Pg_KDD - Entorno Gráfico para el Sistema de Descubrimiento de Conocimiento en Bases de Datos PostgresKDD

MANUAL DE REFERENCIA

WILMER JEFFERSSON CUCHALA ARTEAGA
FRANCISCO JAVIER URBANO ROSALES
RICARDO TIMARÁN PEREIRA

GRUPO DE INVESTIGACIÓN GRIAS
UNIVERSIDAD DE NARIÑO
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE SISTEMAS
SAN JUAN DE PASTO
2012

RESUMEN

En este documento se describe el proceso de construcción de la herramienta "***Pg_KDD- entorno gráfico para el sistema de descubrimiento de conocimiento en bases de datos PostgresKDD"*** desarrollado en el grupo de investigación GRIAS del departamento de Sistemas de la facultad de Ingeniería de la Universidad de Nariño.

Pg_KDD es un ambiente gráfico para el sistema de descubrimiento de conocimiento PostgresKDD, una herramienta computacional fuertemente acoplada con el SGBD PostgreSQL, que permite al usuario final, interactuar de una manera amigable con el motor KDD y extraer conocimiento de las bases de datos de una manera fácil.

Esta herramienta gráfica está dividida en tres módulos principales, los cuales son:

Módulo interfaz gráfica: este módulo administra la interfaz gráfica de Pg_KDD.

Módulo kernel Pg_KDD*:* en este módulo se administran todos los procesos referentes a conexiones al sistema, administración de bases de datos y demás procesos derivados a esta, como son administración de tablas, columnas, restricciones, reglas, disparadores, entre otros.

Este módulo contiene los siguientes submódulos:

Sentencias gráficas: en este submódulo se representa el resultado de sentencias SQL obtenidas del manejo gráfico de relaciones de una base de datos, en donde gráficamente y de manera manual se puede realizar selecciones, uniones, ordenamiento, aplicación de funciones de agregación y agrupamiento.

Minería de datos*:* en este submódulo se gestiona de manera gráfica los operadores, primitivas y algoritmos implementados en PostgresKDD, para las tareas de minería de datos asociación y clasificaciones, con el fin de descubrir conocimiento a partir de los datos seleccionados.

Utilidades: en este módulo se gestiona la conexión con el sistema de descubrimiento de conocimiento en base de datos PostgresKDD, al igual que el manejo de scripts SQL y la visualización de las tablas de las base de datos.

CONTENIDO

1. INTRODUCCIÓN

El explosivo crecimiento en los volúmenes de los datos y las bases de datos que superan los métodos tradicionales de análisis basados en hojas de cálculo y consultas ad-hoc [6], ha generado una urgente necesidad de contar con nuevas técnicas y herramientas que puedan, inteligente y automáticamente, transformar los datos en información útil [3]. Estas técnicas y herramientas son el objeto del emergente campo de Descubrimiento de Conocimiento en Bases de Datos DCBD (KDD- Knowledge discovery in databases).

A pesar del acelerado avance y del incremento de la investigación en el área de DCBD [3][7][9][17][18][23][28][29][1], relativamente son pocas las propuestas de integrar al lenguaje de consultas SQL nuevas primitivas que permitan descubrir eficientemente conocimiento en grandes bases de datos [4][14][21][24]. La mayor parte de los sistemas y herramientas DCBD existentes se han construido bajo el modelo de arquitectura débilmente acoplada con un SGBD. Además, no existe un consenso general sobre el conjunto de primitivas necesarias para soportar el descubrimiento de conocimiento en un SGBD.

En este documento se presenta uno de los resultados de la segunda etapa del proyecto PostgresKDD cuyo objetivo principal fue construir un ambiente gráfico para el sistema de descubrimiento de conocimiento PostgresKDD, una herramienta computacional fuertemente acoplada con el SGBD PostgreSQL, financiado por el Sistema de Investigaciones de la Universidad de Nariño. En la primera etapa se implementaron algunos operadores y primitivas SQL propuestos por Timaran [32] para el Descubrimiento de Reglas de Asociación y Clasificación al interior del motor del SGBD PostgreSQL. El resultado de esa etapa fue la primera versión de la herramienta PostgresKDD con la capacidad de descubrir Reglas de Asociación y Clasificación. En esta etapa se pretende construir a PostgresKDD, un ambiente gráfico que permita de una manera amigable interactuar con el motor KDD y extraer conocimiento de las bases de datos de una manera fácil.

2. FUNDAMENTACIÓN TEORICA

2.1 ANTECEDENTES

A continuación se describen algunos proyectos de investigación relacionados con el Descubrimiento de Conocimiento en Bases de datos con la aplicación de tareas de minería de datos.

2.1.1 PostgresKDD: Es un proyecto de investigación que se encuentra en el grupo de investigación GRIAS de la Universidad de Nariño, que se denota bajo la arquitectura fuertemente acoplada con el SGBD PostgreSQL, cuyo nombre es "Implantación de primitivas SQL para el descubrimiento de conocimiento de reglas de asociación y clasificación al interior del motor del sistema gestor de bases de datos PostgreSQL" [43].

