de compra al cliente, lo que facilitará y permitirá que la compra sea rápida.

## ÍNDICE GENERAL

AGRADECIMIENTO.....	II
DEDICATORIA.....	III
TRIBUNAL DE SUSTENTACIÓN.....	IV
RESUMEN.....	V
ÍNDICE GENERAL.....	VI
ÍNDICE DE FIGURAS.....	X
ÍNDICE DE TABLAS.....	XVI
INTRODUCCIÓN.....	XVII
CAPÍTULO 1.....	1
GENERALIDADES.....	1
1.1. Antecedentes.....	1
1.2. Descripción del problema.....	3
1.3. Solución propuesta.....	3

1.4. Objetivos.....	5
1.5. Metodología.....	6
CAPÍTULO 2 .....	10
MARCO TEÓRICO.....	10
2.1. Computación en la nube .....	10
2.2. Minería de datos .....	11
2.3. Sistema de recomendaciones.....	16
CAPÍTULO 3 .....	22
DEFINICIÓN DE LA SITUACIÓN ACTUAL Y DEFINICIÓN DE.....	
REQUERIMIENTOS.....	22
3.1. Definición de la situación actual .....	22
3.2. Levantamiento de información del proceso actual .....	23
3.3. Levantamiento de requerimientos funcionales .....	27
3.4. Definición del proceso mejorado.....	27
3.5. Alcance del proyecto .....	29

CAPÍTULO 4 .....	31
ELABORACIÓN DEL MODELO DE RECOMENDACIÓN DE PRODUCTOS .....	31
4.1. Análisis de variables .....	31
4.2. Diseño del modelo .....	35
4.3. Configuración de los servicios de Microsoft Azure .....	36
4.4. Procesamiento de datos .....	44
4.5. Evaluación del modelo.....	47
4.6. Integración del modelo con el punto de venta.....	60
CAPÍTULO 5 .....	62
PRUEBAS Y ANÁLISIS DE RESULTADOS .....	62
5.1 Pruebas internas.....	62
5.2 Pruebas en locales .....	64
5.3 Plan de implementación.....	64
5.4 Evaluación de resultados .....	65



CONCLUSIONES Y RECOMENDACIONES .....	70
BIBLIOGRAFÍA .....	72
GLOSARIO .....	77
ANEXOS .....	79

## ÍNDICE DE FIGURAS

Figura 1.1.- Modelo del sistema .....	5
Figura 2.1.- Esquema de funcionamiento básico de un sistema .....	
recomendador .....	19
Figura 3.1.- Definición del proceso actual.....	25
Figura 3.2.- Definición del proceso mejorado .....	29
Figura 4.1.- Preferencias del cliente según el local.....	31
Figura 4.2.- Peticiones de otros clientes .....	32
Figura 4.3.- Productos más vendidos .....	34
Figura 4.4.- Restauración base de datos e10022, base inicial .....	37
Figura 4.5.- Proyecto de integration services.....	38
Figura 4.6.- Tarea a ejecutar en sql.....	38
Figura 4.7.- Sentencia de la tarea .....	39

Figura 4.8.- Proyecto de integration services origen y destino de la información.....	39
Figura 4.9.- Conexión de origen customers .....	40
Figura 4.10.- Conexión a la base del data warehouse, tesis_dm.....	41
Figura 4.11.- Tareas sin novedades .....	41
Figura 4.12.- Proyecto ejecutado correctamente .....	42
Figura 4.13.- Creación del paquete .....	43
Figura 4.14.- Procesamiento de datos .....	44
Figura 4.15.- Pasos para crear nuevo proyecto. Parte 1 .....	47
Figura 4.16.- Pasos para crear nuevo proyecto. Parte 2 .....	48
Figura 4.17.- Pasos para la creación de la vista. Parte 1 .....	48
Figura 4.18.- Pasos para la creación de la vista. Parte 2.....	49
Figura 4.19.- Pasos para la creación de la vista. Parte 3.....	49
Figura 4.20.- Pasos para la creación de la vista. Parte 4.....	50

Figura 4.21.- Pasos para la creación de la vista. Parte 5.....	50
Figura 4.22.- Pasos para la creación de la vista. Parte 6.....	51
Figura 4.23.- Pasos para la creación de la vista. Parte 7.....	51
Figura 4.24.- Pasos para la creación de la estructura de minería. Parte 1.	52
Figura 4.25.- Pasos para la creación de la estructura de minería. Parte 2.	53
Figura 4.26.- Pasos para la creación de la estructura de minería. Parte 3.	53
Figura 4.27.- Pasos para la creación de la estructura de minería. Parte 4.	54
Figura 4.28.- Pasos para la creación de la estructura de minería. Parte 5.	55
Figura 4.29.- Pasos para la creación de la estructura de minería. Parte 6.	56
Figura 4.30.- Pasos para la creación de la estructura de minería. Parte 7.	57
Figura 4.31.- Pasos para la creación de la estructura de minería. Parte 8.	57
Figura 4.32.- Pasos para la creación de la estructura de minería. Parte 9.	58
Figura 4.33.- Listado de estructura de minería de datos.....	59
Figura 4.34.- Modelo de minería de datos .....	59

Figura 4.35.- Ejecución de estructura de minería de datos .....	60
Figura 4.36. Proyección o evaluación del producto por cliente .....	61
Figura 5.1.- Resultados de consulta en powerbi por cliente Edwin Terán..	63
Figura 5.2.- Resultados del plan de implementación .....	64
Figura 5.3.- Resultados del modelo de recomendación de productos.....	65
Figura 5.4.- Productos comprados en la transacción .....	65
Figura 5.5.- Productos comprados en la transacción .....	66
Figura 5.6.- Productos comprados en la transacción .....	67
Figura 5.7.- Productos comprados en la transacción .....	67
Figura 5.8.- Análisis de la eficacia del modelo de recomendación de .....	
productos .....	68
Figura 5.9.- Análisis de la eficacia del modelo de recomendación de .....	
productos .....	69
Figura 5.10.- Instalación de sql server 2017 parte 1 .....	79

Figura 5.11.- Instalación de sql server 2017 parte 2 .....	79
Figura 5.12.- Instalación de sql server 2017 parte 3 .....	80
Figura 5.13.- Instalación de sql server 2017 parte 4 .....	80
Figura 5.14.- Instalación de sql server 2017 parte 5 .....	80
Figura 5.15.- Instalación de sql server 2017 parte 6 .....	81
Figura 5.17.- Instalación de sql server 2017 parte 8 .....	82
Figura 5.18.- Instalación de visual ssdt parte 1 .....	82
Figura 5.19.- Instalación de visual ssdt parte 2.....	83
Figura 5.20.- Resultado de la proyección del modelo parte 1 .....	83
Figura 5.21.- Resultado de la proyección del modelo parte 2 .....	84
Figura 5.22.- Resultado de la proyección del modelo parte 3 .....	84
Figura 5.23.- Resultado de la proyección del modelo parte 4 .....	85
Figura 5.24.- Resultado de la proyección del modelo parte 5 .....	85
Figura 5.25.- Resultado de la proyección del modelo parte 6 .....	86

Figura 5.26.- Resultados de la proyección del modelo parte 7 .....86

## ÍNDICE DE TABLAS

Tabla 1.- Preferencias del cliente según el local.....	32
Tabla 2.- Peticiones de otros clientes.....	33
Tabla 3.- Productos más vendidos .....	34
Tabla 4.- Productos consumidos por el cliente.....	35
Tabla 5.- Producto consumidos por el cliente .....	63



## INTRODUCCIÓN

La incorporación y desarrollo de nuevas tecnologías ha producido enormes cambios en la calidad de vida o calidad de atención al cliente, convirtiéndose en una herramienta primordial en muchos aspectos y áreas, tanto de venta como de compras para cada individuo, permitiendo así realizar ventas de manera más eficaz resolviendo y facilitando procesos que antes demoraban horas o generaban grandes colas para una atención respectiva.

Es por eso que en la actualidad es muy importante y responsable por parte de los empleadores sacar al máximo provecho a todo lo que ofrece las herramientas tecnológicas que existen para modelar y examinar grandes cantidades de datos, por lo que se debería realizar la implementación de mejoras en los procesos, es decir una automatización de los mismos, aplicando corrección de problemas de tiempo y satisfacción al cliente.

Este proyecto se realizará con la finalidad de brindar a los usuarios una información automatizada con sugerencias seguras con respecto a los datos en el módulo de ventas de caja o punto de venta donde opera la cajera de la tienda, incluyendo el análisis de los datos y entrega de resultado al punto de venta.

## **CAPÍTULO 1**

### **GENERALIDADES**

#### **1.1. Antecedentes**

Se menciona que existe un estudio relacionado al comportamiento del consumidor relacionado en las técnicas de la minería de datos titulado: "DATA MINING TECHNIQUES: A SOURCE FOR CONSUMER BEHAVIOR ANALYSIS, el cual fue elaborado por un departamento de ciencias de la computación de Vivekanand College en la India.

El estudio explica que para la aplicación de datos es considerable escoger el modelo adecuado para la obtención de resultados certeros.

Además, menciona que el conocimiento que se genera con técnicas de minería de datos es útil en la toma de decisiones del negocio y es importante para la asociación de la compra del cliente con la compra de productos determinados y de esta manera saber el cambio a determinadas marcas de producto lo cual logra la satisfacción de sus necesidades ya que los hábitos están estudiados previamente.

La conclusión es que la minería de datos nos ayuda en el estudio o investigación del comportamiento de compra de los clientes en retails, además hay hábitos de compra que se pueden tomar como referencia para el ofrecimiento de nuevas alternativas y poder retenerlo.

En el documento "Know your buyer: A predictive approach to understand online buyers' behavior By Sandip Pal" [1], se investiga al cliente en el comercio electrónico y se llega a la conclusión que millones de compradores visitan sitios electrónicos que comercializan productos para todo tipo de necesidades, pero pocas personas llegan a comprar dichos productos, entonces, la minería de datos puede ser aplicada para lograr convertir los visitantes en compradores.

El objetivo de estudio es Implementar un modelo de recomendación de productos aplicando minería de datos para la mejora del proceso de atención al cliente en una empresa de comida rápida de consumo masivo, el cual está basado en el historial de compras del cliente y en transacciones similares de otros clientes.

## **1.2. Descripción del problema**

La comercialización de productos o servicios en cualquier categoría del mercado es de mucha importancia en nuestro país, en especial de los restaurantes de comida rápida debido a que esta actividad crece cada vez más y por ende se vuelve más competitivo ya que se ofrece muchas veces el mismo producto en diferentes restaurantes.

Los tiempos de atención al cliente de la empresa generalmente son muy demorados, esto es debido a la indecisión de los clientes al momento de hacer el pedido en la caja y la gran afluencia de clientes sin importar el horario ni la localidad.

Además, debido al gran número de transacciones que se realiza diariamente se puede analizar que la mayoría tienen gran similitud en sus ítems, lo cual genera pérdida de tiempo en la atención al cliente al momento de ingresar una y otra vez el mismo pedido a diferentes clientes.

Los clientes nuevos, debido a que nunca han comprado en el local tienden a demorarse y mostrar mucha indecisión al momento de hacer un pedido y en algunas ocasiones deciden no comprar, perdiendo la empresa la oportunidad de venta y de captar a un nuevo cliente.

## **1.3. Solución propuesta**

El desarrollo de este proyecto tiene como objetivo principal diseñar e implementar un Modelo de Análisis Predictivo que permita sugerir al cliente

los productos o servicios que necesite en base a las transacciones que haya realizado con anterioridad y/o que tengan similitud a los productos o servicios que otros clientes suelen realizar.

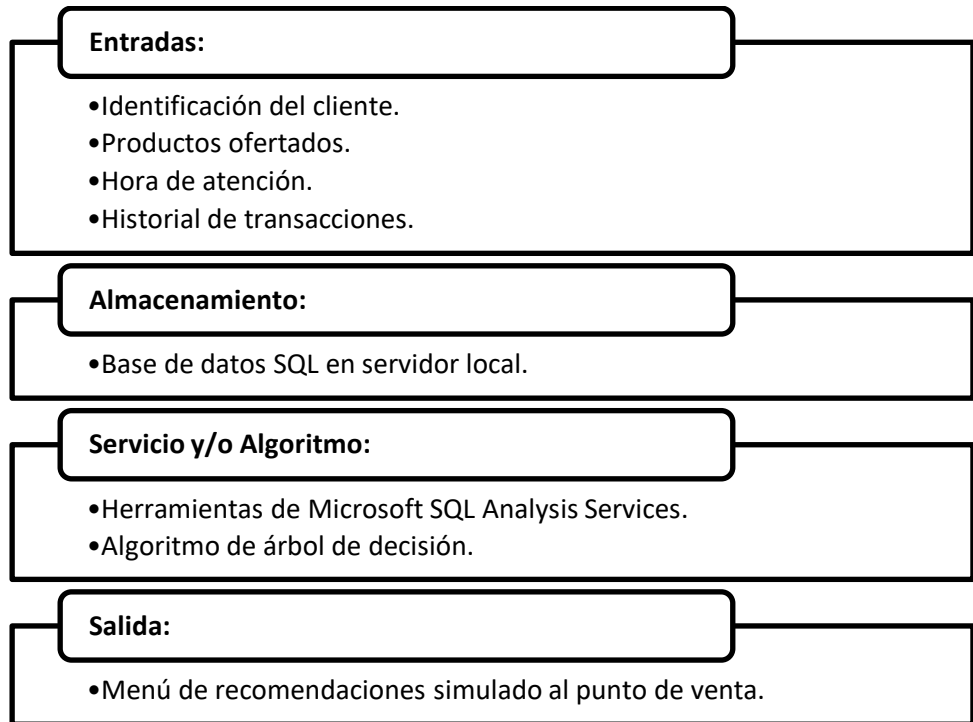
En el modelo de recomendación se utilizará las herramientas de Microsoft SQL Analysis Services que sirven para modelar y examinar grandes cantidades de datos para el análisis de datos ad hoc, además de Minería de Datos para explorar cantidades de datos de manera automática o semiautomática con el objetivo de encontrar patrones repetitivos que expliquen el comportamiento de los datos, usando el algoritmo de reglas de asociación que sirve para detectar que productos se adquieren juntos o que eventos se producen juntos para crear recomendaciones y así poder tomar decisiones estratégicas y mejorar la eficiencia operativa.

Para la realización del modelo se analizará data de 3 años de antigüedad a la fecha actual, la cual contiene aproximadamente 77.701 registros de clientes, 48.3850 registros de transacciones y alrededor de 104 productos. Las variables de entrada para el análisis y realización del modelo son "identificación del cliente" versus "productos" y "hora", lo cual nos da como resultado un menú de sugerencias para cada cliente. Cabe recalcar que la identificación del cliente va a ser por medio de reconocimiento biométrico.

La solución propuesta influiría de tal manera que el cliente al llegar a hacer su pedido, el cajero le pedirá su número de cédula y lo ingresará al software que utiliza la empresa, el cual le recomendará productos en base a su

historial de compras y también en base a compras relacionadas realizadas por otros clientes.

El modelo por utilizar sería el siguiente:



**Figura 1.1.-** Modelo del Sistema

#### 1.4. Objetivos

##### Objetivo general

Implementar un modelo de recomendación de productos aplicando minería de datos para la mejora del proceso de atención al cliente en una empresa de comida rápida de consumo masivo.

##### Objetivos específicos

- Diagnosticar la situación actual del problema a resolver.
- Determinar principales fundamentos teóricos y metodológicos que sustentan el tema.
- Diseñar un modelo de recomendación de productos que permita sugerir las preferencias de los clientes, soportado por las herramientas de Microsoft SQL Analysis Services.
- Aplicar las herramientas de Microsoft SQL Analysis Services para que permitan la implementación del modelo de recomendación de productos.
- Evaluar el resultado del modelo de recomendación de productos en el proceso de atención al cliente de la empresa de comida rápida de consumo masivo.

### **1.5. Metodología**

La presente investigación tiene carácter mixto cuantitativo y cualitativo, dado que se aborda la temática desde un análisis cualitativo en la recolección bibliográfica documental de la teoría que atañe al problema de investigación, mientras que el desarrollo del trabajo adopta un enfoque cuantitativo en la ejecución de los algoritmos que serán objeto de la propuesta, además el estudio adopta un enfoque de campo analizando la información necesaria para realizar el modelo de recomendación de productos, mediante la verificación de los hechos y los actores del problema, con el fin de conocer de forma objetiva la realidad de la situación, para el desarrollo en la investigación se aplican una serie de técnicas y herramientas inherentes de las TICs, como el Business Intelligence, Microsoft SQL y la minería de datos.

De tal forma que se analizan varios factores que permiten adoptar la minería de datos desde Microsoft SQL.

- Análisis de la flexibilidad y rapidez de adaptación de las soluciones brindadas por Microsoft SQL.
- Análisis del algoritmo de árbol de decisión para la minería de datos.

Cuando se hace mención a la aplicación de un sistema de minería de datos, hay que referirse a las reglas de asociación, mismas que permiten el establecimiento de las posibles correlaciones o relaciones entre sucesos que aparentan no tener relación que pueden inducir la aparición de otros sucesos derivados [2].

En [29], artículo el cual menciona que: Un árbol de decisión es un algoritmo de predicción cuyo objetivo principal es el aprendizaje inductivo a partir de observaciones y construcciones lógicas. Son muy similares a los sistemas de predicción basados en reglas, que sirven para representar y categorizar una serie de condiciones que suceden de forma sucesiva para la solución de un problema. Constituyen probablemente el modelo de clasificación más utilizado y popular. El conocimiento obtenido durante el proceso de aprendizaje inductivo se representa mediante un árbol. Un árbol gráficamente se representa por un conjunto de nodos, hojas y ramas [29].

En el proyecto tenemos la base de datos del ERP la cual se filtra y esos datos van a otra base de datos, la información que nos entrega es la crucial para la toma de decisiones, información como: los productos, facturas, locales, sucursales, todo ello alimenta a una tabla con ella es que se alimenta el Data Warehouse ya que éstos son los datos de entrada a la



minería de datos, después se selecciona los datos de entrada seleccionando el modelo el cual es el árbol de decisiones.

Un algoritmo de generación de árboles de decisión consta de 2 etapas: la primera corresponde a la inducción del árbol y la segunda a la clasificación. En la primera etapa se construye el árbol de decisión a partir del conjunto de entrenamiento; comúnmente cada nodo interno del árbol se compone de un atributo de prueba y la porción del conjunto de entrenamiento presente en el nodo es dividida de acuerdo con los valores que pueda tomar ese atributo. La construcción del árbol inicia generando su nodo raíz, eligiendo un atributo de prueba y dividiendo el conjunto de entrenamiento en dos o más subconjuntos; para cada partición se genera un nuevo nodo y así sucesivamente. Cuando en un nodo se tienen objetos de más de una clase se genera un nodo interno; cuando contiene objetos de una clase solamente, se forma una hoja a la que se le asigna la etiqueta de la clase. En la segunda etapa del algoritmo cada objeto nuevo es clasificado por el árbol construido; después se recorre el árbol desde el nodo raíz hasta una hoja, a partir de la que se determina la membresía del objeto a alguna clase. El camino a seguir en el árbol lo determinan las decisiones tomadas en cada nodo interno, de acuerdo con el atributo de prueba presente en él [29].

Con el árbol de decisiones se estiman riesgos, costos, beneficios y así mismo múltiples opiniones en el modelo, comparando alternativas antes la acción de comprar una comida desde un consumidor con su decisión ya sea específica o no el modelo llega a su objetivo el cual es la recomendación de

productos implementando la minería de datos para mejorar del proceso de atención al cliente en una empresa de comida rápida que tiene una masiva demanda.

## **CAPÍTULO 2**

### **MARCO TEÓRICO**

#### **2.1. Computación en la nube**

La computación en la nube consiste en los servicios que se ofrece a través del internet o también llamada red, tales como, el almacenamiento, correos electrónicos, uso de aplicaciones de almacenamiento de datos, etc., estos son normalmente accesibles mediante datos en un navegador web a través del internet, estas son procesadas y ejecutas [9]. Aguilar manifiesta, que “es la evolución de un conjunto de tecnologías que afectan al enfoque de las organizaciones y empresas en la construcción de su infraestructura de TI. Al igual que ha sucedido con la evolución de la web, con la web 2.0 y la web semántica, la computación en nube no incorpora nuevas tecnologías. Se

han unido tecnologías potentes e innovadoras, para construir este nuevo modelo y arquitectura de la web” [1].