El objetivo principal es dotar al SGBD PostgreSQL la capacidad de descubrir conocimiento en bases de datos al interior de su motor mediante la implementación de primitivas SQL para el descubrimiento de Reglas de asociación y clasificación.

Para el desarrollo de este proyecto se estudio los operadores de descubrimiento de conocimiento propuestos por Timaran [31], se analizo la arquitectura del SGBD PostgreSQL, su código fuente y finalmente se implementaron al interior del motor de PostgreSQL las primitivas SQL para que compile, transforme y ejecute eficientemente una consulta que involucre descubrimiento de reglas de Asociación y Clasificación, evaluando su rendimiento con bases de datos sintéticas con un gran volumen de datos.

Como conclusiones para este proyecto y de acuerdo a las pruebas de rendimiento, se recalca la mejora en eficiencia, en cuanto a tiempo de ejecución, de los nuevos operadores de Asociación y Clasificación en comparación con otros proyectos débilmente acoplados como TariyKDD [51].

Al igual que PostgresKDD, Pg_KDD esta desarrollado bajo los lineamientos de software libre los hace herramientas accesibles para para cualquier empresa u organización que requiera de un apoyo en la toma de decisiones. La diferencia de este proyecto con PgKDD, radica en la inexistencia de una herramienta computacional grafica para la fácil aplicación y visualización de los resultados obtenidos de las implementaciones que se encuentran dentro del motor de PostgreSQL

2.1.2 TariyKDD: Es un proyecto de investigación que se encuentra en el grupo de investigación GRIAS de la Universidad de Nariño, que se denota bajo la arquitectura débilmente acoplada con el SGBD PostgreSQL, cuyo nombre es "*Una herramienta genérica De Descubrimiento De Conocimiento En Bases de Datos débilmente acoplada con El SGBD PostgreSQL*" [51].

El objetivo principal es desarrollar una herramienta genérica para el Descubrimiento de Conocimiento en bases de datos débilmente acoplada con el sistema gestor de bases de datos PostgreSQL, bajo los lineamientos del Software Libre, que facilite la toma de decisiones a las pequeñas y medianas empresas u organizaciones de nuestro país y de cualquier parte del mundo.

Para el desarrollo de este proyecto se estudiaron las diferentes herramientas de Descubrimiento de conocimiento débilmente acopladas con un SGBD, de igual forma se desarrollaron diferentes módulos para suplir con todas las etapas del Descubrimiento de conocimiento, Selección, Reprocesamiento, Transformación, Minería de Datos, Visualización y Análisis de resultados.

Los algoritmos para la obtención de patrones y reglas de Asociación y Clasificación implementados en esta herramienta fueron EquipAsso, MateTree, Apriori Hibrido, FPGrowth y C4.5, de los cuales se presentaron las pruebas de rendimiento respectivas con grandes volúmenes de datos.

Como conclusiones de esta herramienta tenemos las mejoras en la implementación de los algoritmos EquipAsso, MateTree y FPGrowth, ausentes en

otras herramientas débilmente acopladas, al igual que la obtención de buenos tiempos de respuesta según sus pruebas de rendimiento.

Al igual que TariyKDD, Pg_KDD esta desarrollado bajo los lineamientos de software libre los hace herramientas accesibles para para cualquier empresa u organización que requiera de un apoyo en la toma de decisiones, de igual forma Pg_KDD apoya en las tareas de selección, minería de datos y visualización del proceso de Descubrimiento de Conocimiento con Bases de Datos.

La diferencia de este proyecto con Pg_KDD, radica en la implementación de módulos gráficos para la administración de bases de datos, como también en el uso y aplicación de algoritmos, operadores y primitivas que se encuentran dentro de un sistema de Descubrimiento de Conocimiento fuertemente acoplado con un SGBD como es PostgresKDD.

2.1.3 MATE-KDD: Es un proyecto de investigación que se encuentra en el grupo de investigación GRIAS de la Universidad de Nariño, que se denota bajo la arquitectura medianamente acoplada con el SGBD PostgreSQL, cuyo nombre es "*Una herramienta genérica para el Descubrimiento de reglas de Clasificación medianamente acoplada Al SGBD PostgreSQL*" [37].

Desarrollar una herramienta genérica para el Descubrimiento de reglas de Clasificación en bases de datos medianamente acoplada con el Sistema Gestor de Bases de Datos PostgreSQL, bajo los lineamientos del Software Libre.

Para el desarrollo de este proyecto se estudiaron las diferentes herramientas de Descubrimiento de conocimiento para Clasificación, se implementaron dentro de PostgresKDD, operadores y primitivas SQL para las tareas de Clasificación como funciones definidas por el usuario o medianamente acopladas. Se realizaron las respectivas pruebas de rendimiento del nuevo algoritmo propuesto MATE-TREE.

Al igual que MATE-KDD, Pg_KDD trabaja en conexión con el Sistema de descubrimiento de conocimiento con Bases de Datos PostgresKDD y esta desarrollado bajo los lineamientos de software libre los hace herramientas accesibles para para cualquier empresa u organización que requiera de un apoyo en la toma de decisiones, de igual forma Pg_KDD apoya en las tareas de selección, minería de datos y visualización del proceso de Descubrimiento de Conocimiento con Bases de Datos.

La diferencia de este proyecto con Pg_KDD es que este no solo aplica tareas de minería de datos para el descubrimiento de reglas de clasificación si no también tareas de minería de datos para el descubrimiento de reglas de asociación, haciendo uso de operadores y primitivas que se encuentran dentro del sistema PostgresKDD, además que Pg_KDD contiene una interfaz adicional para la creación de sentencias graficas aplicando los conceptos generales como son selección, agrupamiento, ordenamiento, entre otros.

2.2 EL PROCESO DE DESCUBRIMIENTO DE CONOCIMIENTO EN BASES DE DATOS- DCBD

El DCBD es el proceso que utiliza métodos de minería de datos (algoritmos) para extraer (identificar) patrones que evaluados e interpretados, de acuerdo a las especificaciones de medidas y umbrales, usando una base de datos con alguna selección, pre procesamiento, muestreo y transformación, se obtiene lo que se piensa es conocimiento [6][8].

El proceso de DCBD es interactivo e iterativo, involucra numerosos pasos con la intervención del usuario en la toma de muchas decisiones y se resumen en las siguientes etapas:

- ✓ Selección
- ✓ Pre procesamiento/Data cleaning
- ✓ Transformación/Reducción
- ✓ Minería de Datos/Data Mining (DM)
- ✓ Interpretación/Evaluación

2.2.1 Minería de Datos. La minería de datos consiste en la extracción no trivial de información que reside de manera implícita en los datos. Dicha información era previamente desconocida y podrá resultar útil para algún proceso. En otras palabras, la minería de datos prepara, sondea y explora los datos para sacar la información oculta en ellos [31].

Bajo el nombre de minería de datos se engloba todo un conjunto de técnicas encaminadas a la extracción de conocimiento procesable, implícito en las bases de datos. Está fuertemente ligado con la supervisión de procesos industriales ya

que resulta muy útil para aprovechar los datos almacenados en las bases de datos [31].

Es una etapa dentro del proceso completo del descubrimiento del conocimiento, este intenta obtener patrones o modelos a partir de los datos recopilados. Decidir si los modelos obtenidos son útiles o no suele requerir una valoración subjetiva por parte del usuario. Según Fayyad, los algoritmos de DM suelen tener tres componentes [8]:

- ✓ El modelo, que contiene parámetros que han de fijarse en partir de los datos de entrada.

- ✓ El criterio de preferencia, que sirve para comparar modelos alternativos.

- ✓ El Algoritmo de búsqueda, que viene a ser como cualquier otro programa de inteligencia artificial (IA).

El criterio de preferencia suele ser algún tipo de heurística y los algoritmos de búsqueda empleados suelen ser los mismos que en otros programas de inteligencia artificial. Las principales diferencias entre los algoritmos de DM se hallan en el modelo de representación escogido y la función del mismo, es decir según el objetivo perseguido.

2.2.2 Tareas de Minería de Datos. Las técnicas DM empleadas en el proceso de KDD se pueden clasificar en dos grandes grupos:

- ✓ Técnicas de verificación, en las que el sistema se limita a comprobar hipótesis suministradas por el usuario.

- ✓ Métodos de descubrimiento, en los que se han de encontrar patrones potencialmente interesantes de forma automática, incluyendo en este grupo todas las técnicas de predicción.

El resultado obtenido con la aplicación de los algoritmos de DM al segundo grupo, el de técnicas de descubrimiento, pueden ser de carácter descriptivo o predictivo. Las predicciones sirven para prever el comportamiento futuro de algún tipo de entidad mientras que una descripción puede ayudar a su comprensión.

La aplicación de técnicas de DM en grandes bases de datos persiguen los siguientes resultados:

- ✓ **Clasificación:** Se trata de obtener un modelo que permita asignar un caso de clase desconocida a una clase concreta (seleccionada de un conjunto redefinido de clases), como son los árboles de clasificación (CART), cuyos resultados pueden expresarse mediante reglas ejecutables directamente del SQL o el método de Bayesiano.

- ✓ **Regresión:** Se persigue la obtención de un modelo que permita predecir el valor numérico de alguna variable (modelos de regresión logística).

- ✓ **Agrupamiento (clustering):** Hace corresponder cada caso de una clase, con la peculiaridad de que las clases se obtienen directamente de los datos de entrada utilizando medidas de similar dad. Es decir, agrupan a los datos bajo diferentes métodos y criterios. Las técnicas más usadas son las clásicas (distancia mínima) y las redes neuronales (método de Kohonen o método de Neural-Gas).