Lo que este concepto indica, es que la computación a través de internet es el desarrollo de la tecnología que utilizan las empresas para innovar sus procesos y valerse de las herramientas que esta proporciona y así estar a la vanguardia del mundo globalizado y ser competitivo en el mercado.

## 2.2. Minería de datos

Hay que entender que a la minería de datos se la podría denominar una tecnología que ha sido un buen punto de encuentro entre personas pertenecientes al ámbito académico y al de los negocios, la misma que está compuesta por etapas que integran varias áreas y que no se debe confundir con un gran software; por lo cual se podría decir que: “La minería de datos es el análisis de archivos y bitácoras de transacciones, las mismas que trabajan a nivel del conocimiento con el fin de descubrir patrones, relaciones, reglas, asociaciones o incluso excepciones útiles para la toma de decisiones” [18].

**Algoritmo de asociación.** - Un algoritmo en minería de datos comprende un grupo de “heurísticas y cálculos que permiten crear un modelo a partir de datos” [19]. La minería de las reglas de asociación ha sido generalmente aplicada al área de los negocios en especial a las tiendas minoristas [5]. El modelo de minería de datos que crea un algoritmo a partir de los datos puede tomar diversas formas, entre las que se incluyen:

- Un conjunto de clústeres que describe cómo se relacionan los casos de un conjunto de datos.
- Un árbol de decisión que predice un resultado y que describe cómo afectan a este los distintos criterios.
- Un modelo matemático que predice las ventas.
- Un conjunto de reglas que describen cómo se agrupan los productos en una transacción, y las probabilidades de que dichos productos se adquieran juntos [19].

**Algoritmo de árbol de decisión.** - Este algoritmo funciona con predicciones basadas en las “relaciones entre las columnas de entrada de un conjunto de datos. Utiliza los valores, o estados, de estas columnas para predecir los estados de una columna que se designa como elemento de predicción” [20].

Sin embargo, se va a utilizar únicamente el algoritmo de árboles de decisión ya que aplica más al retail [20] y se puede usar en la herramienta Microsoft SQL Analysis Server.

### **Metodologías en la aplicación de minería de datos**

Según [21] existen varios tipos de metodologías para la minería de datos, por lo que se expone las siguientes:

**El Proceso KDD.** - Sus siglas en inglés provienen de Knowledge Discovery in Databases. Es un proceso que usa métodos de Data Mining (DM) para extraer conocimiento, utilizando una base de datos junto con cualquier pre

procesamiento, sub-muestreo y transformación requeridos de la base de datos. La KDD es un término que se confunde muy comúnmente con la minería de datos. KDD es un proceso que consta de una serie de fases mientras que la minería de datos es solo una de esas fases [22]. Se consideran cinco etapas:

- 1) Selección - Esta etapa consiste en crear un conjunto de datos objetivo, o enfocarse en un subconjunto de variables o muestras de datos, en las que se debe realizar el descubrimiento.
- 2) Procesamiento previo - Esta etapa consiste en la limpieza y preprocesamiento de datos de destino para obtener datos consistentes.
- 3) Transformación - Esta etapa consiste en la transformación de los datos usando métodos de reducción de dimensionalidad o transformación.
- 4) Minería de Datos - Esta etapa consiste en la búsqueda de patrones de interés en una forma representacional particular, dependiendo del objetivo de minería de datos (por lo general, la predicción).
- 5) Interpretación / Evaluación - Esta etapa consiste en la interpretación y evaluación de los patrones.

***El proceso CRISP-DM.*** - Sus siglas en inglés provienen de Cross Industry Standard Process For Data Mining, es un proceso capaz de estructurar el ciclo de vida de un proyecto en seis fases, que interactúan entre ellas de forma iterativa durante el desarrollo. Es de libre distribución y permite

trabajar con cualquier herramienta para el desarrollo del proyecto [23]. Las fases son las siguientes:

- 1) **Comprensión del negocio** - Esta fase inicial se centra en la comprensión de los objetivos del proyecto y los requisitos desde una perspectiva de negocio, a continuación, convertir este conocimiento en una definición de problema de minería de datos y un plan preliminar diseñado para lograr los objetivos.
- 2) **Comprensión de los datos** - La fase de comprensión de los datos comienza con una recopilación inicial de datos y prosigue con las actividades para familiarizarse con los datos, identificar problemas de calidad de los datos, descubrir los primeros datos o detectar subconjuntos interesantes para formar hipótesis para Información oculta.
- 3) **Preparación de datos** - La fase de preparación de datos abarca todas las actividades para construir el conjunto de datos final a partir de los datos iniciales sin procesar.
- 4) **Modelado** - En esta fase, se seleccionan y aplican diversas técnicas de modelado y se calibran sus parámetros a valores óptimos.
- 5) **Evaluación** - En esta etapa el modelo o modelos obtenidos se evalúan más a fondo y se revisan los pasos ejecutados para construir el modelo para asegurarse de que alcanza adecuadamente los objetivos de negocio.
- 6) **Implementación** - La creación del modelo generalmente no es el final del proyecto. Incluso si el propósito del modelo es aumentar el

conocimiento de los datos, el conocimiento adquirido deberá ser organizado y presentado de manera que el cliente pueda utilizarlo.

Dado que se necesita de un proceso flexible al cliente se selecciona el proceso KDD, además de su aplicación a través de cualquier herramienta.

### **Herramientas para Análisis de Datos**

- Analysis Services es un motor de datos analíticos (Vertipaq) que se usa en la ayuda para la toma de decisiones y el análisis empresarial. Proporciona funcionalidades de modelo de datos semánticos de nivel empresarial para Business Intelligence (BI), análisis de datos y aplicaciones de informes como Power BI, Excel, Reporting Services y otras herramientas de visualización de datos. Analysis Services está disponible en distintas plataformas [25].
- SQL Server Analysis Services: instalado como una instancia de servidor de VM o local, SQL Server Analysis Services admite modelos tabulares en todos los niveles de compatibilidad (dependiendo de la versión), modelos multidimensionales, minería de datos y Power Pivot para SharePoint.
- Power BI Premium (versión preliminar): el motor Vertipaq de Analysis Services proporciona capacidad de programación, aplicación cliente y herramientas para Power BI Premium conjuntos de valores en los niveles de compatibilidad 1500 y superior a través de las bibliotecas de cliente y las API que admiten el protocolo XMLA Open-Standard. Power BI Premium conjuntos de valores admiten



conexiones a través de extremos XMLA para operaciones de solo lectura y de lectura y escritura de Microsoft y herramientas y aplicaciones cliente de terceros. Para obtener más información, consulte Analysis Services en Power BI Premium y Power BI Premium Conectividad del conjunto de información con el punto de conexión XMLA.

En conclusión, al tratarse de procesamiento masivo y que se requiere velocidad, se ha seleccionado SQL Analysis Services.

### **2.3. Sistema de recomendaciones**

En general se definiría como una base de datos en la cual se almacena cada evento que se refiere a una actividad, y se relaciona con un caso particular por lo que algunas técnicas de minería hacen uso de este tipo de información, tales como, la persona o recursos relacionados con el evento, el tiempo de ejecución o cualquier otro tipo de dato que pueda registrarse [26].

Para lo cual este sistema debería almacenar la información de los clientes, así como de sus pedidos anteriores, lo que permitirá facilitar esta información en futuras ocasiones.

Los sistemas de recomendaciones (SR) surgen “como una poderosa alternativa; este tipo de sistemas aplican técnicas de búsqueda y filtrado de información para proporcionar a los usuarios sugerencias personalizadas sobre un conjunto de ítems en un dominio específico” [27].

Ocampo Botello, Felipe Durán y de Luna Caballero, [28] manifiestan que los sistemas inteligentes para la personalización de usuarios en la web se han vuelto una herramienta muy poderosa para predecir las necesidades de los usuarios que navegan en Internet. Una vez que un usuario tiene un perfil personalizado puede ser ayudado a buscar la información en internet de acuerdo a sus gustos y necesidades. Con ese perfil, el usuario de la web puede ser apoyado por los administradores del sitio que visita, para ir directamente a la información, servicio o producto que está buscando y obtenerlo de forma más rápida y, sobre todo, eficiente.

Por esta razón se han desarrollado varios sistemas de remuneración, encaminado siempre a la mejora de las operaciones de las empresas.

Algunos de estos sistemas tienen sus bases en datos históricos de los usuarios ya sea de manera directa o indirecta. Otros sistemas se basan en información reciente que proporciona el usuario y con ello se pretende establecer algunas sugerencias más certeras sobre productos y servicios.

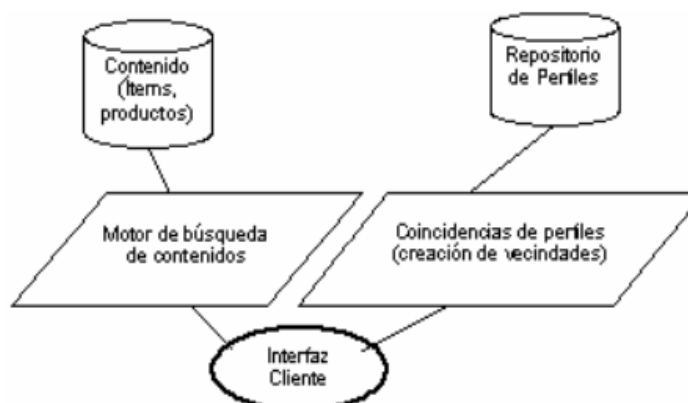
Por ello Ocampo Botello, Felipe Durán, de Luna Caballero [28] sugieren considerar los siguientes aspectos en los sistemas de recomendación:

- Recomendadores colaborativos
- Recomendadores basados en contenido
- Recomendadores basados en conocimiento
- Recomendadores híbridos

Desde la perspectiva de Vélez Langs y Santos, [28], los sistemas de recomendación buscan estar por delante de la recuperación tradicional de la información, además:

Como su nombre nos lo indica los SR se encargan de recomendar o sugerir a los usuarios ítems o productos concretos basándose en sus preferencias, son usados por sitios web de comercio electrónico como herramientas de mercadeo para incrementar ventas al presentar al usuario aquellos productos que desea (o desearía) comprar, es así como se construye una base de entendimiento de necesidades concretas respecto a lo que gusta o no a los clientes, lo cual puede verse reflejado en un incremento de la lealtad de los clientes. La gran mayoría de los SR trabajan con enfoques de filtrado colaborativo, en términos simples, por filtrado colaborativo se entiende al método de hacer predicciones automáticas (filtrado) acerca de los intereses de un usuario, colectando información sobre los gustos de varios usuarios (colaboración).

Para una comprensión más acertada del funcionamiento de los sistemas de recomendación, se ilustra su esquema en el siguiente gráfico:



**Figura 2.1.-** Esquema de funcionamiento básico de un Sistema Recomendador

Tomado de “Sistemas Recomendadores: Un enfoque desde los algoritmos genéticos” por Vélez Langs, Oswaldo; Santos, Carlos [17]

Esta herramienta no es únicamente aplicable a negocios online, o a empresas comercializadoras, sino también a empresas y a personas que ofrecen servicios; capacitaciones o entrevistas de trabajo, centros médicos, consultorios jurídicos, entre otros.

### **Sistemas de recomendación de datos basados en árboles de decisiones**

#### *Sistema de pronóstico de ventas de productos en la empresa kanga*

Kanga es una empresa que según [29] se dedica a la venta de artículos todo tipo de artículos al por mayor y por menos en la ciudad de Lima – Perú que con el tiempo pasó a ser un minimarket y realizar no solo venta de artículos si no a brindar servicios como el alquiler de camionetas, maquinarias pesadas, etc. Este proyecto tuvo como objetivo:

- Identificar la situación inicial de la empresa KanQa en el área de Ventas.
- Desarrollar un sistema de pronóstico de ventas utilizando árboles de decisiones.
- Aplicar el Sistema de pronóstico de ventas en la empresa

En [29] se pudo obtener mediante arboles de decisión, las diferentes probabilidades de ventas según el día de las categorías de productos que se ofrece. Por último, generaron el reporte de indicadores para que la Gerencia pueda realizar las diferentes decisiones estratégicas para la mejora de las ventas.

*Sistema experto para apoyar el proceso de toma de decisiones en los casos de pensión alimenticia en la ciudad de Chiclayo*

Sistema el cual hará uso de un lenguaje en .Net y el gestor de base de datos SQL Server, lo cual es de suma importancia ya que la interfaz gráfica del sistema experto será web y será desarrollada con el lenguaje de .Net [30] nos indica que:

“La pensión de alimentos hoy en día es un problema muy común, ya que a nuestro alrededor encontramos a familias disfuncionales y muchas de ellas no reciben un sustento para la manutención de sus hijos. Existen casos donde muchos de ellos llegan a conciliar para de una u otra manera reciban una pensión mensual para solventar las necesidades del menor, sin embargo, no siempre el monto que las madres reciben es el adecuado para cubrir todas las necesidades del menor, ya que por conocimiento propio el dinero obtenido solo alcanza para la alimentación del menor, dejando de lado el vestido, diversión, educación y vivienda.”

A continuación, se describen algunos objetivos específicos del mismo:

- Lograr al reconocer el conjunto de reglas que se encuentran dentro del Código Penal y la Constitución Política del Perú, las cuáles son relacionadas a los casos de la Constitución Política.
- Elegir el algoritmo de acuerdo con el método de árbol de decisión que permita apoyar el proceso de toma de decisiones en los casos de pensión alimenticia.
- Desarrollar un sistema experto que contenga el algoritmo elegido para apoyar el proceso de toma de decisiones.
- Demostrar que el sistema experto funciona correctamente de acuerdo con las reglas que tiene el algoritmo.

Según [30] logró implementar el sistema experto, el cual permitió apoyar el proceso de toma de decisiones en los casos de la pensión de alimentos, el cual será de mucha utilidad para los abogados, jueces o profesionales que se encarguen de resolver este tipo de casos. Tal como se menciona hoy en día los aplicativos son importantes y necesarios para las entidades, ya que les agiliza el tiempo en el que los casos son resueltos y los ayuda a tomar decisiones.

## **CAPÍTULO 3**

### **DEFINICIÓN DE LA SITUACIÓN ACTUAL Y DEFINICIÓN DE REQUERIMIENTOS**

#### **3.1. Definición de la situación actual**

Los establecimientos de comida rápida se caracterizan por suministrar alimentos de rápida elaboración en los que el consumidor suele hacer el papel de camarero, es decir, se acerca a la caja, solicita su pedido y lo traslada hasta la mesa, lo cual en ciertas ocasiones desencadena en dos factores que convierte en deficiente al proceso de compra: lentitud en la atención al cliente, indecisión al momento de escoger los productos.

No atender a un cliente de forma eficiente ocasiona un efecto dominó ya que los demás que estaban haciendo fila sufren el mismo problema al ser atendidos. Se han intentado un sinnúmero de mejoras en el procedimiento manual por ejemplo colocar anuncios con combos sugeridos de acuerdo a la opinión del gerente de cada local, o entregar volantes mostrando combos de bajos precios. Todas estas iniciativas no han logrado disminuir los tiempos de atención.

Se han agregado otro tipo de soluciones tecnológicas como la venta en línea por medio de celulares a través de terceros como Uber Eats, etc, pero el mercado actual aún está en crecimiento. Se han cambiado los equipos para que se vuelvan táctiles reemplazando la digitación por teclado, esto aumenta la velocidad de ingreso de datos por parte del cajero, pero el cuello de botella sigue siendo el cliente indeciso.

Cualquier de las iniciativas realizadas no ha podido disminuir el tiempo en el que cliente realiza el pedido, el gerente de la empresa esta consiente que disminuir los tiempos de atención permitirá incrementar los ingresos aumentando la cantidad de clientes por la excelente calidad de atención percibida, por lo tanto, están dispuestos a invertir en el uso de nuevas tecnologías de la información basadas en estadísticas.

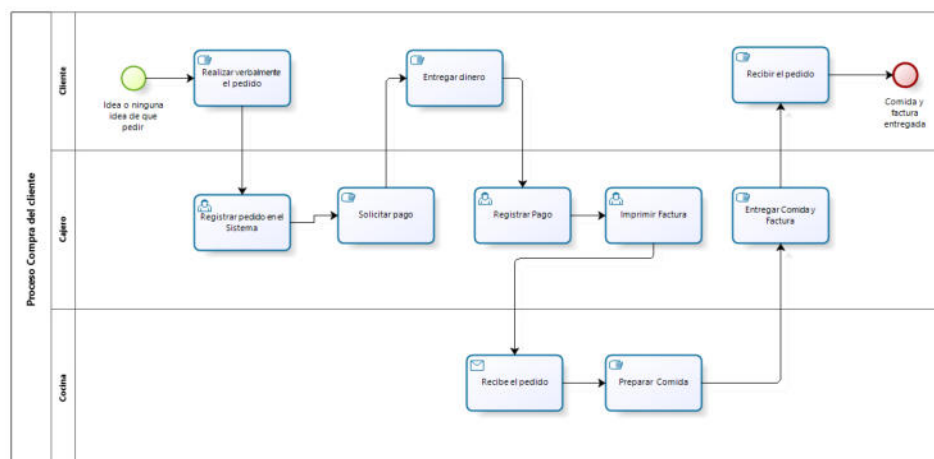
### **3.2. Levantamiento de información del proceso actual**

Durante el análisis de un mes se pudo observar y recabar información sobre varios aspectos del proceso:



1. El proceso de compra del cliente inicia con la idea o ninguna de que pedir al momento de hacer la cola. Lo único que sabe el cliente es que quiere comprar comida rápida, deliciosa y en algunos casos repetir la última orden sin conocer los nuevos productos.
2. El cliente realiza verbalmente el pedido al cajero tomándose su tiempo en caso de que no tenga idea de que pedir o que tenga muchas opciones en los letreros que confunden y toma tiempo su elección.
3. El cajero registra el pedido en el sistema, incluso algunas veces recomendado al cliente que comprar y/o avisando sobre nuevas promociones.
4. El cajero solicita el pago de la orden una vez que el cliente termina de seleccionar los productos.
5. El cliente entrega el dinero ya sea en efectivo, tarjeta de débito o crédito al cajero.
6. El cajero registra el pago, si es necesario da vuelto e imprime la factura.
7. El área de cocina recibe el pedido, el cual queda en la lista de espera.
8. El área de cocina prepara el pedido siguiente y una vez termina entrega al área de cajeros.
9. El Cajero disponible recibe la comida y junto con la factura previamente impresa llama y entrega al cliente.
10. El cliente recibe el pedido y factura finalizando el proceso de la compra.

Se desarrolló el siguiente diagrama de procesos actual donde constan las actividades anteriormente descritas:



**Figura 3.1.-** Definición del proceso actual

Nota: Realizar verbalmente el pedido: Esta actividad toma más de 5 minutos en promedio ya que el cliente pregunta sobre los productos o toma su tiempo para recordar lo que ha consumido anteriormente. En el caso de clientes nuevos el tiempo suele duplicarse.

Como ejemplo de las demoras tenemos los siguientes casos:

- **Caso 1.-** El cliente Antonio Pérez (nombre ficticio para proteger el nombre real) llegó a las 10 am, no había fila, pero se tomó 6 minutos para elegir los productos que iba a consumir, esto se debió a que inicialmente el pedido que había hecho fue una hamburguesa mixta con papitas y cola, a pesar de que el cajero comunicó lo mejor que pudo sobre las promociones del día el cliente este no pudo decidirse

rápidamente. Finalmente terminó agregado a su combo uno de los productos que hace varios días había consumido.

- **Caso 2.-** El cliente Ana Alvarado (nombre ficticio para proteger el nombre real) llegó a las 19:00, había una fila de 4 personas que estaban esperando a que el cliente en la caja termine de hacer su pedido, el ritmo de atención fue de 10 minutos, 8 minutos, 5 minutos y 4 minutos. Los tres primeros clientes se tomaron su tiempo para elegir los combos y promociones, esto afectó al último cliente ya que este tuvo que esperar 27 minutos, provocando un gran disgusto por la espera y posiblemente la pérdida de un cliente.

Otros hallazgos mientras se levantaba el proceso actual son los siguientes:

- Los empleados brindan a sus clientes un servicio aceptable, es decir con amabilidad; sin embargo, no todos los clientes terminan satisfechos totalmente, puesto que, al tener una carta amplia con varias elecciones de compra provoca indecisión.
- No existen quejas por parte de los usuarios con respecto a la atención que reciben; los empleados no pueden dar opciones de compras a sus clientes, o a su vez las más preferidas por otros usuarios, o las opciones más vendidas, ya que los empleados no cuentan con un sistema que les permita facilitar a sus clientes opciones de compra.

- No se han analizado los datos que puedan medir tendencias de compra y predecir qué características de los clientes determinan la compra de un producto.

### **3.3. Levantamiento de requerimientos funcionales**

Los requerimientos funcionales se establecen en conjunto con los funcionarios operativos y jefes del área de ventas y marketing para asegurar que el proyecto cumpla con las expectativas de la empresa, en base a las reuniones mantenidas se propone que:

- Cuando el cliente se acerque a la ventanilla se requiere que se identifique por medio del número de cédula.
- Luego de la autenticación exitosa se muestra las recomendaciones de consumo de productos basado en sus compras anteriores y de los productos más solicitados por todos los clientes. Estas recomendaciones son el producto del análisis de datos.
- El proceso analítico de recomendaciones por cada pedido no debe superar los 3 segundos de tiempo.

### **3.4. Definición del proceso mejorado**

Se espera que una vez simulado un modelo de recomendación de productos aplicando minería de datos por medio de herramientas de Microsoft SQL para la mejora del proceso de atención al cliente, se podrá recomendar una

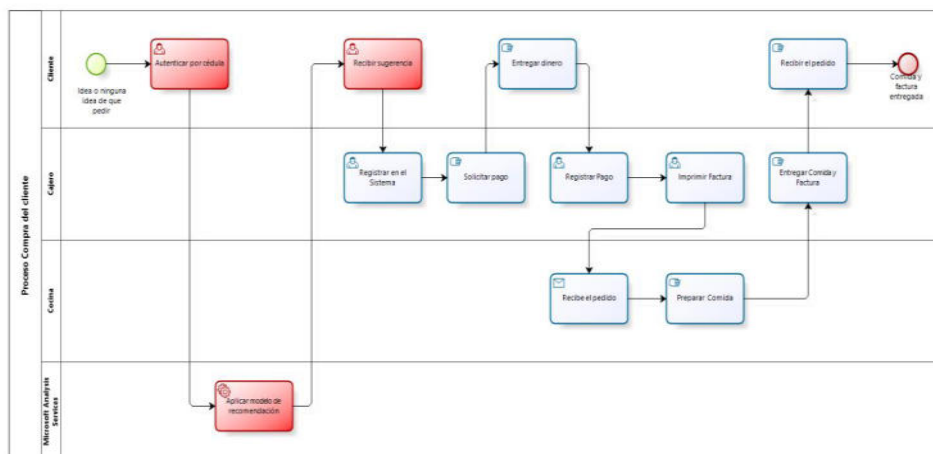
mejor opción de compra al cliente, lo que facilitará y permitirá que la compra sea rápida.

De acuerdo a los procesos actuales y a los requerimientos funcionales se han creado nuevas actividades en el proceso (en rojo) que reemplazan a la actividad realizar verbalmente el pedido y son:

- 1) Autenticar por cédula. Permite que el cliente sea reconocido por el sistema y comience su búsqueda en la base de datos.
- 2) Aplicar el modelo de recomendación. Está basado en los gustos del cliente y de otro cliente, permite seleccionar productos con una alta posibilidad de selección por parte del cliente. En la nube se ejecuta del modelo realizado en Visual Studio previamente desplegado en SQL Analysis Service que tomando como dato de entrada la fecha actual y el número de cédula ejecuta el algoritmo de Asociación que aplica las reglas del modelo y usa los datos históricos. Como resultado de esta ejecución en cuestión de segundos se obtiene una lista de productos sugeridos o recomendados que van a ser entregados al módulo de punto de venta para que sea comunicado al cliente y este tenga pueda realizar la mejor elección posible.
- 3) Recibir sugerencia. El cliente recibe la sugerencia que aparecerá en una pantalla o que será comunicada por el cajero al cliente.

El proceso no se ve afectado en las demás actividades ya que las tareas nuevas solo aplican a la interacción entre el cliente y el sistema ERP-Punto

de venta que se comunica automáticamente con el proceso automático de generación de la recomendación.



**Figura 3.2.-** Definición del proceso mejorado

Las Actividades en Rojo son necesarias para aplicar el modelo de recomendación (predicción) con lo cual disminuirá considerablemente en tiempo de realización de la compra. Esto incluye una tarea en la cual el cliente se identifica (autentica) en el sistema, se procesa los datos (aplicación del modelo de recomendación) y se presenta al cliente la recomendación (recibe en pantalla la información).

### 3.5. Alcance del proyecto

El desarrollo del proyecto comprenderá el análisis, diseño y simulación de la aplicación del análisis de datos en el módulo de ventas de caja o punto de venta donde opera la cajera de la tienda, incluyendo el análisis de los

datos y entrega de resultado por medio un servicio de SQL al punto de venta.

Cabe recalcar que para dicho análisis se utilizará la herramienta SQL Analysis Services de Microsoft SQL que sirve para modelar y examinar grandes cantidades de datos.

Se desea implementar este modelo de recomendación de productos en todas las sucursales a nivel nacional, pero en primera instancia será simulado y evaluado en las sucursales de la ciudad de Guayaquil.

## CAPÍTULO 4

### ELABORACIÓN DEL MODELO DE RECOMENDACIÓN DE PRODUCTOS

#### 4.1. Análisis de variables

##### a. Las preferencias del cliente según el local

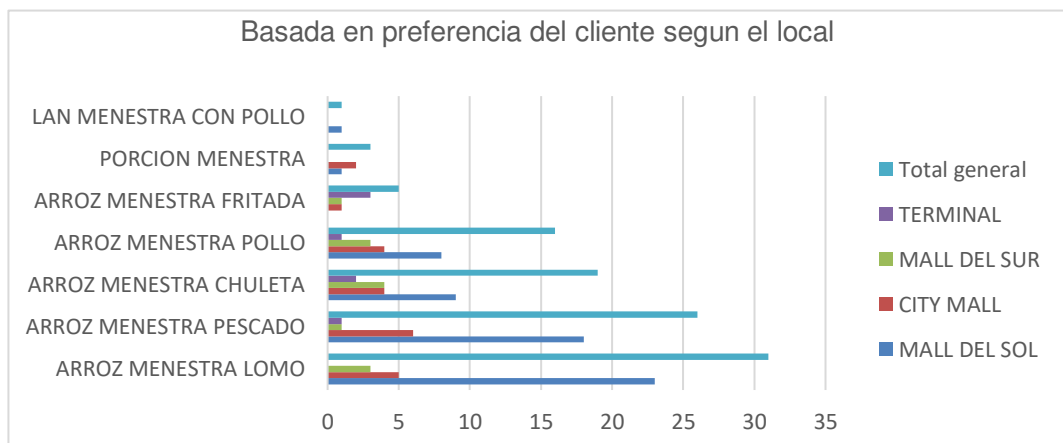


Figura 4.1.- Preferencias del cliente según el local




**Tabla 1.-** Preferencias del cliente según el local

Producto	Mall del sol	City mall	Mall del sur	Terminal	Total, general
<b>Arroz menestra lomo</b>	23	5	3		31
<b>Arroz menestra pescado</b>	18	6	1	1	26
<b>Arroz menestra chuleta</b>	9	4	4	2	19
<b>Arroz menestra pollo</b>	8	4	3	1	16
<b>Arroz menestra fritada</b>		1	1	3	5
<b>Porción menestra</b>	1	2			3
<b>Lan menestra con pollo</b>	1				1
<b>Total, general</b>	60	22	12	7	101

El análisis de este gráfico (enfocados a solo el arroz con menestra) muestra que el arroz con menestra y lomo es el más cotizado por los clientes en especial en el mall del sol dando como resultado un total de 31 pedidos, y en ese mismo lugar el mall del sol se descubre que existe un total de 60 de 101 pedidos sumando el resultado de los demás platos.

#### b. Las peticiones de otros clientes

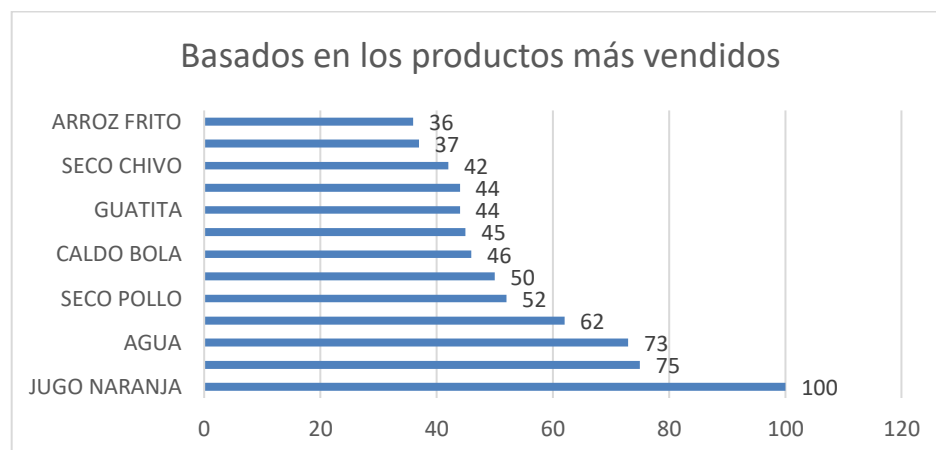
**Figura 4.2.-** Peticiones de otros clientes

**Tabla 2.-** Peticiones de otros clientes

<b>Platos</b>	<b>Sábado y Domingo</b>	<b>Lunes a viernes</b>
<b>ARROZ MENESTRA CHULETA</b>	117	195
<b>ARROZ MENESTRA LOMO</b>	122	252
<b>ARROZ MENESTRA PESCADO</b>	108	238
<b>ARROZ MENESTRA POLLO</b>	144	233
<b>CALDO BOLA</b>	397	477
<b>CALDO GALLINA</b>	287	348
<b>CALDO PATA</b>	359	384
<b>CALDO SALCHICHA</b>	270	72
<b>FRITADA</b>	169	222
<b>PESCADO FRITO</b>	138	211
<b>SECO CARNE</b>	80	182
<b>SECO CHIVO</b>	242	296
<b>SECO POLLO</b>	251	479

El análisis de este gráfico basado en lo que los otros clientes piden tomando como referencia al mall del sol en los meses de febrero a marzo. Se concluyó que el producto más cotizado es el jugo de naranja seguido de la cola coca de ½ litro con una diferencia de 19 pedidos, y en el puesto final o con el consumo mínimo de los otros clientes tenemos a dos productos los cuales son el arroz con menestra y pescado junto con el arroz con pollo apanado y puré.

**c. Basado en los productos más vendidos**



**Figura 4.3.- Productos más vendidos**

**Tabla 3.- Productos más vendidos**

<b>Producto</b>	<b>Cantidad</b>
<b>JUGO NARANJA</b>	<b>100</b>
<b>COLA COCA 1/2 LITRO</b>	<b>75</b>
<b>AGUA</b>	<b>73</b>
<b>JUGO MORA</b>	<b>62</b>
<b>SECO POLLO</b>	<b>52</b>
<b>ARROZ CON CHOCLO</b>	<b>50</b>
<b>CALDO BOLA</b>	<b>46</b>
<b>CHURRASCO MONTADO</b>	<b>45</b>
<b>GUATITA</b>	<b>44</b>
<b>CALDO GALLINA</b>	<b>44</b>
<b>SECO CHIVO</b>	<b>42</b>
<b>AGUA DASANI SIN GAS 600 ML</b>	<b>37</b>
<b>ARROZ FRITO</b>	<b>36</b>

Como notamos que en la lista de productos hay uno que sobresale mucho más que cualquier otro, y es el jugo de naranja con un total de 100 lo cual

lo coloca en primer lugar de los productos más vendidos, teniendo como diferencia un 25% con la cola coca ½ litro que es la siguiente en la lista. Esa conclusión el jugo de naranja es el producto es más vendido del restaurante.

#### 4.2. Diseño del modelo

Este modelo genera un algoritmo que nos representa las diferentes alternativas junto con los posibles resultados para cada alternativa elegida de la información, este modelo facilita mucho la comprensión de las diferentes predicciones; el árbol de decisión nos va servir sirve para abordar los problemas del stock en inventario, agilidad en venta y cercanía del cliente debido a que nos ayudará a tomar decisiones futuras.

El siguiente modelo permitirá generar las probabilidades de los productos más consumidos por Cliente, con la finalidad de generar una mejor experiencia al cliente sugiriendo el plato más consumido en esas fechas en el local que se está acercando a realizar la compra.

Las variables utilizadas son producto y nombre cliente, como métrica se utilizó la cantidad de productos consumidos, y como filtros de los datos se utilizó el día de la compra y el mes, restaurante o local y nombre del cliente.

**Tabla 4.-** Productos consumidos por el cliente

Modelos Generados	Dato (ANGEL CHOCO)	Tiempo 2019	
		Marzo	Junio
Modelo de Recomendación de Productos	CARNE APANADA PURE Y ARROZ	0	4
	CERDO TERIYAKI	5	9

Modelos Generados	Dato (ANGEL CHOCO)	Tiempo 2019	
		Marzo	Junio
	CHULETA DE CERDO GLASEADA	3	7
	ENSALADA DE FIDEO TORNILLO	4	0
	ENSALADA RUSA	0	5

Debido a que se necesita realizar la mejora de los tiempos de atención al cliente, con este modelo se puede sugerir al cliente que plato seleccionar al momento de tomar sus pedidos, dando así satisfacción al cliente.

#### 4.3. Configuración de los servicios de Microsoft Azure

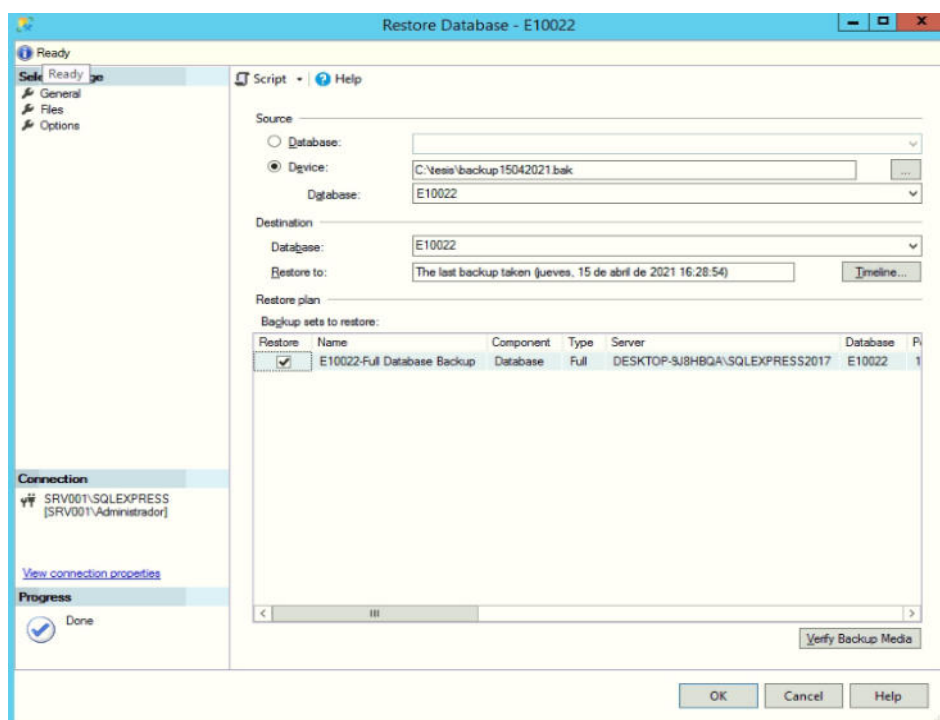
El modelo se iba a realizar en Microsoft Azure, pero se desistió de realizarlo en dicha plataforma por dos razones, la primera fue su alto costo de implementación y la segunda, ciertos problemas de compatibilidad con modelos multidimensionales, por lo cual se procedió a utilizar SQL Analytics Services.

SQL Server Management Studio es un entorno de gestión y administración, que se utiliza principalmente para administrar instancias de Analysis Services, SQL Server, Integration Services y Reporting Services. Con SQL Server Management Studio, puede administrar objetos de Analysis Services (realizar copias de seguridad, procesamiento, etc.) y también puede crear nuevos objetos directamente en una instancia de Analysis Services existente mediante scripts XMLA. SQL Server Management Studio proporciona un proyecto de Scripts de Analysis Server en el que puede desarrollar y guardar scripts escritos en Expresiones multidimensionales

(MDX), Extensiones de minería de datos (DMX) y XML para análisis (XMLA).

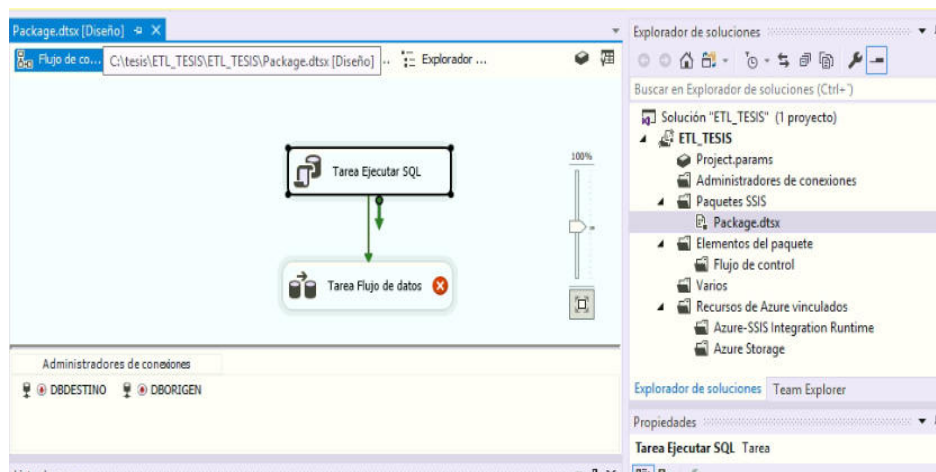
Por lo general, los proyectos de Analysis Server Scripts se utilizan para realizar tareas de administración o volver a crear objetos, como bases de datos y cubos, en instancias de Analysis Services. Estos proyectos pueden guardarse como parte de una solución e integrarse con el control del código fuente” [30].

Se procede a realizar la restauración de las bases de datos en el nuevo servidor, tanto el de la base transaccional como la del Data Warehouse donde se guardará la información procesada para la minería de datos.



**Figura 4.4.-** Restauración base de datos E10022, base inicial

Se empiezan a cargar los proyectos de integración de datos, el cual va a extraer la información del ERP para tenerlos procesados en tablas del Data Warehouse.



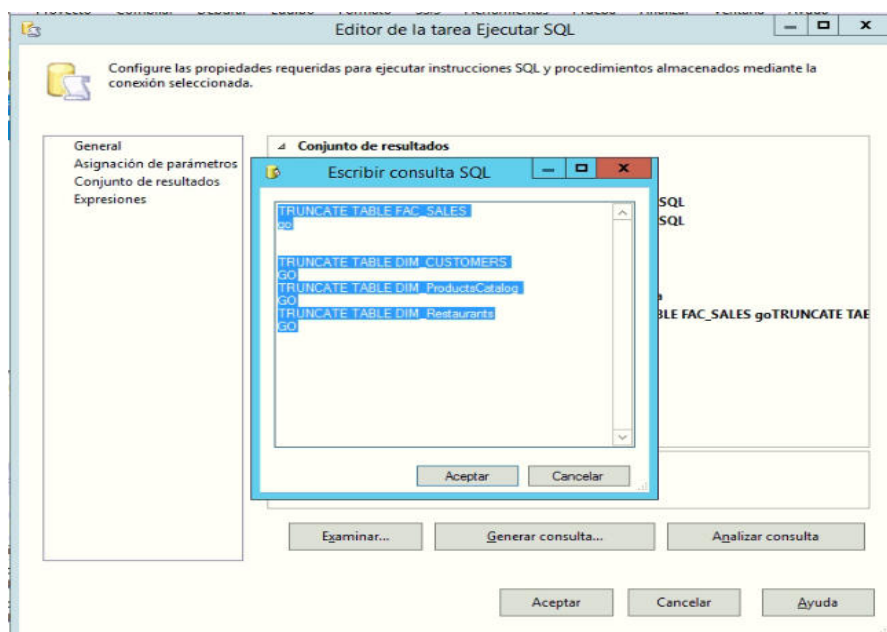
**Figura 4.5.-** Proyecto de Integration Services

La siguiente imagen muestra la tarea que se crea dentro del proyecto de Integration Services, la cual se ejecutará cada noche para extraer la información pendiente de procesar, la misma que fue generada en el transcurso del día. Esta tarea a su vez ejecuta un flujo de datos y empezará a transmitir la información de la base de datos principal a la base del Data Warehouse.