- ✓ **Resumen:** Se obtienen representaciones compactas para subconjuntos de los datos de entrada (análisis interactivo de datos, generación automática de informes, visualización de datos).

- ✓ **Modelado de Dependencias:** se obtienen descripciones de dependencias existentes entre variables. El análisis de relaciones (por ejemplo las reglas de asociación), en que se determinan relaciones existentes entre elementos de una base de datos, podría considerarse un caso particular de modelado de dependencias.

- ✓ **Análisis de Secuencias:** Se intenta modelar la evolución temporal de alguna variable, con los fines descriptivos o predictivos (redes neuronales multicapas).

2.2.3 Tarea de Asociación. La tarea de asociación se basa en los siguientes fundamentos [50]:

- Las entradas son un conjunto de ítems y una colección de transacciones (canastas)

- Sea I= {i1, i2,..., im) un conjunto de ítems.
- Sea D un conjunto de transacciones
- Cada transacción T es un conjunto de ítems tal que $T \subseteq I$.

- La tarea es generar reglas que cumplan un soporte y una confianza mínima expresados por el usuario.
  - Una regla de asociación es una implicación de la forma $X \Rightarrow Y$, donde $X \subset I$, $Y \subset I$ y $X \cap Y = \Phi$
  - La regla $X \Rightarrow Y$ tiene soporte ***s*** en D si s% de transacciones en D contienen $X \cup Y$.
  - La regla $X \Rightarrow Y$ se cumple en D con confianza ***c*** si c% de las transacciones en D que contienen X también contienen a Y.
  - **c** denota la solidez de la implicación y **s** indica la frecuencia de ocurrencia del patrón en la regla.

Pasos para minar reglas de asociación [50]:

- El problema de minar reglas de asociación es encontrar todas las reglas de asociación que satisfagan un soporte mínimo especificado por el usuario y una mínima restricción de confianza.

- El problema se descompone en los siguientes pasos:
  - Descubrir los ítemsets frecuentes, i.e., el conjunto de ítemsets que tienen el soporte de transacciones por encima de un predeterminado soporte **s** mínimo.
  - Usar los ítemsets frecuentes para generar las reglas de asociación para la base de datos.

- Todo el rendimiento de minar las reglas de asociación es determinado por el primer paso.

- Después de que los ítemsets frecuentes son identificados, las correspondientes reglas de asociación pueden ser derivadas de una manera directa.

El conteo eficiente de los ítemsets frecuentes es el centro de atención de los algoritmos de Asociación.

2.2.4 Tarea de Clasificación. La clasificación es una tarea de minería de datos por medio de la cual se encuentra propiedades comunes entre un conjunto de objetos de una base de datos y se los clasifica en diferentes clases, de acuerdo al modelo de clasificación [49].

Proceso de Clasificación

La Clasificación de datos es un proceso de dos pasos [49]:

En el primero, se construye un modelo con base en un conjunto de datos denominado conjunto de entrenamiento. En el conjunto de entrenamiento, cada tupla se asume que pertenece a una clase predefinida, determinada por un atributo clase. El resto de atributos se denominan atributos condición.

En el segundo, el modelo inicialmente se prueba con otro conjunto de datos denominado conjunto de prueba. La exactitud del modelo se calcula de acuerdo al porcentaje de ejemplos de prueba que son correctamente clasificados.

Métodos de Clasificación

Los métodos de clasificación se utilizan para descubrir clases en forma automática [49].

Algunos métodos de clasificación:

– Redes Neuronales
– Conjuntos aproximados (rough sets)
– Algoritmos genéticos
– Árboles de decisión

Clasificación por árboles de decisión

Un árbol de decisión es una estructura compuesto por nodos internos, ramas y hojas. Cada nodo interno denota a un atributo de prueba. Cada rama representa una salida o regla. Cada hoja representa a una clase. El nodo inicial se denomina nodo raíz. [49]
El algoritmo básico para árboles de decisión es el C4.5, el cual construye el árbol de arriba hacia abajo recursivamente utilizando la manera de “divide y

conquistaras". El algoritmo usa una métrica basada en la entropía, conocida como ganancia de información para construir el árbol. [49]

Ganancia de Información

Minimiza la medida de entropía aplicada a los ejemplos en un nodo. Esta heurística permite seleccionar el atributo que provee la mayor ganancia de información [49].

La ganancia de información de un atributo A, con respecto a un conjunto de ejemplos S es [49]:

$Gain(S,A) = Entropía(S) - \Sigma v \in Valores(A) * |Sv|/|S| * Entropía(Sv)$

Donde:

Valores(A) es el conjunto de todos los valores del atributo *A*
Sv es el subconjunto de *S* para el atributo *A* que toma valores *v.*

$Entropía(S) = -\Sigma pi \log_2 pi$, donde pi es la probabilidad que un ejemplo arbitrario pertenezca a la clase Ci.