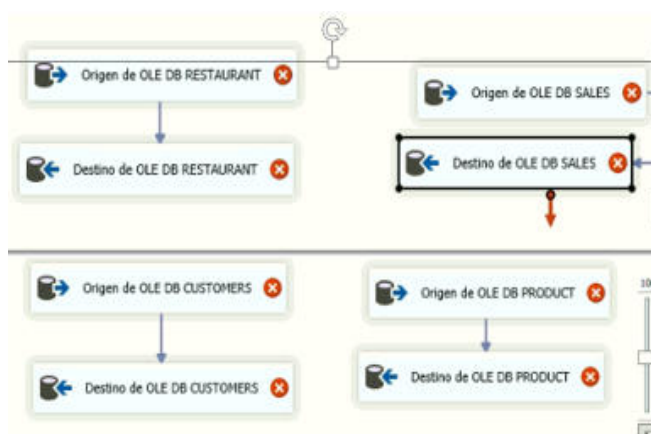
**Figura 4.6.-** Tarea a Ejecutar en SQL

Se puede ver en examinar las sentencias a ejecutar. Las tablas que vamos a migrar son Customers, Productcatalog, restaurants y sales.



**Figura 4.7.-** Sentencia de la tarea

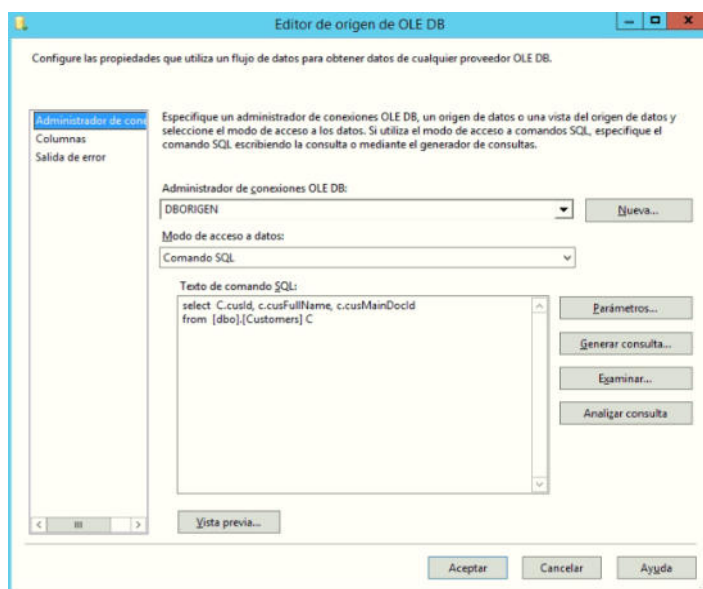
Una vez abierto el flujo se mostrará la migración de las tablas antes mencionadas, desde la base inicial hasta el Data Warehouse.



**Figura 4.8.-** Proyecto de Integration Services Origen y destino de la información

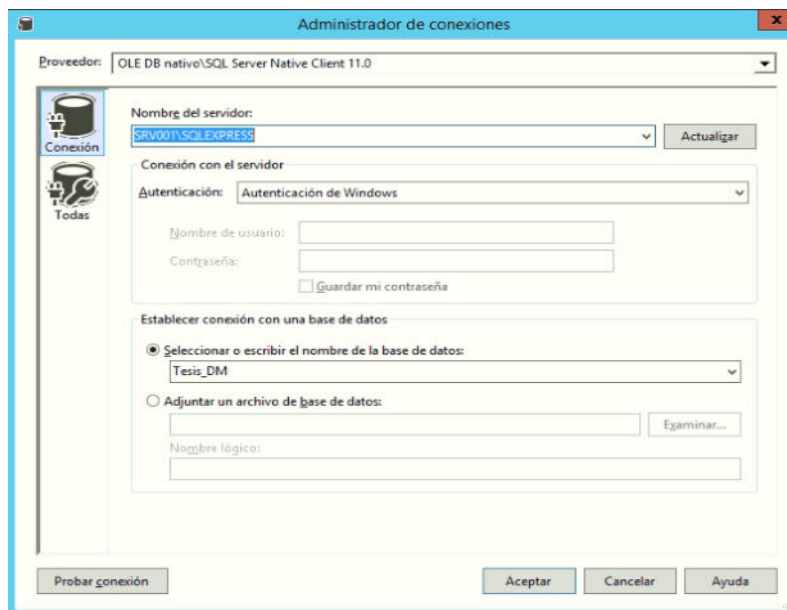


En las conexiones de origen se realiza la sentencia que traerá la información solicitada desde la base de datos e10022.



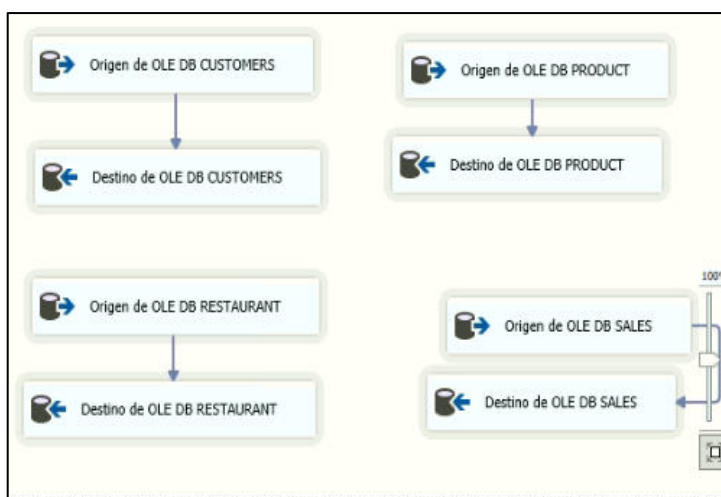
**Figura 4.9.-** Conexión de Origen Customers

Se empieza a modificar las cadenas de conexiones a los servidores de base de datos.



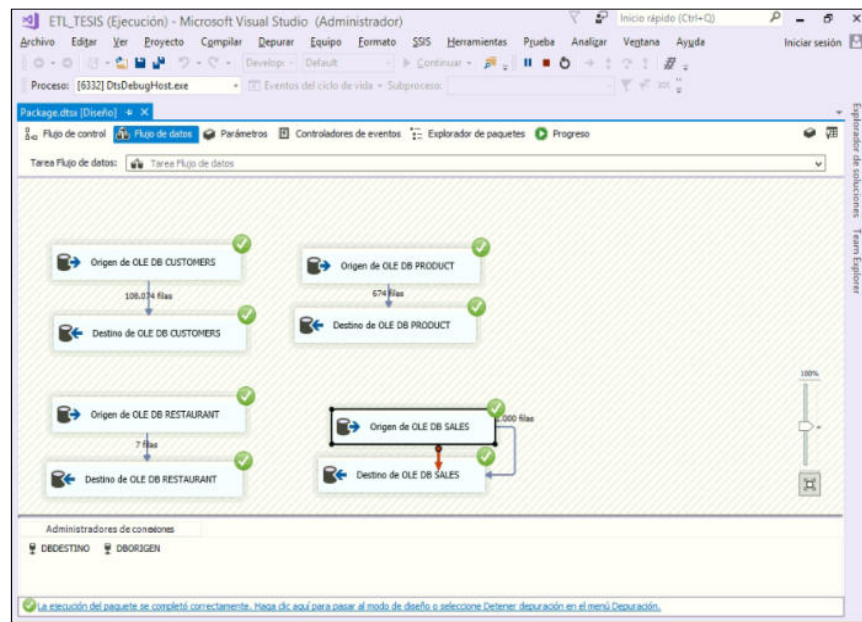
**Figura 4.10.-** Conexión a la base del Data Warehouse, Tesis\_DM

Una vez modificada las cadenas de conexión se debe verificar que ya no presentan errores de conexión.



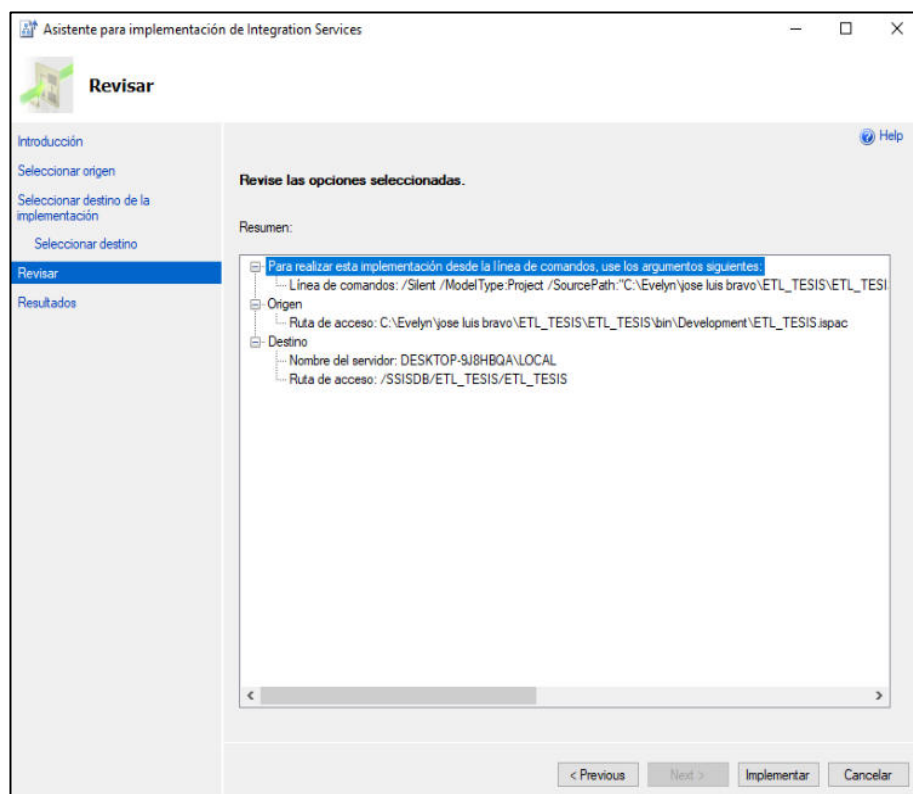
**Figura 4.11.-** Tareas sin novedades

Se procede a ejecutar los package para alimentar el Data WareHouse.



**Figura 4.12.-** Proyecto ejecutado correctamente

Se debe generar los paquetes de integración de datos para que una tarea en SQL server sea ejecutada cada noche.



**Figura 4.13.-** Creación del Paquete

Una vez generado el paquete, debe ser implementado en SQL a través de un job o tarea para que se ejecute cada noche y así alimentamos nuestra base de datos de la data Warehouse y ya no tenemos la necesidad de abrir el proyecto de visual de Integration services, sino que el proceso se ejecutará automáticamente.

Finalmente se ejecuta el job creado y se empieza a visualizar la información en la base de la data Warehouse, la misma que previamente se encontraba vacía.

#### 4.4. Procesamiento de datos



**Figura 4.14.-** Procesamiento de datos

La imagen a continuación muestra como es el flujo de la información, desde que es almacenada hasta que se empiezan a generar los modelos de minería de datos. Cada uno de los puntos está explicado posterior a la imagen.

**Registra:** El ERP genera las transacciones de las ventas, este proceso lo realizan diariamente a través de su operativa normal cada vez que se realiza una compra en los establecimientos de comida. Este proceso lo realiza normalmente, tal como lo hacía antes del proyecto de minería de datos, es decir que esta parte de la operativa no cambia.

Los clientes al acercarse a los locales, podrán elegir su pedido tal como lo ha venido realizando, es el empleado quien será capaz de sugerirla al cliente las opciones disponibles y que más se acerquen a sus preferencias.

**Procesa y almacena:** Diariamente se ejecuta una tarea que extrae la información de la base de datos transaccional y la inserta en la base de la data WareHouse. El proceso se lleva a cabo automáticamente a la 01:00 am, y es la data inicial que utilizaremos en el proceso de minería de datos, para mostrarles las opciones a los clientes.

Las estructuras de datos que vamos a almacenar son de Restaurantes, Clientes, producto y Ventas. Esta información es tomada de la base de datos transaccional E10022 y será insertada en Tesis\_DM.

El proceso dura aproximadamente 30 minutos, es por ese motivo que se decidió ejecutarlo a la 1:00 am diariamente.

**Analiza:** Para realizar el análisis de información utilizamos el Analysis Service, lo cual para llegar a esa instancia realizamos lo siguiente:

1. Se procede a realizar la creación de un Data WareHouse.
2. A través de la creación de paquetes de integración alimentamos nuestro Data WareHouse, la cual contiene una tabla de hechos, donde se encuentran los pedidos facturados por fechas y diferentes variables a analizar.

3. A través del Analysis Service se procesa los datos para generar la minería de datos, los cuales contiene:
  - a. Clientes
  - b. Restaurantes
  - c. Pedidos
  - d. Fecha de venta
  - e. Tiempo de entrega de producto

El Analysis Service se encarga de procesar en memoria los registros guardados en la base del Data Warehouse, y a través de la minería de datos con procesos matemáticos genera patrones y tendencias, este proceso lo genera internamente el Analysis al dejar configurado los valores a analizar.

Para este proyecto vamos a generar el modelo a partir de una base de datos relacional o de almacenamiento de datos, usando la técnica de árboles de decisión de Microsoft.

Este algoritmo identifica las columnas de entrada como establecimiento, cliente o cantidad, estas columnas se correlacionan con la columna de predicción que en nuestro caso sería producto y de esta manera podemos predecir que producto es el más vendido según el establecimiento.

**Muestra resultados:** Una vez ingresada la información a analizar, podremos visualizarlo en power bi o Excel, es aquí donde el empleado que

se encuentra en el área de facturación puede empezar a sugerir a los comensales los productos con mayor salida según los diferentes criterios de búsqueda.


#### 4.5. Evaluación del modelo

Se desarrolla las estructuras de minerías de datos, cada una de las estructuras muestra una información relacionada al análisis solicitado, en las mismas podemos validar las preferencias de los clientes al realizar sus pedidos ya sea por sucursal, cantidad, tiempo de entrega y por los mismos clientes u otros clientes.

Para iniciar con el análisis vamos a utilizar Visual Studio 2017 SSDT, como herramienta para el desarrollo del proyecto de minería, y para continuar debemos tener acceso a la base de datos Tesis\_DM en la cual ya tenemos migrada toda la información necesaria para proceder con el análisis.

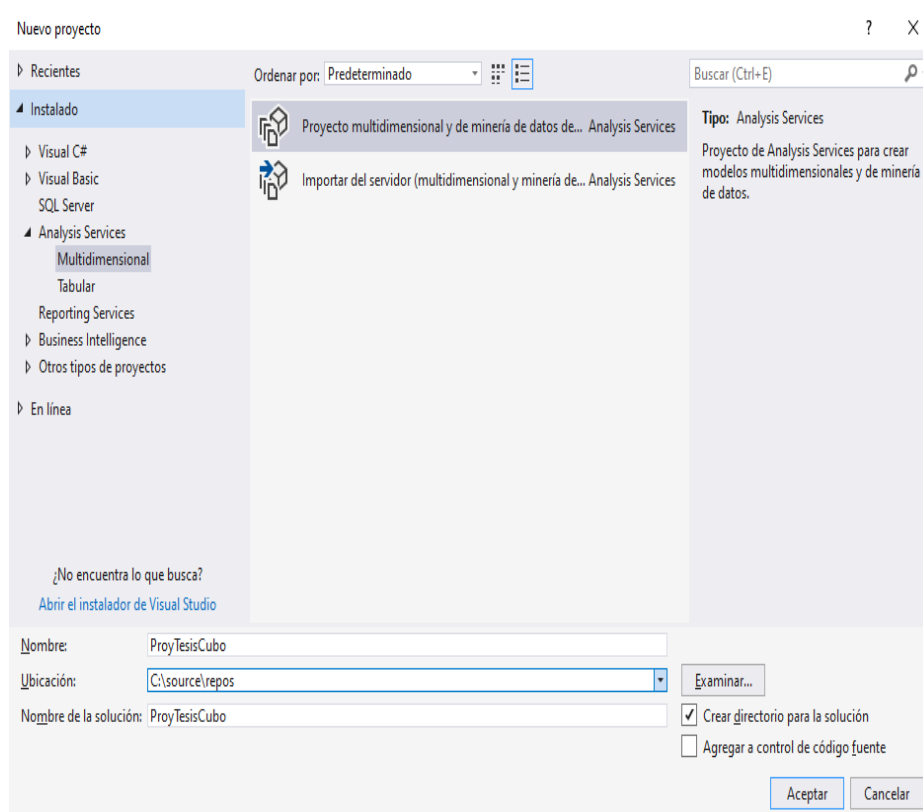
#### Creación del proyecto de minería de datos:

Una vez que hayamos pulido la información que pasa a la nueva base de datos Tesis\_DM, se procede a crear el proyecto de minería en visual estudio. El nombre del proyecto será ProyTesisCubo y se creará como Analysis Services, proyecto multidimensional y de minería de datos, tal como se muestra en las siguientes imágenes.



**Figura 4.15.-** Pasos para crear nuevo proyecto. Parte 1






**Figura 4.16.-** Pasos para crear nuevo proyecto. Parte 2

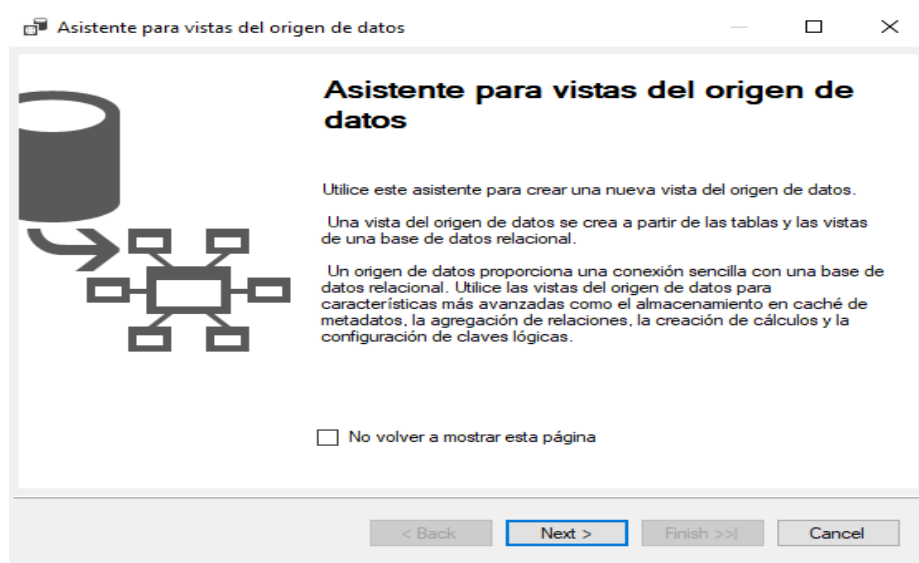
### Creación de la conexión a la base de datos

Una vez creado el proyecto se debe generar una nueva conexión a la base de datos, la base es Tesis\_DM y vamos a acceder a ella mediante autenticación Windows.

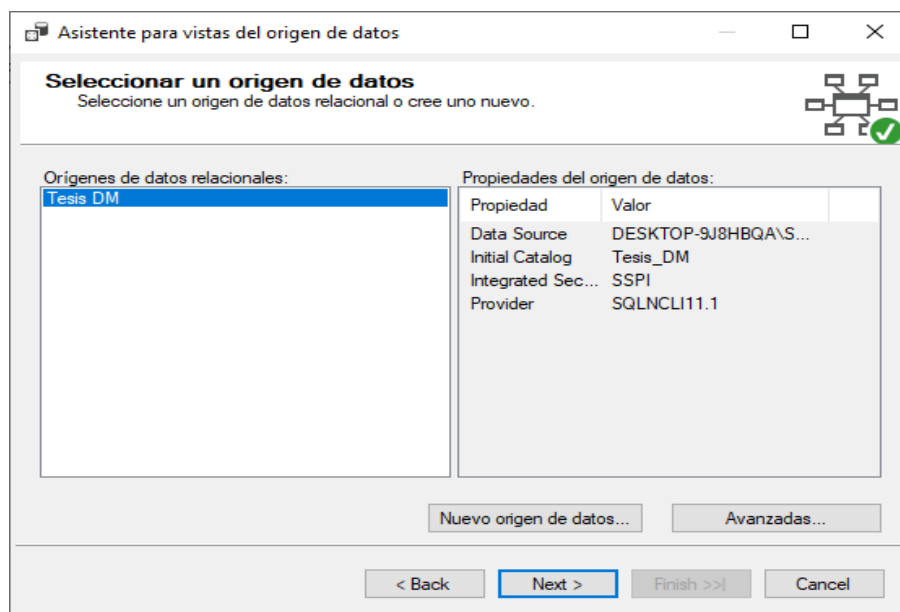
### Creación de la vista de origen de datos



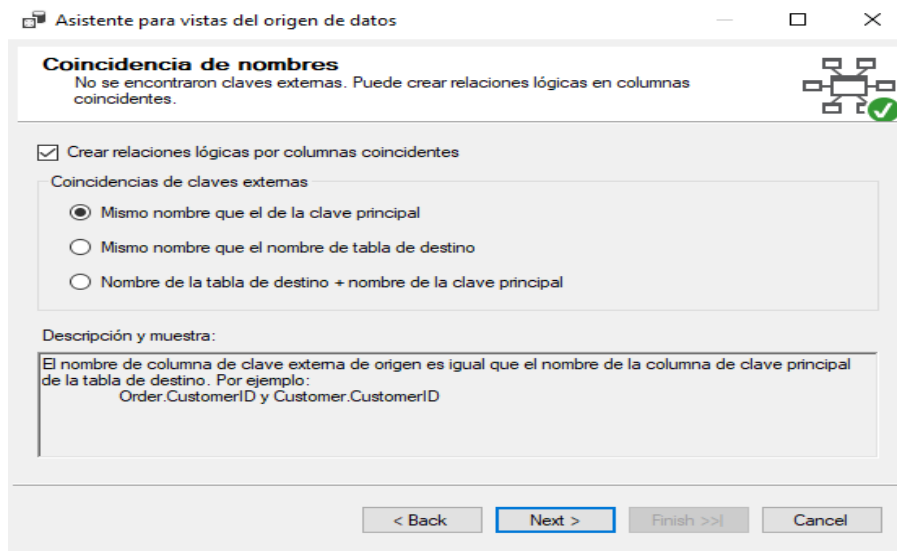
**Figura 4.17.-** Pasos para la creación de la vista. Parte 1



**Figura 4.18.-** Pasos para la creación de la vista. Parte 2

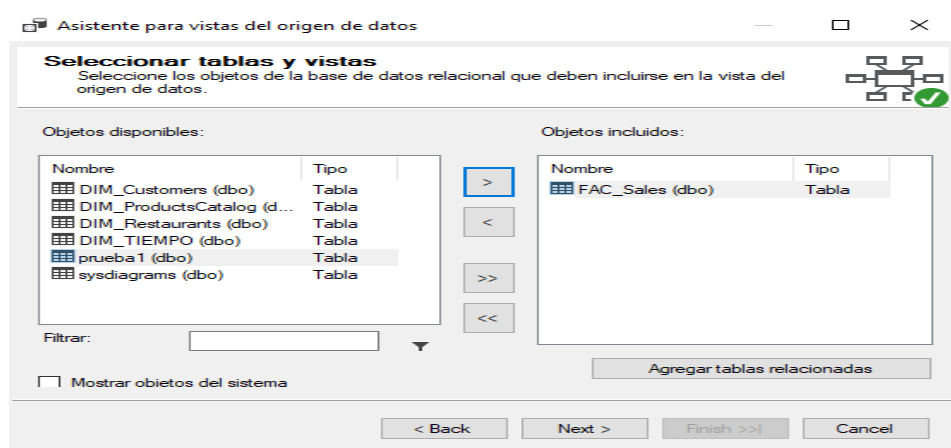


**Figura 4.19.-** Pasos para la creación de la vista. Parte 3



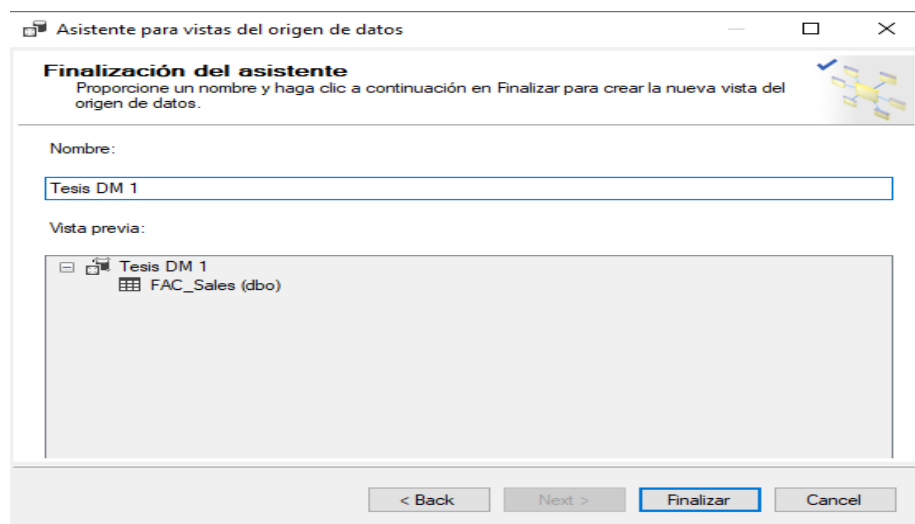
**Figura 4.20.-** Pasos para la creación de la vista. Parte 4

Se procede a seleccionar las estructuras de datos para proceder a analizarlas. Todo lo que se seleccione en esta vista es lo que podrá ser invocado para realizar el análisis. Por el momento vamos a trabajar con FAC\_Sales, el mismo que ya tiene la información completa de las ventas, incluyendo descripciones de productos, nombres de clientes y de restaurantes.



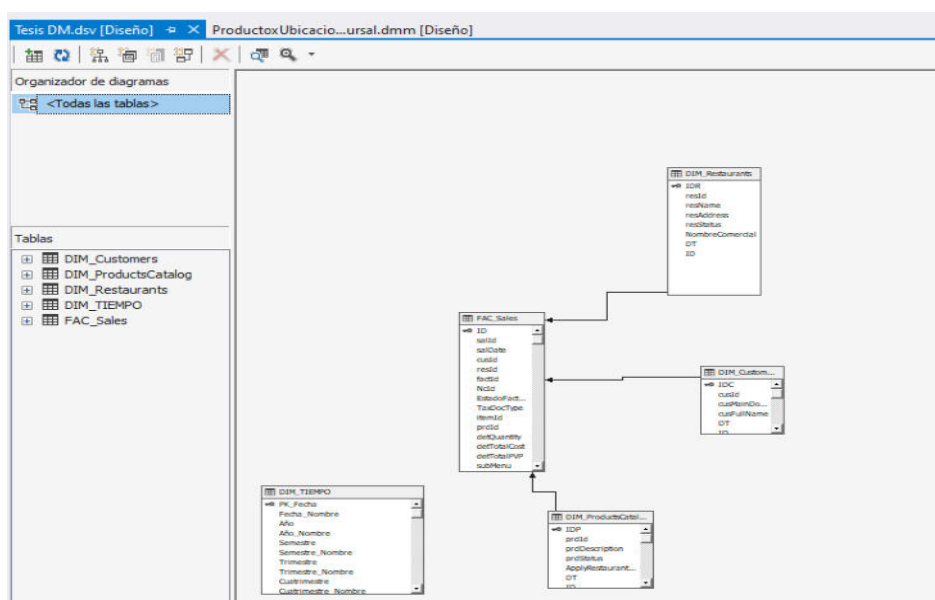
**Figura 4.21.-** Pasos para la creación de la vista. Parte 5

Una vez que se selecciona las estructuras, se procede a finalizar la creación de la vista.



**Figura 4.22.-** Pasos para la creación de la vista. Parte 6

Una vez finalizada la creación de la vista ya podemos ver todas las estructuras creadas y con las cual ya podemos trabajar.




**Figura 4.23.-** Pasos para la creación de la vista. Parte 7

### Pasos para la creación de las estructuras de minerías de datos

Una vez creada la conexión y la vista de datos, ya podemos proceder a crear las nuevas estructuras de minerías de datos. En las cuales vamos a utilizar la técnica de árbol de decisión y en cada una de las estructuras vamos a definir los datos de entrada, claves principales y finalmente los campos de predicción.

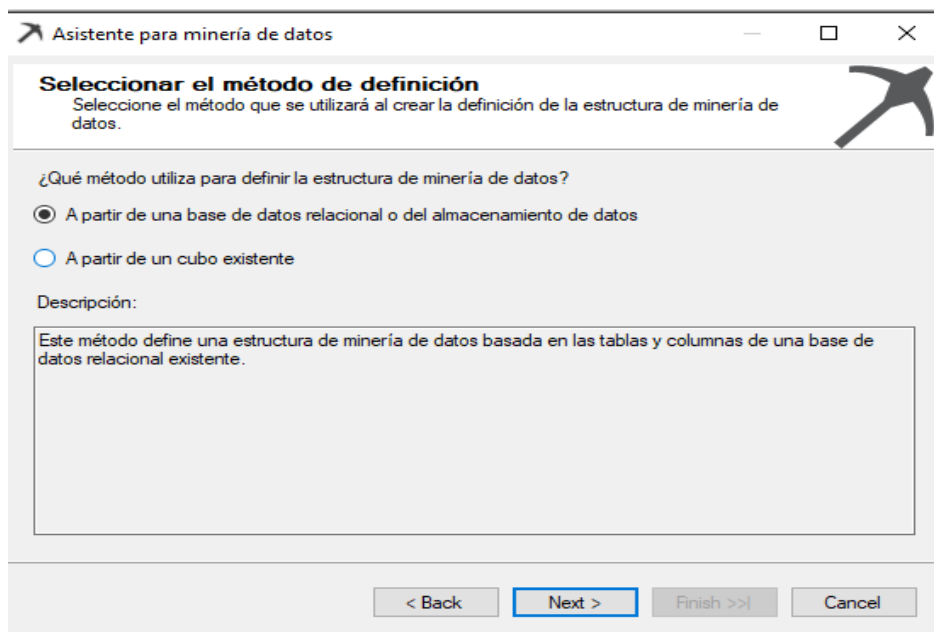
El árbol de decisión nos permite basarnos en la regresión, la clasificación y la asociación de los parámetros ingresados para darnos resultados más efectivos. Estos resultados vamos a contrastarlos en el capítulo 5, en las pruebas internas.

Se da clic derecho y se selecciona nueva estructura de minería de datos.



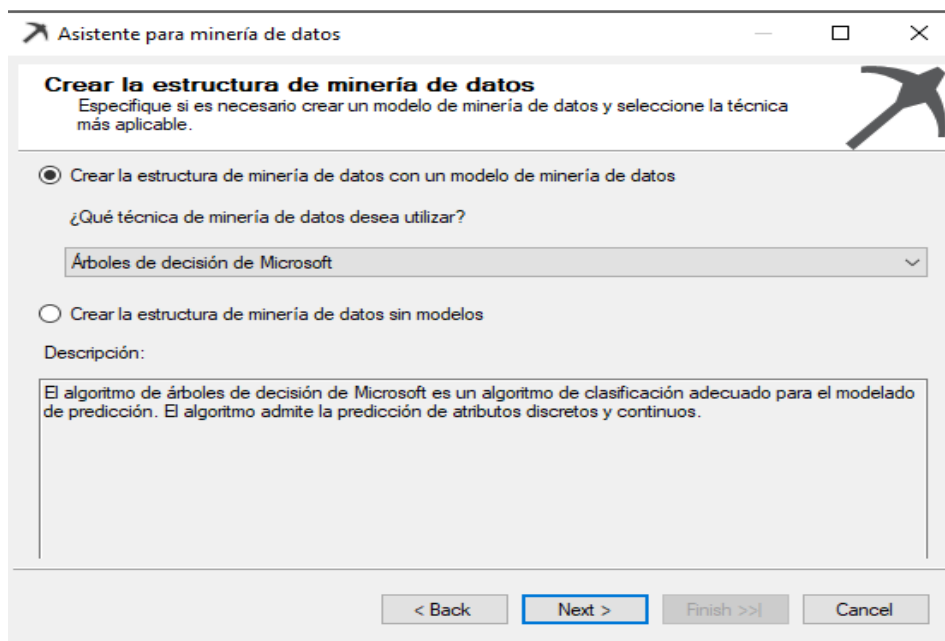
**Figura 4.24.-** Pasos para la creación de la estructura de minería. Parte 1

Seleccionamos la base de datos al que vamos a hacer referencia.



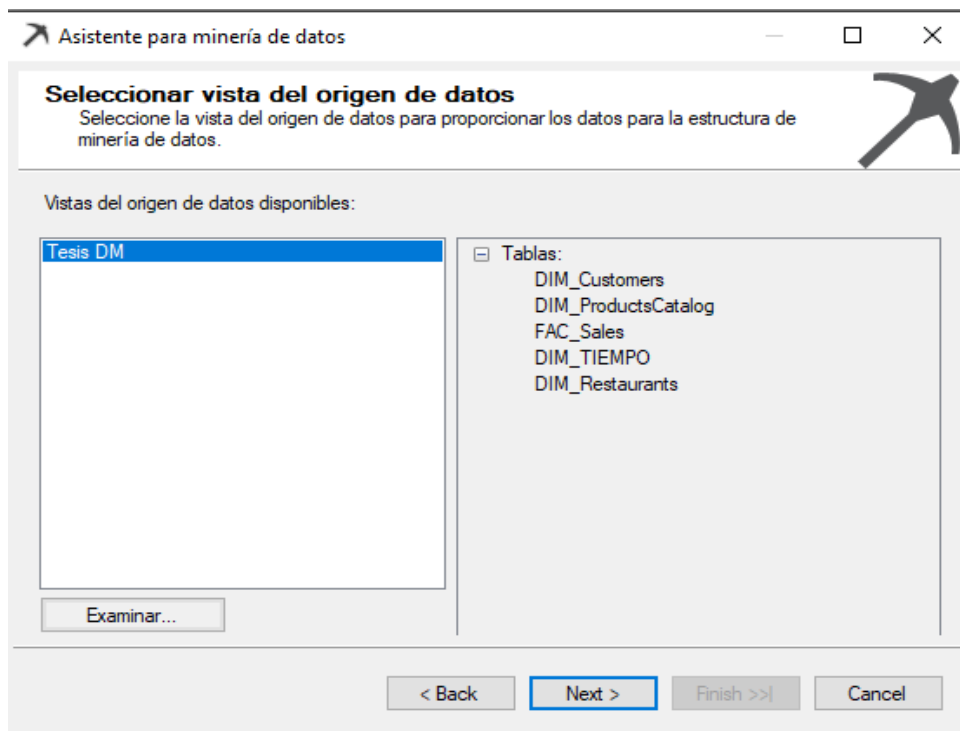
**Figura 4.25.** - Pasos para la creación de la estructura de minería. Parte 2

Seleccionamos la técnica de minería de datos, en este caso vamos a usar el árbol de decisión.



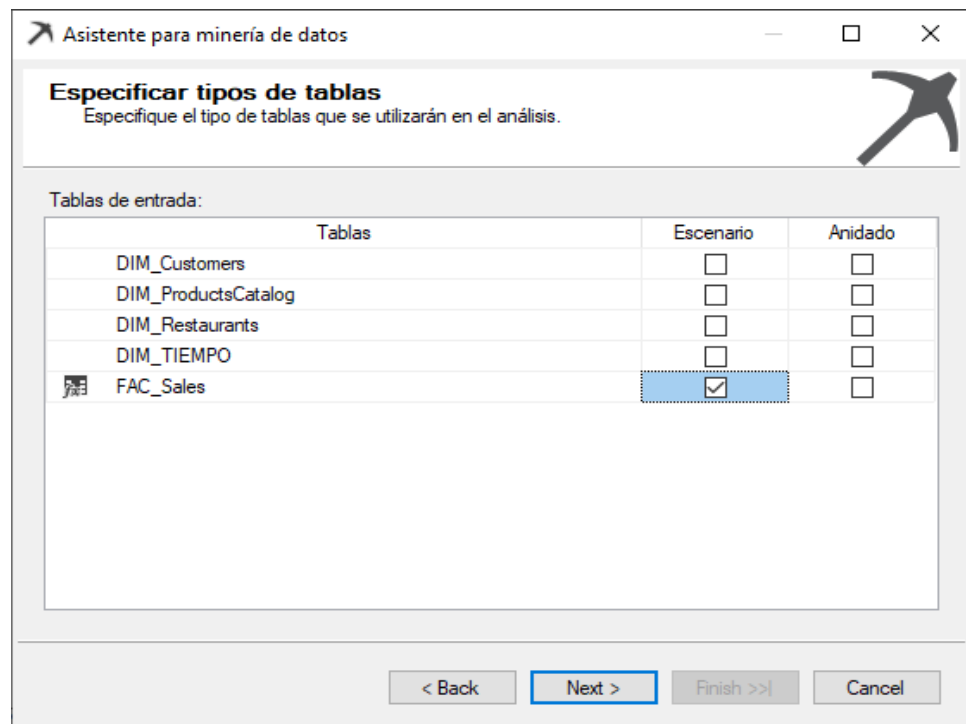
**Figura 4.26.-** Pasos para la creación de la estructura de minería. Parte 3

Luego de seleccionar la técnica, se debe seleccionar la vista del origen de datos previamente creada.



**Figura 4.27.-** Pasos para la creación de la estructura de minería. Parte 4

En la vista ya podemos ver todas las estructuras agregadas en la vista Tesis DM, entre ellas Fac Sales, la cual vamos a utilizar para crear la estructura de datos y debemos seleccionarla como escenario, si tuviéramos alguna tabla relacionada, también la seleccionamos. Por el momento FAC\_Sales cuenta con todos los campos necesarios para realizar la minería.

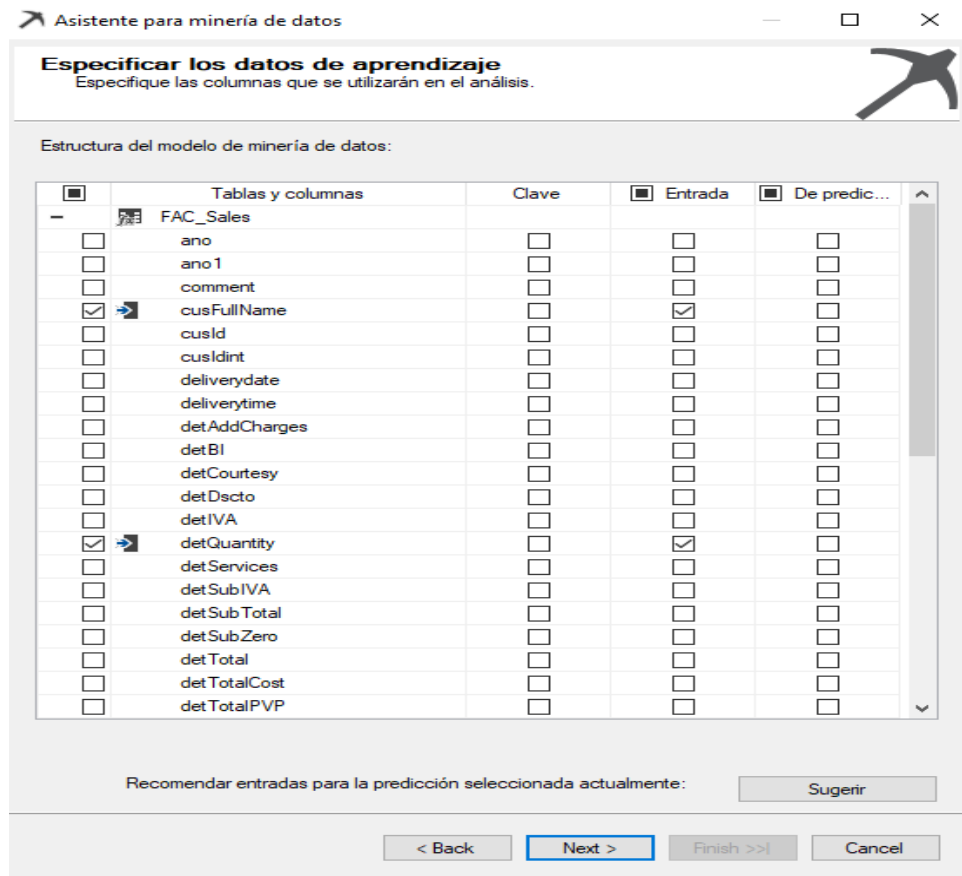


**Figura 4.28.-** Pasos para la creación de la estructura de minería. Parte 5

Después de seleccionar el escenario, automáticamente aparece seleccionada la columna clave, que toma por default la clave principal de la tabla, posterior a esto se debe elegir las entradas que son las columnas que vamos a tomar como referencia para realizar los resúmenes como por ejemplo la sucursal.