2.2.5 Arquitecturas de Integración de DCBD con un SGBD. Muchos investigadores [2][30][13][20] han reconocido la necesidad de integrar los sistemas de Descubrimiento de Conocimiento con los Sistemas de Bases de Datos, haciendo de esta una área activa de investigación. Dentro de los enfoques de integración de KDD y SGBD reportados en la literatura se pueden ubicar en uno de tres tipos de arquitectura: sistemas débilmente acoplados, medianamente acoplados y sistemas fuertemente acoplados [31].

Una Herramienta para el DCBD debe integrar una variedad de componentes (técnicas de Minería de datos, consultas, métodos de visualización, interfaces, etc.), que juntos puedan eficientemente identificar y extraer patrones interesantes y útiles de los datos almacenados en las bases de datos.

Una arquitectura es débilmente acoplada cuando los algoritmos de Minería de Datos y demás componentes se encuentran en una capa externa al SGBD, por fuera del núcleo y su integración con este se hace a partir de una interfaz [31]

Una arquitectura es medianamente acoplada cuando ciertas tareas y algoritmos de descubrimiento de patrones se encuentran formando parte del SGBD mediante procedimientos almacenados o funciones definidas por el usuario [31].

Una arquitectura es fuertemente acoplada cuando la totalidad de las tareas y algoritmos de descubrimiento de patrones forman parte del SGBD como una operación primitiva, dotándolo de las capacidades de descubrimiento de conocimiento y posibilitándolo para desarrollar aplicaciones de este tipo (ver Figura 1).

Figura 1. Sistema de Minería de Datos Fuertemente Acoplada con un SGBD.

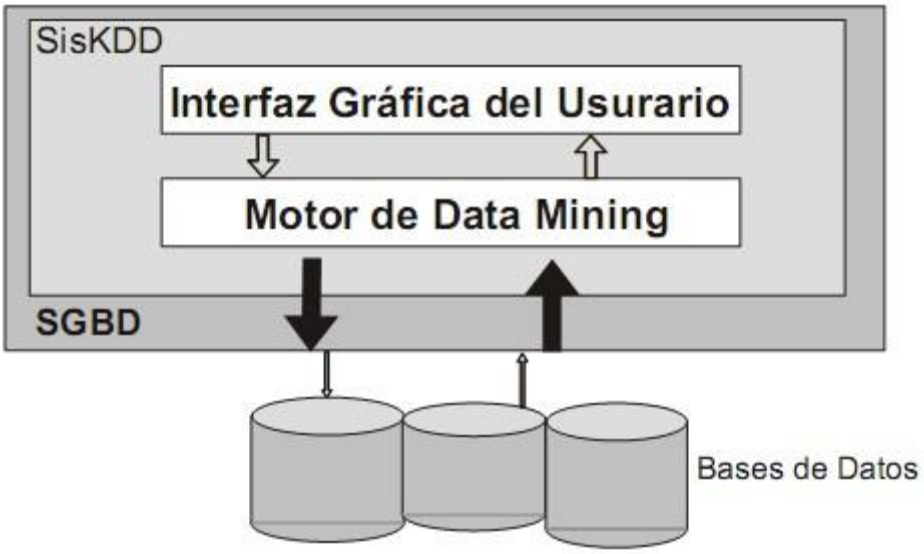

Fuente. Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. [31]

2.3 METODOLOGÍA PARA EL DESARROLLO DE Pg_KDD

Con la finalidad de realizar el análisis y el diseño del proyecto Pg_KDD se adoptó la metodología Proceso Unificado (RUP) que utiliza la notación del Lenguaje Unificado de Modelado (UML). De este modo, Pg_KDD fue desarrollado siguiendo los estándares de modelado que plantea RUP. Para comprender sus lineamientos es necesario conocer, manejar y poder utilizar los diagramas del Lenguaje Unificado de Modelado (UML) que, a su vez, se basa en el paradigma de

programación Orientado a Objetos. Seguidamente se explicará en qué consisten cada una de estas herramientas del análisis, diseño y modelado de sistemas computacionales.

2.3.1 Análisis y diseño de sistemas usando la metodología orientada a objetos (O.O). Las metodologías de Ingeniería de Software tienen mecanismos para hacer análisis de necesidades y diseño de sistemas complejos, y han evolucionado con la tecnología en relación con el diseño computacional.

Así, por ejemplo, el análisis estructurado se basa en la descomposición en funciones o procesos. La metodología (Orientada a objetos), se centra en el análisis usando una descomposición del sistema por objetos o conceptos [33][38].