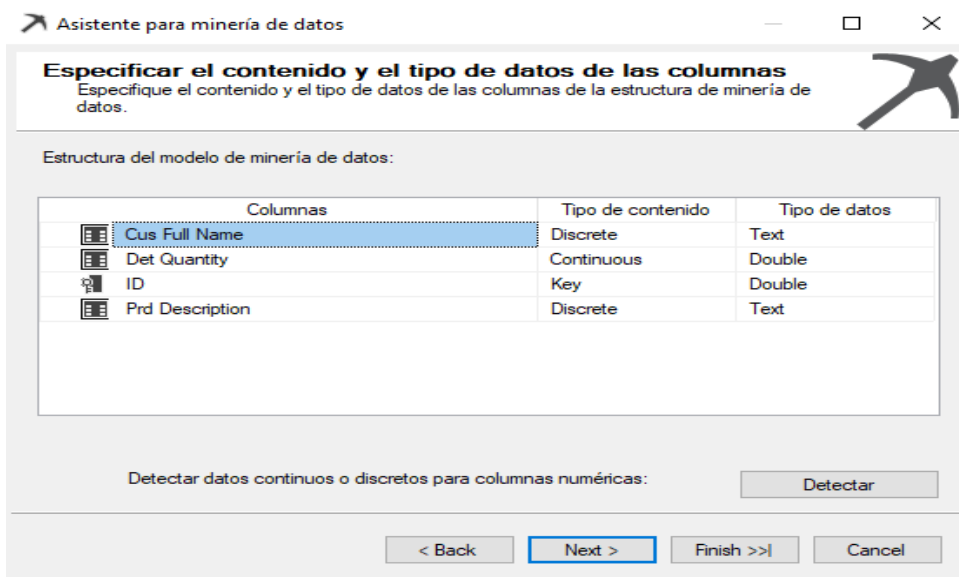
La columna predicción es la que me indica el pronóstico que necesito. Es decir que en la mayoría de las estructuras vamos a predecir el nombre del producto que les podemos sugerir a los clientes al momento de realizar sus compras.





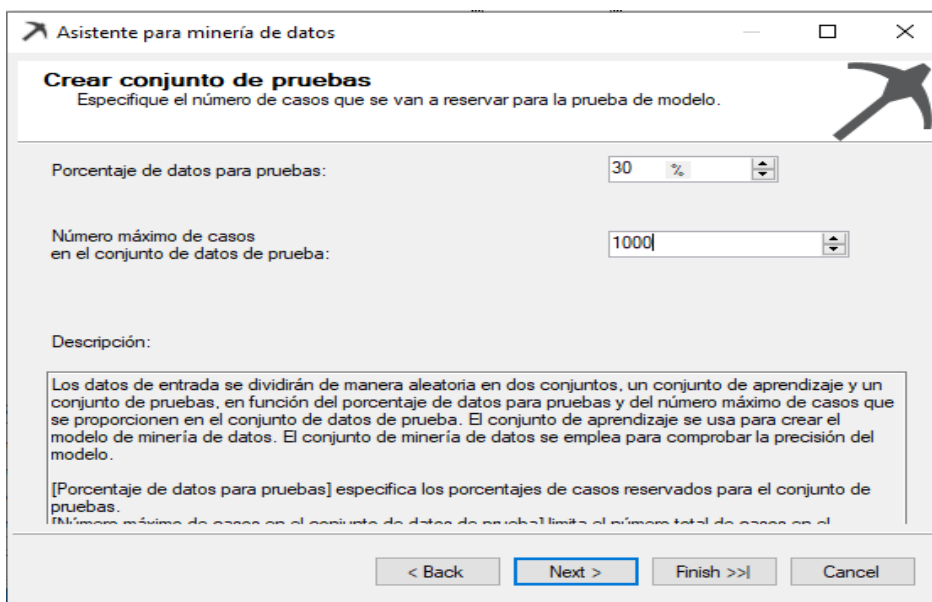
**Figura 4.29.** - Pasos para la creación de la estructura de minería. Parte 6

Una vez seleccionadas las columnas, ya podemos ver las definiciones de las columnas y cambiarlas de ser el caso.



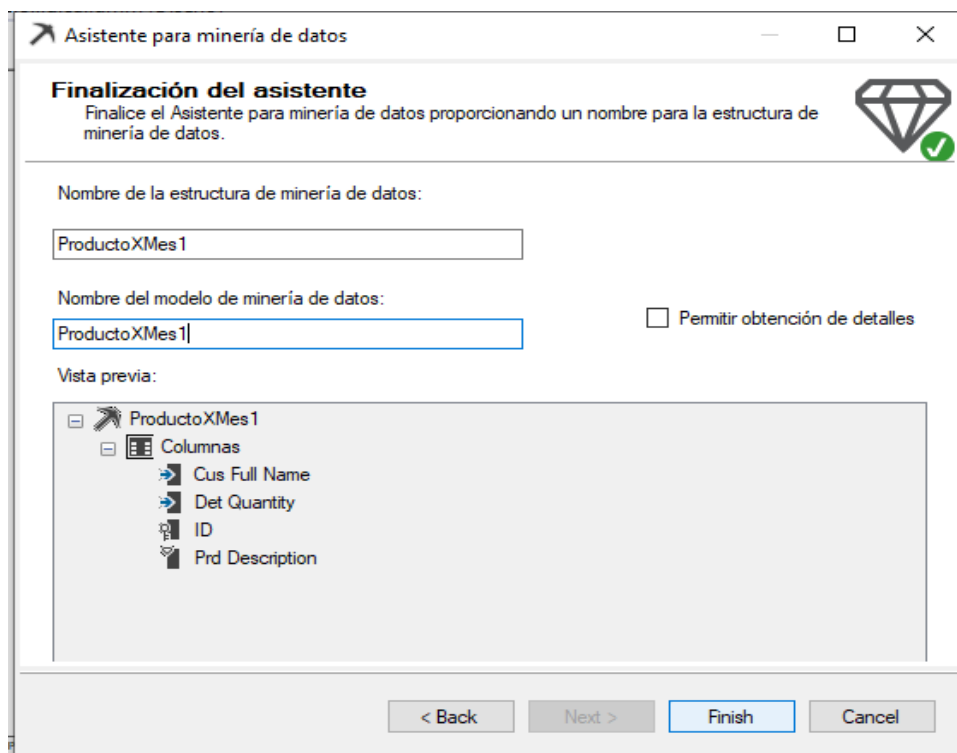
**Figura 4.30.-** Pasos para la creación de la estructura de minería. Parte 7

Cuando ya se tiene la estructura definida, podemos indicar cuál es el porcentaje que se va a tomar para realizar la predicción, y el número máximo de casos que vamos a mostrar.



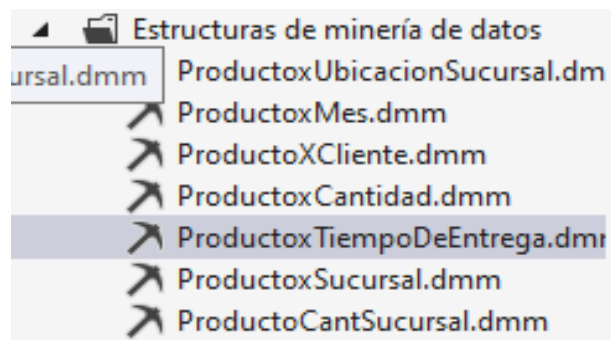
**Figura 4.31.-** Pasos para la creación de la estructura de minería. Parte 8

Finalmente escribimos el nombre de la estructura de la minería y del modelo a crear, y para comprobar la información nos muestra los datos seleccionados.

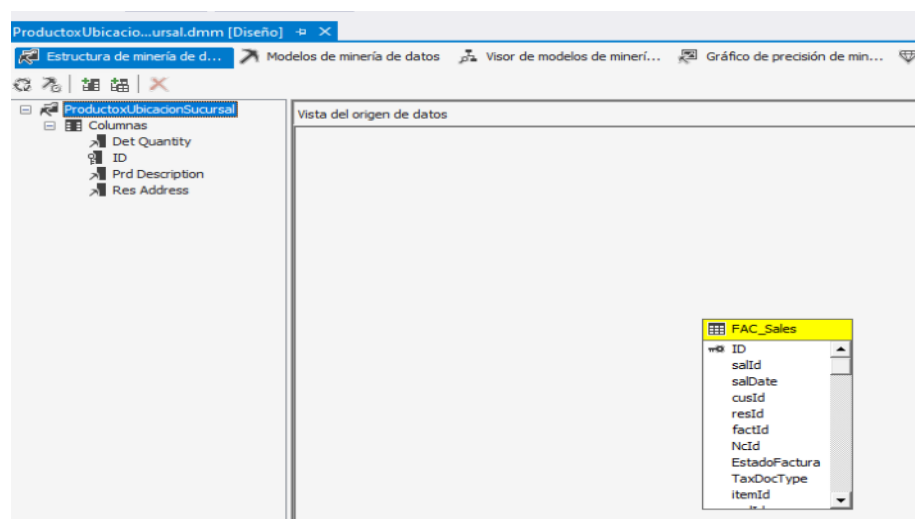


**Figura 4.32.-** Pasos para la creación de la estructura de minería. Parte 9

A continuación, se muestran todas las estructuras creadas para analizarlas en este documento. Cada una de ella toma en cuenta la cantidad como dato de entrada debido a que vamos a analizar los productos más vendidos. Según las diferentes necesidades vamos a seleccionar las demás entradas.

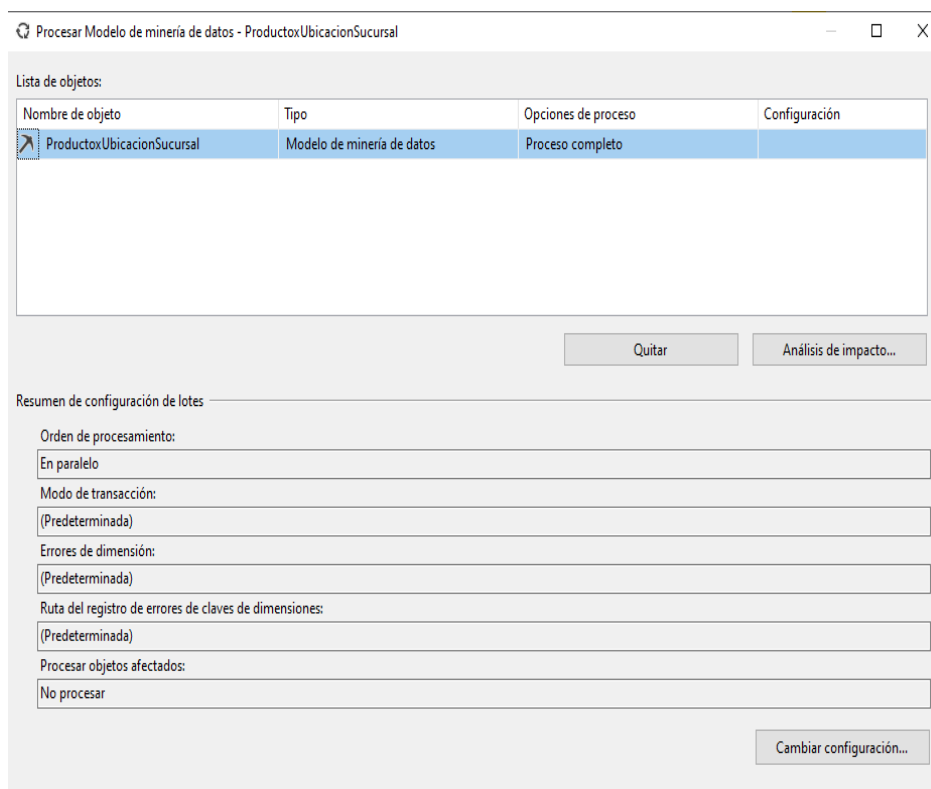


**Figura 4.33.-** Listado de Estructura de Minería de datos



**Figura 4.34.-** Modelo de Minería de datos

La evaluación la revisamos al procesar la minería, la misma que muestra los productos ordenados alfabéticamente y nos indica cual es el porcentaje según la preferencia de los compradores.



**Figura 4.35.-** Ejecución de Estructura de Minería de datos

#### 4.6. Integración del modelo con el punto de venta

A continuación, se generó el cuadro de probabilidades que puede visualizar el usuario por las diferentes variables configuradas, para el mismo se utilizó la interfaz propia del Visual.

#### **Proyección o evaluación del modelo**

Para generar la estructura de minería definimos el Id como columna de identificación o clave, el nombre del cliente como información de ingreso, y el código de producto a ser predicho.

Se muestra todos los resultados de los productos ofrecidos en los establecimientos y los que más fueron comprados por cliente.

Valor	Esce...	Probabi...
<input checked="" type="checkbox"/> 15 ALITAS	1804	0.13%
<input checked="" type="checkbox"/> 30 ALITAS	1265	0.09%
<input checked="" type="checkbox"/> 8 ALITAS	1707	0.13%
<input checked="" type="checkbox"/> AGUA	41688	3.08%
<input checked="" type="checkbox"/> AGUA 1 LT	196	0.01%
<input checked="" type="checkbox"/> AGUA AROMATICA	147	0.01%
<input checked="" type="checkbox"/> AGUA CON GAS	1245	0.09%
<input checked="" type="checkbox"/> AGUA DASANI CON GAS 500 ML	857	0.06%
<input checked="" type="checkbox"/> AGUA DASANI SIN GAS 600 ML	27837	2.06%
<input checked="" type="checkbox"/> AGUA MINERAL	459	0.03%
<input checked="" type="checkbox"/> AGUA NATURAL	3888	0.29%
<input checked="" type="checkbox"/> ALAS	1	0.00%
<input checked="" type="checkbox"/> ALITAS	329	0.02%
<input checked="" type="checkbox"/> ALITAS BBQ CON PAPAS	2765	0.20%
<input checked="" type="checkbox"/> ALL YOU CAN EAT	6	0.00%
<input checked="" type="checkbox"/> ALMUERZOS PARA FUNCAY	2	0.00%
<input checked="" type="checkbox"/> AMARETTO CREAM	54	0.00%
<input checked="" type="checkbox"/> AMARETTO CREAM - HH	18	0.00%
<input checked="" type="checkbox"/> AMERICAN BOMBAY	71	0.01%
<input checked="" type="checkbox"/> AMERICAN BOMBAY - HH	25	0.00%
<input checked="" type="checkbox"/> AMERICAN ICE TEA	3	0.00%
<input checked="" type="checkbox"/> ARRIENDO HILTON COLON APT. 1205	11	0.00%
<input checked="" type="checkbox"/> ARRIENDO PARQUEO WTC 21 Q 4	10	0.00%
<input checked="" type="checkbox"/> ARROZ BLANCO	1831	0.14%
<input checked="" type="checkbox"/> ARROZ BLANCO VENTA	242	0.02%
<input checked="" type="checkbox"/> ARROZ CON CAMARON	1712	0.13%
<input checked="" type="checkbox"/> ARROZ CON CHOCLO	42603	3.15%
<input checked="" type="checkbox"/> ARROZ CON CHOCLO VENTA	337	0.02%

**Figura 4.36.** Proyección o evaluación del producto por cliente

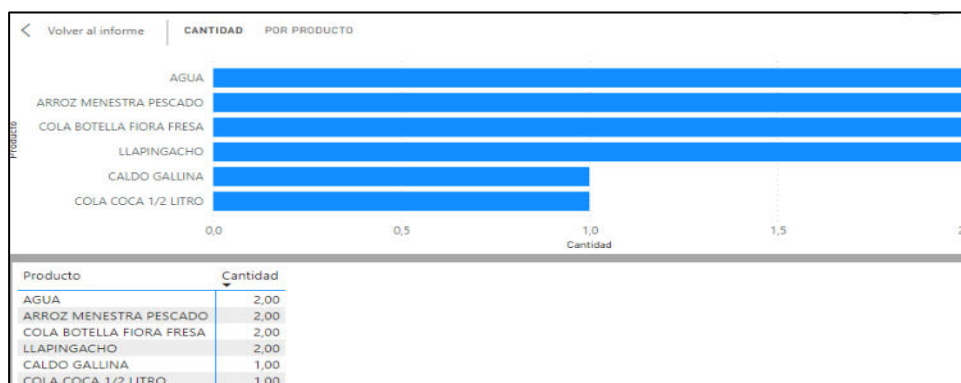
## CAPÍTULO 5

### PRUEBAS Y ANÁLISIS DE RESULTADOS

#### 5.1 Pruebas internas

***Pruebas de la evaluación del modelo.*** - Cuando los clientes que se identifican solicitan los productos de la cadena de comida, el asistente de ventas le indicará las opciones le sugieren dependiendo del día que se acerque el cliente a realizar la compra, a continuación, vamos a revisar el siguiente escenario:

Al presentarse el cliente Edwin Terán, las opciones cambian y se les guiará que en pedidos anteriores el señor había solicitado agua, arroz menestra pescado, cola botella fiora fresa.



**Figura 5.1.-** Resultados de consulta en PowerBI por cliente Edwin Terán

En el siguiente escenario revisamos como el sistema interpreta por la cantidad de pedidos de los platos por mes, cual producto puede sugerirse, porque podemos analizar las tendencias de los clientes por una fecha en específico, esto puede realizarse por días, horas y cualquier fecha específica.

**Tabla 5.-** Producto consumidos por el cliente

Modelos Generados	Dato (ANGEL CHOCO)	Tiempo	
		2019	
		Marzo	Junio
Modelo de Producto por Cliente	CARNE APANADA PURE Y ARROZ	0	4
	CERDO TERIYAKI	5	9
	CHULETA DE CERDO GLASEADA	3	7
	ENSALADA DE FIDEO TORNILLO	4	0
	ENSALADA RUSA	0	5




## 5.2 Pruebas en locales

Debido a la pandemia del COVID-19, la empresa no quiso que se implemente o realice ningún tipo de programa, actualización o modificación al software que utilizan diariamente por lo cual no se pudo realizar pruebas en los locales y se procedió a simular el modelo mediante la herramienta Power BI.

## 5.3 Plan de implementación

Este análisis realizado a todas las sucursales de la cadena debe ser implementado en los equipos de cómputo donde se realiza la facturación. Es decir que cada vendedor debe ser capacitado para que pueda proponer al cliente una opción que se encuentre acorde a sus preferencias anteriores, o basada en las preferencias de otros clientes.

Para realizar la implementación del proyecto de análisis de preferencias se propone instalar Power BI, y/o Excel el mismo que cuenta con filtros para poder facilitar la búsqueda de los platos o productos más solicitados.




**Figura 5.2.-** Resultados del Plan de Implementación

## 5.4 Evaluación de resultados


En el siguiente ejemplo se comparará los resultados del modelo de recomendación de productos frente a compras realizadas en diferentes fechas y horas por el cliente seleccionado para comprobar el funcionamiento del modelo.

**Cliente:** Compañía GroupSolutions S.A.



**Figura 5.3.-** Resultados del Modelo de Recomendación de Productos

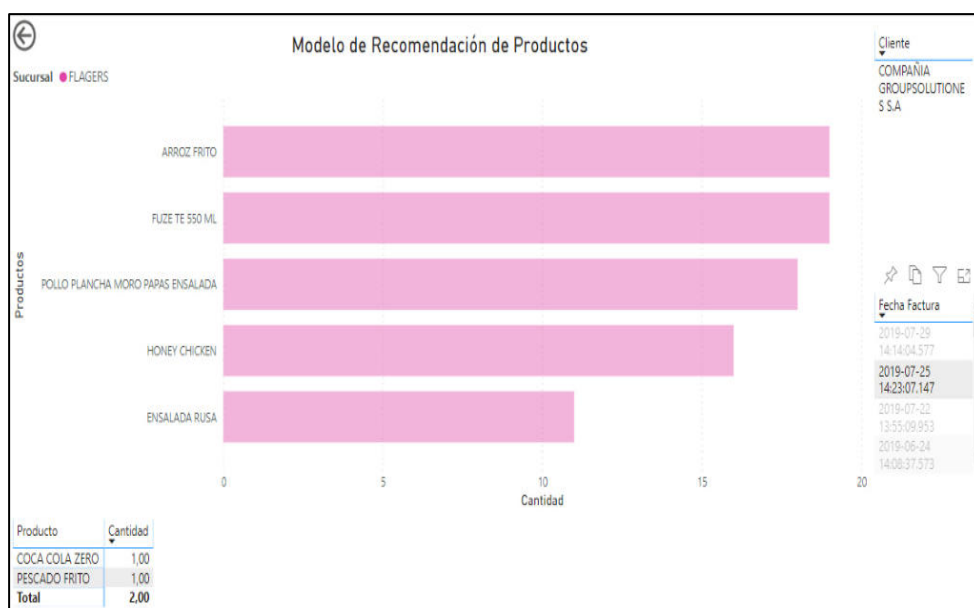
**Fecha de Factura:** 24/06/2019



**Figura 5.4.-** Productos comprados en la transacción

En esta transacción podemos observar que el cliente consumió tres de las cinco recomendaciones que le sugiere el modelo de recomendaciones, lo que significa que el modelo tuvo un 60% de acierto.