De acuerdo a Joseph Schmuller,

> Los objetos concretos y virtuales, están a nuestro alrededor, ellos conforman nuestro mundo. El software actual simula al mundo (o un segmento de él), y los programas, por lo general, imitan los objetos del mundo. Si comprende algunas cuestiones básicas de los objetos, entenderá cómo se deben mostrar estos en las representaciones de software. Antes que nada, un objeto es la instancia de una clase (o categoría). Usted y yo, por ejemplo, somos instancias de la clase persona. Un objeto cuenta con una estructura, es decir atributos (propiedades) y acciones. Las acciones son todas las actividades que el objeto es capaz de realizar. Los atributos y acciones, en conjunto, se conocen como características o rasgos [1].

Schmuller define a los objetos no solo como aquello que tiene masa, sino también habla de la posibilidad de encontrar objetos virtuales, que no pueden tocarse, como por ejemplo una dirección de correo electrónico.

La metodología O.O. trae una serie de ventajas. Por ejemplo: el suministro de modelos similares a los del mundo real, la facilidad para manejar sistemas complejos y la reutilización de los objetos, permite además el desarrollo iterativo de las aplicaciones y también facilita la interoperabilidad de las mismas.

1. Schmuller, Joseph. Aprendiendo UML en 24 horas. Prentice-Hall, 2001

Según lo que menciona Schmuller un objeto cuenta con atributos y acciones.

Dicho de otro modo, los **Atributos** pueden considerarse como un estado, o conjunto de propiedades inherentes a él. Las acciones pueden catalogarse como un conjunto de operaciones o **Métodos**. Pero, además, los objetos tienen también, una **Identidad**, es decir, un identificador que los hará únicos [33][38].

Desde un punto de vista enfocado a la programación puede decirse que un objeto es una parte de software que cumple con ciertas características como:

- ✓ ***Herencia*****:** una clase (clase derivada) puede adoptar los atributos y métodos de una clase superior (superclase), de esta manera, cuando se crea un objeto como instancia de una clase, éste tendrá todas las características tanto de la clase de la cual es instancia, como de la superclase de la cual ésta hereda [38][39].

- ✓ ***Polimorfismo***: hace referencia a como una operación puede tener el mismo nombre en una misma clase y, sin embargo, puede realizar diferentes procesos. A esto se le conoce como *Sobrecarga de Métodos*. La clave está en los valores de entrada que reciben dichas operaciones [38][39].

  El polimorfismo también se presenta en el momento en que una superclase define una operación y sus clases derivadas redefinen los procesos que se ejecutan dentro de ella. Así, al llamar a determinada operación redefinida, se ejecuta la redefinición y no la definición original en la superclase. Esto recibe el nombre de *Redefinición de Métodos* [38][39].

- ✓ ***Encapsulamiento***: esta característica de los objetos hace que se oculten sus funcionalidades internas, así solo se encargarán de realizar las acciones que le correspondan sin que el usuario se dé cuenta de qué es lo que pasa en su interior. esta característica hace que se protejan los datos de accesos indebidos, la forma de protegerlos es haciendo que los objetos puedan ser privados, protegidos o públicos [38][39].

- ✓ ***Abstracción***: existen diferentes mecanismos de abstracción, como por ejemplo composición, clasificación, agrupación y especialización [38][39].

Una Clase es la unidad básica que encapsula toda la información de un objeto. A través de ellas se puede modelar el entorno, o la categoría de un objeto. Todos los objetos se crean por instancia de las clases.

2.3.2 El lenguaje unificado de modelado (UML). Un modelo puede considerarse como la abstracción de un sistema del mundo real, este modelo se encarga de describir completamente los aspectos del sistema que son relevantes para un nivel de abstracción dado, teniendo en cuenta los detalles importantes del sistema real [38][39].

La necesidad de nuevas formas de diseño ha dado pie a la creación de nuevas herramientas que permitan a los diseñadores de sistemas trabajar de forma que los demás comprendan las ideas de sus modelos.

UML es una de las herramientas más utilizadas para el modelado de sistemas. Nació en la empresa Rational Software Co, quien se puso en la tarea de crear una notación unificada en la qué basar la construcción de sus herramientas CASE. En el proceso de creación de UML han participado, empresas de gran peso en la industria como Microsoft, Hewlett-Packard, Oracle e IBM, así como grupos de analistas y desarrolladores; y su desarrollo fue encabezado por: Grady Booch, Ivar Jacobson y Jim Rumbaugh [33][38][39].

Uno de los objetivos principales de la creación de UML era posibilitar el intercambio de modelos entre las distintas herramientas CASE orientadas a objetos del mercado.

Pero, específicamente ¿Qué es UML?

Según Grady Booch, James Rumbaugh e Ivar Jacobson, “El lenguaje unificado de modelado (Unified Modeling Language, UML) es un lenguaje estándar para escribir planos de software. UML puede utilizarse para visualizar, especificar, construir, y documentar los artefactos de un sistema con gran cantidad de Software” [33][38].

UML combina notaciones provenientes del modelo orientado a objetos, el modelo de datos, el modelo de componentes y modelo de flujos de trabajo, y la principal característica es que está dirigido por casos de uso y se centra en la arquitectura.

Esta combinación da origen a tres clases de bloques de construcción que son [33][38]:

- ✓ ***Elementos***: los elementos son abstracciones de cosas reales o ficticias como objetos o acciones.

- ✓ ***Relaciones***: formas de relacionar los *elementos* entre sí.

- ✓ ***Diagramas***: son colecciones de *elementos* con sus *relaciones*.

Profundizando un poco más en los diagramas. Un diagrama es la representación gráfica de un conjunto de elementos con sus relaciones, ofrece una vista del sistema a modelar. Para poder representar correctamente un sistema, UML ofrece una amplia variedad de diagramas para visualizar el sistema desde varias perspectivas.

Los diferentes tipos de diagramas que se utilizan en UML son:

- ✓ *Diagrama de Casos de uso*
- ✓ *Diagrama de clases*
- ✓ *Diagrama de Objetos*

Diagramas de Comportamiento

- ✓ *Diagrama de Estados*
- ✓ *Diagrama de Actividad*

Diagramas de Interacción

- ✓ Diagrama de secuencia
- ✓ Diagrama de colaboración

Diagramas de Implementación

- ✓ Diagrama de Componentes
- ✓ Diagrama de Despliegue

Diagramas: Los diagramas más utilizados en el modelamiento de sistemas como Pg_KDD son:

- ***Diagrama de Casos de Uso***: Muestra la relación entre los actores y los casos de uso del sistema. Representa la funcionalidad que ofrece el sistema en lo que se refiere a su interacción externa. Se define un caso de uso como cada interacción supuesta con el sistema a desarrollar, donde se representan los requisitos funcionales. Es decir, se está diciendo lo que tiene que hacer un sistema y cómo, (Figura 2) [33][38][39].

Figura 2: Representación gráfica de un Diagrama de Casos de Uso

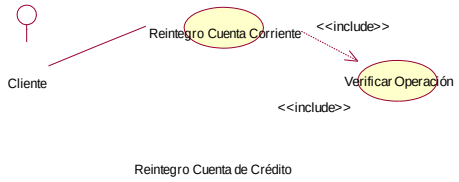

Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley [38].

- ***Diagrama de clases:*** Muestra un conjunto de clases, interfaces y sus relaciones, es el diagrama más común a la hora de escribir un diseño de los sistemas orientados a objetos, (Figura 3) [38][39].

Figura 3: Representación gráfica de un Diagrama de clases

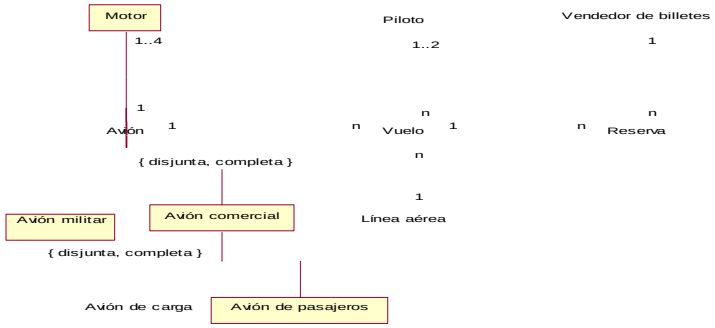

Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley [38].

- ***Diagrama de secuencia:*** Se muestra en la interacción entre los actores y los objetos que componen un caso de uso o una operación (Figura 4).

Figura 4: Representación gráfica de un Diagrama de secuencia

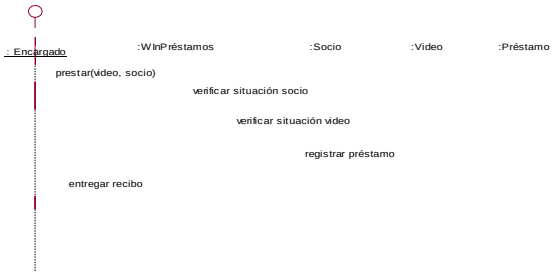

Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley [38].

Los diagramas expresan gráficamente las partes de un modelo (Figura 5). Un modelo es una abstracción del sistema centrada en una estructura semántica determinada. Los modelos están compuestos por un conjunto de diagramas según lo establezca la metodología de modelamiento seleccionada. Por ejemplo, en el Proceso Unificado, el Modelo de Análisis cuenta con diagramas de clases y de colaboración [38][39].