**Fecha de Factura: 25/07/2019**



**Figura 5.5.- Productos comprados en la transacción**

En esta transacción el cliente no pidió ningún producto que recomendó el modelo y prefirió consumir otros productos, así como se muestra en la imagen anterior, eso significa que tuvo un 0% de acierto.


**Fecha de Factura: 22/07/2019**



**Figura 5.6.-** Productos comprados en la transacción

En esta ocasión, el cliente selecciona al menos dos productos que le sugiere el modelo de recomendaciones, lo que significa que el modelo tuvo un 40% de acierto.


**Fecha de Factura: 20/05/2019**



**Figura 5.7.-** Productos comprados en la transacción


Finalmente, en esta transacción podemos ver que el cliente consume cuatro de las cinco opciones que sugiere el modelo de recomendaciones, eso significa que el modelo tuvo un 80% de acierto.

Con una muestra de cien clientes en cien facturas diferentes se ha procedido a analizar si el modelo de recomendación de productos es eficaz según se detalla a continuación.



**Figura 5.8.-** Análisis de la eficacia del Modelo de Recomendación de Productos

Se puede concluir que en el 71% de los casos analizados el modelo de recomendación de productos tiene una eficacia comprendida entre el 60% al 100% en cada transacción realizada, mientras que en el 29% de los casos analizados el modelo tiene una eficacia menor al 60% como se lo muestra en la siguiente imagen.



**Figura 5.9.-** Análisis de la eficacia del Modelo de Recomendación de Productos

Podemos concluir que el modelo de recomendación de productos es eficaz, debido a esto los usuarios (operadores y cajeros) pueden ser capaces de ofrecer y recordarles a los clientes sus preferencias anteriores. Es decir que con estos resultados podemos minimizar la cantidad de tiempo que se tomaban los clientes para decidir su pedido.

## **CONCLUSIONES Y RECOMENDACIONES**

### **Conclusiones**

1. Con el modelo de recomendación de productos se pudo agilizar y optimizar el proceso de atención al cliente en cuanto a la demora en la realización del pedido.
2. El análisis de las preferencias no solo ayuda en la compra, sino también en la preparación y entrega de los platos, debido a que las sucursales se van a encontrar preparadas con los productos casi listos para ser servidos.
3. Es importante la implementación de un modelo de recomendación de productos en empresas de comida rápida de consumo masivo, puesto que, mediante esta herramienta se puede optimizar algunos procesos de la misma como la atención al cliente e inventario y stock.

## **Recomendaciones**

1. Se recomienda realizar campañas personalizadas por cliente a través de correo electrónico de sus platos favoritos dependiendo de la fecha en que nos encontremos.
2. Se recomienda implementar el modelo de recomendaciones en un kiosko virtual para que se le presenten las sugerencias de productos al cliente al momento de realizar el pedido dependiendo de la sucursal, día y hora en la que realiza el mismo.
3. Se recomienda revisar los productos más vendidos por sucursal para evitar pérdidas con respecto al stock de los insumos utilizados para su preparación.



## BIBLIOGRAFÍA

- [1] 8. J. Aguilar, «COMPUTACIÓN EN LA NUBE Notas para una estrategia española en cloudcomputing,» *Scielo*, p. 24, 2013.
- [2] Y. Robles Aranda y A. R. Sotolongo, «INTEGRACIÓN DE LOS ALGORITMOS DE MINERÍA DE DATOS 1R, PRISM E ID3 A POSTGRESQL,» *JISTEM: Journal of Information Systems and Technology Management*, vol. 10, nº 2, 2013.
- [3] A. Ferrari, M. Russo y C. Webb, «Microsoft SQL Server 2012 Analysis Services,» de *Microsoft SQL Server 2012 Analysis Services: The BISM Tabular Model*, Pearson Education, 2012.
- [4] L. J. Aguilar, «La Computación en Nube (Cloud Computing):El nuevo paradigma tecnológico para empresas y organizaciones en la Sociedad del Conocimiento,» *Scielo*, p. 18, 2009.
- [5] O. A. Mejía, «Computación en la nube,» *Scielo*, p. 8, 2011.
- [6] y. Rodriguez, «Revista cubana de Ciencias Informaticas,» 11 junio 2009. [En línea]. Available: <https://www.redalyc.org/pdf/3783/378343637009.pdf>.
- [7] Microsoft, «Algoritmos de minería de datos (Analysis Services: Minería de datos),» 30 abril 2018. [En línea]. Available: <https://docs.microsoft.com/es-es/analysis-services/data-mining/data-mining-algorithms-analysis-services-data-mining>. [Último acceso: 11 enero 2020].
- [8] A. Sáenz López, F. Cortés Martínez y J. R. Betancourt Chávez, «Reglas de asociación en una Base de datos del área médica,» *Revista de Arquitectura e Ingeniería*, vol. 11, nº 2, pp. 1-8, 2017,.
- [9] Ecuared, «Algoritmo de árboles de decisión de Microsoft,» 2005. [En línea]. Available: [https://www.ecured.cu/Algoritmo\\_de\\_%C3%A1rboles\\_de\\_decisi%C3%B3n\\_de\\_Microsoft](https://www.ecured.cu/Algoritmo_de_%C3%A1rboles_de_decisi%C3%B3n_de_Microsoft). [Último acceso: 11 enero 2020].

- [10] M. Grandes, «Repositorio USIL,» 2007. [En línea]. Available: [http://repositorio.usil.edu.pe/bitstream/USIL/2763/1/2017\\_Granda\\_Aplicacion-de-mineria-datos.pdf](http://repositorio.usil.edu.pe/bitstream/USIL/2763/1/2017_Granda_Aplicacion-de-mineria-datos.pdf).
- [11] M. S. p. m. d. M. d. D. S. y. C. Hernando Camargo, «Dos caminos en la búsqueda de patrones,» *Journal of Technology*, vol. 9, nº 1, 2019.
- [12] M. P. Elina y P. S. Armando, «Metodología CRISP-DM aplicada al proceso de minería de textos para agrupar documentos web,» Congreso Internacional de información, 2016.
- [13] Microsoft, «Docs de Microsoft,» Microsoft, 07 09 2020. [En línea]. Available: <https://docs.microsoft.com/en-us/analysis-services/analysis-services-overview?view=asallproducts-allversions>. [Último acceso: 02 10 2020].
- [14] I. Herrera, «Ciencias de la Informacion,» 2 mayo 2013. [En línea]. Available: <https://www.redalyc.org/pdf/1814/181430077003.pdf>.
- [15] F. Martínez Pabón, V. Garzón Marín, J. C. Ospina Quintero, J. J. Ibarra Samboní, J. Caicedo Guerrero, Á. Chantre Astaiza y G. Ramírez González, «Sistema de recomendaciones para entornos de Digital Signage soportado en un esquema de cooperación smart tv–smartphone,» *Revista Ingenierías Universidad de Medellín*, vol. 12, nº 24, 2014.
- [16] F. Ocampo Botello, F. Felipe Durán y R. de Luna Caballero, «Sistema de recomendación para el comercio electrónico aplicado a una tienda de libros,» *Científica*, vol. 18, nº 2, 2014.
- [17] O. Velez Langs y C. Santos, «Sistemas Recomendadores: Un enfoque desde los algoritmos genéticos,» *Industrial Data*, vol. 9, nº 1, 2006.
- [18] Microsoft, «microsoft,» docs.microsoft, 05 febrero 2018. [En línea]. Available: <https://docs.microsoft.com/en-us/analysis-services/multidimensional-models/creating-multidimensional-models-using-sql-server-data-tools-ssdt?view=asallproducts-allversions>. [Último acceso: 01 marzo 2021].
- [19] M. A. G. MÁRQUEZ, «APLICACIÓN DE MINERÍA DE DATOS PARA DETERMINAR PATRONES DE CONSUMO FUTURO EN CLIENTES

DE UNA DISTRIBUIDORA DE SUPLEMENTOS NUTRICIONALES,» *Scielo*, p. 91, 2017.

- [20] A. S. F. F. Nelly Lisbeth Hernandez Quintero, «COMPUTACIÓN EN LA NUBE,» *Scielo*, p. 6, 2014.
- [21] K. Group, «<http://www.kimballgroup.com/>,» 12 2016. [En línea]. Available: <http://www.kimballgroup.com/data-warehouse-business-intelligence-resources/books/data-warehouse-dw-lifecycle-toolkit/>.
- [22] C. Martinez, octubre 2013. [En línea]. Available: [http://repositorio.uchile.cl/bitstream/handle/2250/112065/cf-martinez\\_ca.pdf?sequence=1&isAllowed=y](http://repositorio.uchile.cl/bitstream/handle/2250/112065/cf-martinez_ca.pdf?sequence=1&isAllowed=y).
- [23] A. Camacho, «Repositorio UJaveriana,» junio 2005. [En línea]. Available: <https://javeriana.edu.co/biblos/tesis/ingenieria/Tesis189.pdf>.
- [24] J. Diaz Vera, C. Molina Fernández y M.-A. Vila Miranda, «Reducción de Redundancia en Reglas de Asociación,» *Revista Cubana de Ciencias Informáticas*, vol. 10, nº 1, 2016.
- [25] A. Sáenz López, F. Cortés Martínez y J. R. Betancourt Chávez, «Reglas de asociación en una Base de datos del área médica.,» *Revista de Arquitectura e Ingeniería*, vol. 11, nº 2, 2017.
- [26] Microsoft, «Referencia técnica del algoritmo de asociación de Microsoft,» 7 mayo 2018. [En línea]. Available: <https://docs.microsoft.com/es-es/analysis-services/data-mining/microsoft-association-algorithm-technical-reference>. [Último acceso: 11 enero 2020].
- [27] Á. Hernández Bravo, «El SaaS y el Cloud-Computing: una opción innovadora para tiempos de crisis,» *REICIS. Revista Española de Innovación, Calidad e Ingeniería del Software*, vol. 5, nº 1, 2009.
- [28] A. Suárez Batista, A. Febles Estrada y Y. Trujillo Casañola, «Software como servicio: necesidades y retos en los sistemas de servicio de la Industria Cubana del Software,» *Revista Cubana de Ciencias Informáticas*, vol. 10, 2016.

- [29] I. Orozco y O. Jacobs, «LA NUEVA ERA DE LOS NEGOCIOS: COMPUTACIÓN EN LA NUBE,» *Télématique*, vol. 15, nº 2, 2016.
- [30] B. A. León Velandia y M. A. Rosero Muñoz, «Recomendaciones para contratar servicios en la 'nube',» *Facultad de Ingeniería*, vol. 23, nº 37, 2014.
- [31] L. M. Arana López, M. E. Ruiz Rivera y N. La Serna Palomino, «Análisis de aplicaciones empleando la computación en la nube de tipo PaaS y la metodología ágil Scrum,» *Industrial Data*, vol. 18, nº 1, 2015.
- [32] IONOS Digital Guide, «PaaS: plataforma como servicio,» 26 junio 2019. [En línea]. Available: <https://www.ionos.es/digitalguide/servidores/know-how/paas/>. [Último acceso: 11 enero 2020].
- [33] Grupo Garatu, «¿Qué es la Infraestructura como Servicio (IaaS) y qué puede aportar a mi empresa?,» 12 diciembre 2016. [En línea]. Available: <https://grupogaratu.com/infraestructura-servicio-iaas-empresas/>. [Último acceso: 11 enero 2020].
- [34] Microsoft, «Algoritmo de clústeres de Microsoft,» 7 mayo 2018. [En línea]. Available: <https://docs.microsoft.com/es-es/analysis-services/data-mining/microsoft-clustering-algorithm>. [Último acceso: 11 enero 2020].
- [35] Microsoft, «Algoritmo de árboles de decisión de Microsoft,» 7 mayo 2018. [En línea]. Available: <https://docs.microsoft.com/en-us/analysis-services/data-mining/microsoft-decision-trees-algorithm>. [Último acceso: 11 enero 2020].
- [36] Ganimides, «Algoritmos de minería de datos,» 2008. [En línea]. Available: [http://www.ganimides.ucm.cl/aurrutia/doc\\_pdf/AMDISQLServer2008.pdf](http://www.ganimides.ucm.cl/aurrutia/doc_pdf/AMDISQLServer2008.pdf). [Último acceso: 11 enero 2020].
- [37] Microsoft, «Algoritmo de regresión lineal de Microsoft,» 7 mayo 2018. [En línea]. Available: <https://docs.microsoft.com/es-es/analysis-services/data-mining/microsoft-linear-regression-algorithm>.

- [38] Microsoft, «Algoritmo de regresión logística de Microsoft,» 7 mayo 2018. [En línea]. Available: <https://docs.microsoft.com/es-es/analysis-services/data-mining/microsoft-logistic-regression-algorithm?view=sql-server-2017>. [Último acceso: 11 enero 2020].
- [39] A. A. Aquino, G. Molero-Castillo y R. Rojano, «Hacia un nuevo proceso de minería de datos centrado en el usuario,» *Pistas Educativas*, nº 114, 2015.

## GLOSARIO

**Algoritmo.** - Es una secuencia lógica y finita de pasos que permite solucionar un problema o cumplir con un objetivo.

**Buyer.** - Es una representación semi-ficticia de tu cliente ideal basado en entrevistas que representan a tus clientes actuales.

**Cloud Computing.** - Es una tecnología que permite acceso remoto a softwares, almacenamiento de archivos y procesamiento de datos por medio de Internet, siendo así, una alternativa a la ejecución en una computadora personal o servidor local.

**Comida rápida.** - Es un estilo de alimentación donde el alimento se prepara y sirve para consumir rápidamente en establecimientos especializados (generalmente callejeros o a pie de calle).

**Minería de datos.** - Es el proceso de hallar anomalías, patrones y correlaciones en grandes conjuntos de datos para predecir resultados. Empleando una amplia variedad de técnicas, puede utilizar esta información para incrementar sus ingresos, recortar costos, mejorar sus relaciones con clientes, reducir riesgos y más.

**Minerías.** - Las personas que se dedican al análisis de datos a través de este sistema son conocidos como mineros o exploradores de datos, estos intentan descubrir patrones en medio de enormes cantidades de datos. Estos pueden ser la clasificación, regresión, segmentación, asociación y análisis de secuencias.

**Modelo de Análisis Predictivo.** - Son modelos matemáticos que predicen el comportamiento de una variable en función de un conjunto de otras variables.

**Retails.** - Es un sector económico que engloba a las empresas especializadas en la comercialización masiva de productos o servicios uniformes a grandes cantidades de clientes. Es el sector industrial que entrega productos al consumidor final.

## ANEXOS

### Pasos para la instalación de los aplicativos relacionados a la minería de datos.

- Se procede con la instalación del SQL Server 2017, donde estarán la base transaccional del ERP y la base del Data WareHouse.

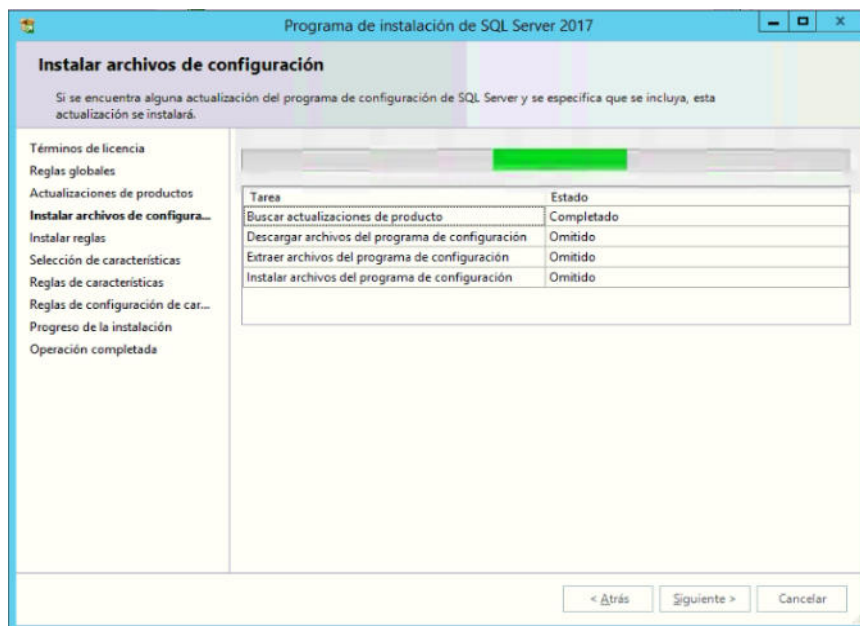


Figura 5.10.- Instalación de SQL Server 2017 parte 1

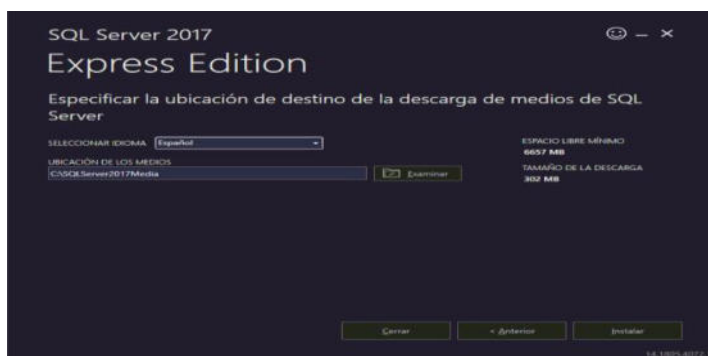


Figura 5.11.- Instalación de SQL Server 2017 parte 2

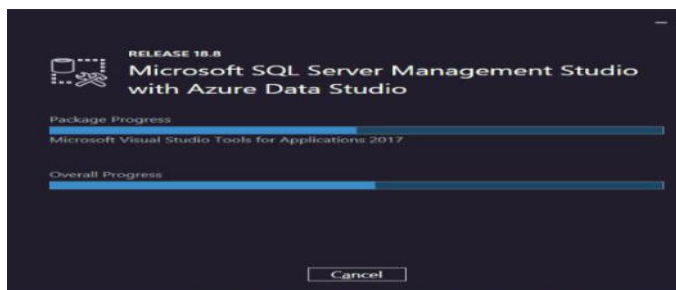




**Figura 5.12-** Instalación de SQL Server 2017 parte 3



**Figura 5.13. -** Instalación de SQL Server 2017 parte 4



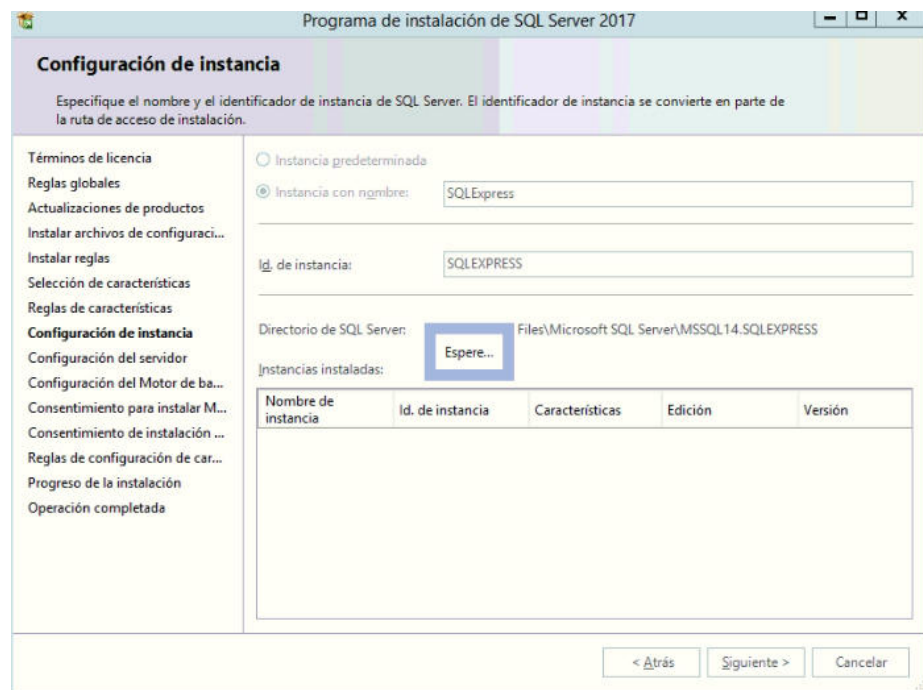
**Figura 5.14.-** Instalación de SQL Server 2017 parte 5



**Figura 5.15.-** Instalación de SQL Server 2017 parte 6



**Figura 5.16.-** Instalación de SQL Server 2017 parte 7



**Figura 5.17.-** Instalación de SQL Server 2017 parte 8

Se procede con la instalación de visual para realizar el proyecto de Integration services y el de minería de datos.



**Figura 5.18.-** Instalación de Visual SSDT parte 1

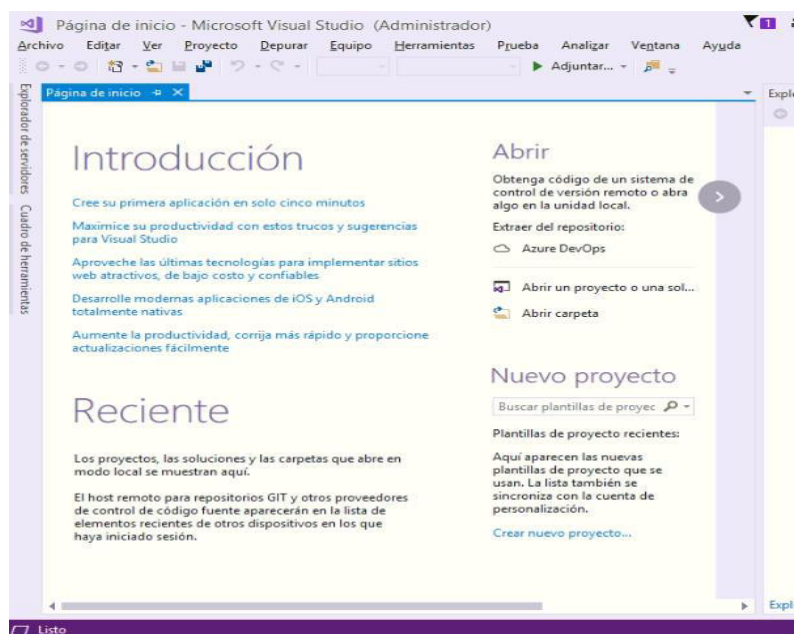


Figura 5.19.- Instalación de Visual SSDT parte 2

## Resultados de las proyecciones

### Resultado de la Proyección o evaluación del modelo

<input checked="" type="checkbox"/>	SALTAMONTES	11	0.01%
<input checked="" type="checkbox"/>	SALTAMONTES - HH	4	0.00%
<input checked="" type="checkbox"/>	SANGO CAMARON	488	0.43%
<input checked="" type="checkbox"/>	SANGRIA BLANCA JARRA	2	0.00%
<input checked="" type="checkbox"/>	SANGRIA BLANCA MEDIA	1	0.00%
<input checked="" type="checkbox"/>	SANGRIA TINTA JARRA	17	0.02%
<input checked="" type="checkbox"/>	SANGRIA TINTA JARRA - HH	0	0.00%
<input checked="" type="checkbox"/>	SANGRIA TINTA MEDIA	14	0.01%
<input checked="" type="checkbox"/>	SANGRIA TINTA MEDIA - HH	0	0.00%
<input checked="" type="checkbox"/>	SECO CARNE	589	0.52%
<input checked="" type="checkbox"/>	SECO CHANCHO	516	0.46%
<input checked="" type="checkbox"/>	SECO CHIVO	1507	1.33%
<input checked="" type="checkbox"/>	SECO POLLO	2148	1.90%
<input checked="" type="checkbox"/>	SERVICIOS DE ALMUERZOS SANOFI	2	0.00%
<input checked="" type="checkbox"/>	SEX ON THE BEACH	4	0.00%
<input checked="" type="checkbox"/>	SEX ON THE BEACH - HH	1	0.00%
<input checked="" type="checkbox"/>	SHAKE JAR	9	0.01%
<input checked="" type="checkbox"/>	SOPA CEBOLLA	39	0.03%
<input checked="" type="checkbox"/>	SOPA DE FIDEO	0	0.00%
<input checked="" type="checkbox"/>	SOPA DE FIDEO QUESO	0	0.00%
<input checked="" type="checkbox"/>	SOPA DIA GRANDE	154	0.14%
<input checked="" type="checkbox"/>	SOPA DIA PEQUEÑA	3	0.00%
<input checked="" type="checkbox"/>	SOPA GRATIS	4161	3.68%
<input checked="" type="checkbox"/>	SOUTH QUESADILLA LOMO	9	0.01%
<input checked="" type="checkbox"/>	SOUTH QUESADILLA POLLO	14	0.01%
<input checked="" type="checkbox"/>	SOUTH QUESADILLAS MIXTA	50	0.04%
<input checked="" type="checkbox"/>	SPAGHETTI AL PESTO	298	0.26%

Figura 5.20.- Resultado de la proyección del modelo parte 1

<input checked="" type="checkbox"/>	SPAGHETTI AL PESTO VENTA	28	0.02%
<input checked="" type="checkbox"/>	SPRITE	95	0.08%
<input checked="" type="checkbox"/>	SPRITE ZERO	5	0.00%
<input checked="" type="checkbox"/>	ST. LOUIS	0	0.00%
<input checked="" type="checkbox"/>	STEAK A LA PARRILA	55	0.05%
<input checked="" type="checkbox"/>	STRAMBERRY MARGARITA	5	0.00%
<input checked="" type="checkbox"/>	STRAMBERRY MARGARITA - HH	4	0.00%
<input checked="" type="checkbox"/>	STRAMBERRY MOJITO	6	0.01%
<input checked="" type="checkbox"/>	STRAMBERRY MOJITO - HH	0	0.00%
<input checked="" type="checkbox"/>	SWEET CORN	370	0.33%
<input checked="" type="checkbox"/>	SWEET JALAPEÑO BURGER	0	0.00%
<input checked="" type="checkbox"/>	TACO SALAD	213	0.19%
<input checked="" type="checkbox"/>	TALLARIN VERDE	49	0.04%
<input checked="" type="checkbox"/>	TALLARIN VERDE LOMO	581	0.51%
<input type="checkbox"/>	TALLARIN VERDE POLLO	74	0.07%
<input checked="" type="checkbox"/>	TALLARIN VERDE VENTA	4	0.00%
<input checked="" type="checkbox"/>	TARRINA	1006	0.89%
<input checked="" type="checkbox"/>	TE GRANDE	236	0.21%
<input checked="" type="checkbox"/>	TE HELADO	99	0.09%
<input checked="" type="checkbox"/>	TE PEQUEÑO	0	0.00%
<input checked="" type="checkbox"/>	TEA DURAZNO	371	0.33%
<input checked="" type="checkbox"/>	TEA LIGHT	0	0.00%
<input checked="" type="checkbox"/>	TEA MANZANA	0	0.00%
<input checked="" type="checkbox"/>	TEA MANZANILLA	2	0.00%
<input checked="" type="checkbox"/>	TEA VERDE	107	0.09%
<input checked="" type="checkbox"/>	TENEDORES	1	0.00%
<input checked="" type="checkbox"/>	TEQUEÑOS CAMARON	14	0.01%

**Figura 5.21.-** Resultado de la proyección del modelo parte 2

Se muestra todos los resultados de los productos ofrecidos en los establecimientos y los que más fueron comprados por cliente.

Valor	Esce...	Probabi...
<input checked="" type="checkbox"/>	15 ALITAS	1804 0.13%
<input checked="" type="checkbox"/>	30 ALITAS	1265 0.09%
<input checked="" type="checkbox"/>	8 ALITAS	1707 0.13%
<input checked="" type="checkbox"/>	AGUA	41688 3.08%
<input checked="" type="checkbox"/>	AGUA 1 LT	196 0.01%
<input checked="" type="checkbox"/>	AGUA AROMATICA	147 0.01%
<input checked="" type="checkbox"/>	AGUA CON GAS	1245 0.09%
<input checked="" type="checkbox"/>	AGUA DASANI CON GAS 500 ML	857 0.06%
<input checked="" type="checkbox"/>	AGUA DASANI SIN GAS 600 ML	27837 2.06%
<input checked="" type="checkbox"/>	AGUA MINERAL	459 0.03%
<input checked="" type="checkbox"/>	AGUA NATURAL	3888 0.29%
<input checked="" type="checkbox"/>	ALAS	1 0.00%
<input checked="" type="checkbox"/>	ALITAS	329 0.02%
<input checked="" type="checkbox"/>	ALITAS BBQ CON PAPAS	2765 0.20%
<input checked="" type="checkbox"/>	ALL YOU CAN EAT	6 0.00%
<input checked="" type="checkbox"/>	ALMUERZOS PARA FUNCAY	2 0.00%
<input checked="" type="checkbox"/>	AMARETTO CREAM	54 0.00%
<input checked="" type="checkbox"/>	AMARETTO CREAM - HH	18 0.00%
<input checked="" type="checkbox"/>	AMERICAN BOMBAY	71 0.01%
<input checked="" type="checkbox"/>	AMERICAN BOMBAY - HH	25 0.00%
<input checked="" type="checkbox"/>	AMERICAN ICE TEA	3 0.00%
<input checked="" type="checkbox"/>	ARRIENDO HILTON COLON APT. 1205	11 0.00%
<input checked="" type="checkbox"/>	ARRIENDO PARQUEO WTC 21 Q 4	10 0.00%
<input checked="" type="checkbox"/>	ARROZ BLANCO	1831 0.14%
<input checked="" type="checkbox"/>	ARROZ BLANCO VENTA	242 0.02%
<input checked="" type="checkbox"/>	ARROZ CON CAMARON	1712 0.13%
<input checked="" type="checkbox"/>	ARROZ CON CHOCLO	42603 3.15%
<input checked="" type="checkbox"/>	ARROZ CON CHOCLO VENTA	337 0.02%

**Figura 5.22.-** Resultado de la proyección del modelo parte 3

<input checked="" type="checkbox"/>	ARROZ MENESTRA FRITADA	62	0.00%
<input checked="" type="checkbox"/>	ARROZ MENESTRA LOMO	15570	1.15%
<input checked="" type="checkbox"/>	ARROZ MENESTRA PESCADO	10882	0.80%
<input checked="" type="checkbox"/>	ARROZ MENESTRA POLLO	16862	1.25%
<input checked="" type="checkbox"/>	ARROZ MORO	14622	1.08%
<input checked="" type="checkbox"/>	ARROZ MORO VENTA	304	0.02%
<input checked="" type="checkbox"/>	ARROZ PRIMAVERA	839	0.06%
<input checked="" type="checkbox"/>	ARROZ PRIMAVERA VENTA	16	0.00%
<input checked="" type="checkbox"/>	Ausente	0	0.00%
<input checked="" type="checkbox"/>	BABY BACK RIBS FULL	801	0.06%
<input checked="" type="checkbox"/>	BABY BACK RIBS HALF	613	0.05%
<input checked="" type="checkbox"/>	BABY BACK RIBS SANDWICH	100	0.01%
<input checked="" type="checkbox"/>	BACON CHEESE BURGER	1437	0.11%
<input checked="" type="checkbox"/>	BACON QUESADILLA POLLO	219	0.02%
<input checked="" type="checkbox"/>	BACON QUESADILLAS LOMO	100	0.01%
<input checked="" type="checkbox"/>	BACON QUESADILLAS MIXTA	561	0.04%
<input checked="" type="checkbox"/>	BANDEJA MIXTA	24	0.00%
<input checked="" type="checkbox"/>	BANDERA	7143	0.53%
<input checked="" type="checkbox"/>	BANDERA CON SECO CARNE	245	0.02%
<input checked="" type="checkbox"/>	BANDERA CON SECO CHANCHO	214	0.02%
<input checked="" type="checkbox"/>	BANDERA CON SECO POLLO	268	0.02%
<input checked="" type="checkbox"/>	BANDERA ESPECIAL	4243	0.31%
<input checked="" type="checkbox"/>	BANDERA ESPECIAL SECO CARNE	124	0.01%
<input checked="" type="checkbox"/>	BANDERA ESPECIAL SECO CHANCHO	118	0.01%
<input checked="" type="checkbox"/>	BANDERA ESPECIAL SECO POLLO	87	0.01%
<input checked="" type="checkbox"/>	BBQ	51	0.00%
<input checked="" type="checkbox"/>	BBQ QUESADILLA LOMO	132	0.01%
<input checked="" type="checkbox"/>	BBQ QUESADILLA POLLO	96	0.01%
<input checked="" type="checkbox"/>	BBQ QUESADILLAS MIXTA	440	0.03%

Figura 5.23.- Resultado de la proyección del modelo parte 4

<input checked="" type="checkbox"/>	BLACK RUSSIAN	35	0.00%
<input checked="" type="checkbox"/>	BLACK RUSSIAN - HH	17	0.00%
<input checked="" type="checkbox"/>	BLOODY MARY	29	0.00%
<input checked="" type="checkbox"/>	BLOODY MARY - HH	17	0.00%
<input checked="" type="checkbox"/>	BLOOMING MARGARITA	39	0.00%
<input checked="" type="checkbox"/>	BLOOMING MARGARITA - HH	9	0.00%
<input checked="" type="checkbox"/>	BLOOMING MOJITO	35	0.00%
<input checked="" type="checkbox"/>	BLOOMING MOJITO - HH	12	0.00%
<input checked="" type="checkbox"/>	BLOOMING SALAD POLLO	92	0.01%
<input checked="" type="checkbox"/>	BLOOMINGS FERRIS WHEEL	338	0.02%
<input checked="" type="checkbox"/>	BLOOMINGS SALAD	24	0.00%
<input checked="" type="checkbox"/>	BLOOMINGS SALAD CAMARON	52	0.00%
<input checked="" type="checkbox"/>	BLOOMINGS STEAK	819	0.06%
<input checked="" type="checkbox"/>	BLUE CHEESE	11	0.00%
<input checked="" type="checkbox"/>	BLUE CHEESE BURGER	11	0.00%
<input checked="" type="checkbox"/>	BLUE ISLAND ICE TEA	68	0.01%
<input checked="" type="checkbox"/>	BLUE ISLAND ICE TEA - HH	31	0.00%
<input checked="" type="checkbox"/>	BLUE MARGARITA	62	0.00%
<input checked="" type="checkbox"/>	BLUE MARGARITA - HH	36	0.00%
<input checked="" type="checkbox"/>	BOLA EXTRA	41	0.00%
<input checked="" type="checkbox"/>	BOLON MIXTO	187	0.01%
<input checked="" type="checkbox"/>	BOLON QUESO	122	0.01%
<input checked="" type="checkbox"/>	BOMBAY MIXED	114	0.01%
<input checked="" type="checkbox"/>	BOMBAY MIXED - HH	38	0.00%
<input checked="" type="checkbox"/>	BOMBAY TONIC	27	0.00%
<input checked="" type="checkbox"/>	BOMBAY TONIC - HH	7	0.00%
<input checked="" type="checkbox"/>	BONELESS CHICKEN	451	0.03%
<input checked="" type="checkbox"/>	BONELESS CHICKEN HONEY MOON	51	0.00%
<input checked="" type="checkbox"/>	BONELESS CHICKEN HONEY MUSTARD	99	0.01%

Figura 5.24.- Resultado de la proyección del modelo parte 5

<input checked="" type="checkbox"/>	HUEVO	22	0.00%
<input checked="" type="checkbox"/>	HUEVO FRITO	998	0.07%
<input checked="" type="checkbox"/>	INCA 400 ML	2495	0.18%
<input checked="" type="checkbox"/>	JALAPEÑOS	8	0.00%
<input checked="" type="checkbox"/>	JUGO DE MORA GRANDE	9478	0.70%
<input checked="" type="checkbox"/>	JUGO DE MORA MEDIANO	5051	0.37%
<input checked="" type="checkbox"/>	JUGO DE NARANJA GRANDE	12754	0.94%
<input checked="" type="checkbox"/>	JUGO DE NARANJA MEDIANO	5730	0.42%
<input checked="" type="checkbox"/>	JUGO DEL VALLE	1879	0.14%
<input checked="" type="checkbox"/>	JUGO LIMONADA 16OZ	11607	0.86%
<input checked="" type="checkbox"/>	JUGO LIMONADA GRANDE	2717	0.20%
<input checked="" type="checkbox"/>	JUGO MORA	41135	3.04%
<input checked="" type="checkbox"/>	JUGO NARANJA	59717	4.41%
<input checked="" type="checkbox"/>	JUGO TOMATE GRANDE	3	0.00%
<input checked="" type="checkbox"/>	JUGO VASO MEDIANO	1	0.00%
<input checked="" type="checkbox"/>	KALBI DE CARNE	1422	0.11%
<input checked="" type="checkbox"/>	KIDS CRISPY TENDER	474	0.04%
<input checked="" type="checkbox"/>	KIDS GRILLED CHICKEN	279	0.02%
<input checked="" type="checkbox"/>	KIDS MAC CHEESE	131	0.01%
<input checked="" type="checkbox"/>	LAN BANDEJA DE CHOCLO	1	0.00%
<input checked="" type="checkbox"/>	LAN CALDO BOLA	4	0.00%
<input checked="" type="checkbox"/>	LAN CALDO DE GALLINA	1	0.00%
<input checked="" type="checkbox"/>	LAN CALDO DE PATA	2	0.00%
<input checked="" type="checkbox"/>	LAN CAMARONES TEMPURA	1	0.00%
<input checked="" type="checkbox"/>	LAN GUATITA	25	0.00%
<input checked="" type="checkbox"/>	LAN LLAPINGACHO	52	0.00%
<input checked="" type="checkbox"/>	LAN LOMITO SALTEADO	14	0.00%
<input checked="" type="checkbox"/>	LAN LOMO CERDO CHIMICHURRI	8	0.00%
<input checked="" type="checkbox"/>	LAN MEDALLONES RES MOSTAZA	20	0.00%
<input checked="" type="checkbox"/>	LAN MENESTRA CON CHULETA	12	0.00%

Figura 5.25.- Resultado de la proyección del modelo parte 6

<input checked="" type="checkbox"/>	SEX ON THE BEACH	19	0.00%
<input checked="" type="checkbox"/>	SEX ON THE BEACH - HH	9	0.00%
<input checked="" type="checkbox"/>	SHAKE JAR	187	0.01%
<input checked="" type="checkbox"/>	SOPA CEBOLLA	329	0.02%
<input checked="" type="checkbox"/>	SOPA DE FIDEO	1575	0.12%
<input checked="" type="checkbox"/>	SOPA DE FIDEO QUESO	432	0.03%
<input checked="" type="checkbox"/>	SOPA DIA GRANDE	1523	0.11%
<input checked="" type="checkbox"/>	SOPA DIA PEQUEÑA	49	0.00%
<input checked="" type="checkbox"/>	SOPA GRATIS	49689	3.67%
<input checked="" type="checkbox"/>	SOUTH QUESADILLA LOMO	58	0.00%
<input checked="" type="checkbox"/>	SOUTH QUESADILLA POLLO	109	0.01%
<input checked="" type="checkbox"/>	SOUTH QUESADILLAS MIXTA	283	0.02%
<input checked="" type="checkbox"/>	SPAGHETTI AL PESTO	2033	0.15%
<input checked="" type="checkbox"/>	SPAGHETTI AL PESTO VENTA	164	0.01%
<input checked="" type="checkbox"/>	SPRITE	992	0.07%
<input checked="" type="checkbox"/>	SPRITE ZERO	235	0.02%
<input checked="" type="checkbox"/>	ST. LOUIS	389	0.03%
<input checked="" type="checkbox"/>	STEAK A LA PARRILA	512	0.04%
<input checked="" type="checkbox"/>	STRAMBERRY MARGARITA	53	0.00%
<input checked="" type="checkbox"/>	STRAMBERRY MARGARITA - HH	26	0.00%
<input checked="" type="checkbox"/>	STRAMBERRY MOJITO	57	0.00%
<input checked="" type="checkbox"/>	STRAMBERRY MOJITO - HH	30	0.00%
<input checked="" type="checkbox"/>	SWEET CORN	4244	0.31%
<input checked="" type="checkbox"/>	SWEET JALAPEÑO BURGER	8	0.00%
<input checked="" type="checkbox"/>	TACO SALAD	1363	0.10%
<input checked="" type="checkbox"/>	TALLARIN VERDE	299	0.02%
<input checked="" type="checkbox"/>	TALLARIN VERDE LOMO	7194	0.53%
<input checked="" type="checkbox"/>	TALLARIN VERDE POLLO	3221	0.24%
<input checked="" type="checkbox"/>	TALLARIN VERDE VENTA	20	0.00%
<input checked="" type="checkbox"/>	TARRINA	12491	0.92%

Figura 5.26.- Resultados de la proyección del modelo parte 7