Figura 5: Representación de los diagramas que componen un Modelo

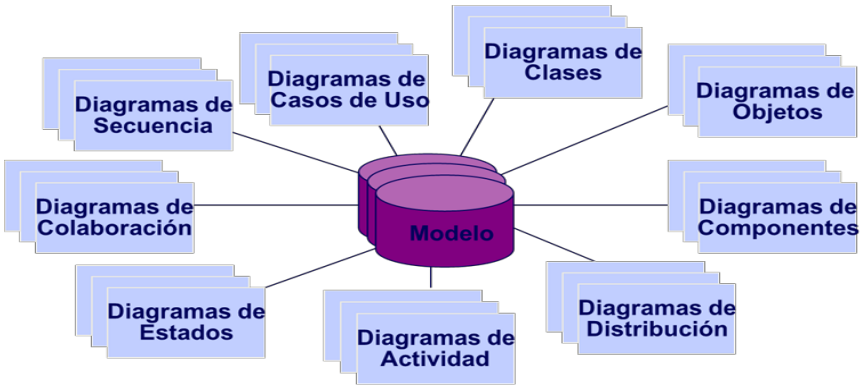

Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley. [38]

Todos estos diagramas deben organizarse en paquetes. Un paquete (Figura 6) es un mecanismo de propósito general para organizar elementos en grupos;

elementos estructurales, elementos de comportamiento, etc. Un paquete es puramente conceptual, es decir que solo existe en el tiempo de desarrollo. Gráficamente un paquete se visualiza como una carpeta, incluyendo normalmente su nombre y en ocasiones su contenido [38][39].

Figura 6: Representación gráfica de un paquete

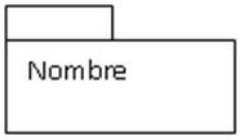

Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley. [38]

Relaciones: En UML existen cuatro tipos de relaciones: dependencia, asociación, generalización y realización [38][39].

- ✓ ***Dependencia***: es una relación semántica entre dos elementos. en la cual el cambio de un elemento puede afectar la semántica de otro, se representa gráficamente de la siguiente manera (Figura 7):

  Figura 7: Representación gráfica de una relación tipo Dependencia

  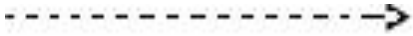

  Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley. [38]

- ✓ ***Asociación***: es una relación estructural que describe cómo una clase está asociada a otra al tener en sus atributos objetos de dicha clase (Figura 8). Existe una relación de asociación especial denominada agregación (Figura 9).

Figura 8: Representación gráfica de una relación tipo Asociación

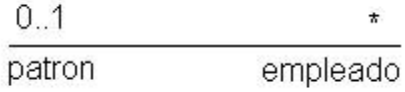

Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley. [38]

- ✓ ***Agregación***: es una relación de asociación que sirve para indicar que la asociación es de composición, es decir, que un objeto está compuesto por otro. La diferencia de la asociación y la agregación es prácticamente conceptual y se hace evidente cuando el objeto componente no puede existir o funcionar completamente sin el objeto agregado.

  Por ejemplo, es posible que un objeto casa (de la clase Vivienda) esté compuesto por un objeto mueble (de la clase ComponentesDeLaVivienda) y por otro objeto paredes (de la clase MuroEstructural). En el primer caso la relación sería de *asociación* debido a que una casa sigue siendo casa si no posee sillas o muebles; pero, la segunda relación sería de *agregación* dado que una casa sin paredes no tendría aspecto de casa sino de kiosco.

Figura 9: Representación gráfica de una relación tipo Agregación

Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley. [38]

- ✓ ***Generalización***: es una relación de especialización en la cual los objetos del elemento generalizado pueden sustituir los objetos del elemento general (hijo - padre). De esta forma el hijo comparte la estructura y el comportamiento del padre. (Figura 10)

Figura 10: Representación gráfica de una relación tipo Generalización

Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley. [38]

- ✓ ***Realización***: es una relación semántica entre clasificadores, en donde un clasificador especifica un contrato que otro clasificador garantiza que cumplirá. Se pueden encontrar relaciones de realización entre interfaces y clases que las implementan, y entre casos de uso y colaboraciones que los realizan (Figura 11).

Figura 11: Representación gráfica de una relación tipo Realización

Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley. [38]

2.3.3 El modelo del proceso unificado (RUP). El Proceso Unificado (RUP) se basa en la metodología Orientada a Objetos (O.O.) y utiliza, para representar los elementos del sistema, los procesos y los flujos de datos, los diagramas del UML [39].

Aunque UML es independiente del proceso de desarrollo, los creadores (Grady Booch, Ivar Jacobson y Jim Rumbaugh [33][38][39]) de UML propusieron su propia metodología de desarrollo denominada Proceso Unificado de Desarrollo.

Las características principales de RUP son tres [33][38]:

- ✓ **Dirigido por casos de uso:** Un caso de uso representa una pieza de funcionalidad en el sistema que le devuelve al usuario un resultado de valor. Los casos de uso sirven para capturar requerimientos funcionales.

- ✓ **Centrado en la arquitectura:** Los casos de uso son desarrollados en conjunto con la arquitectura del sistema y se desarrollan a medida que lo hace el ciclo de vida.

- ✓ **Iterativo e incremental:** La vida de un sistema se encuentra dividida en ciclos. Cada ciclo termina con un lanzamiento de diferentes modelos del producto y consiste de cuatro fases.

El RUP se compone de 4 fases (ver Figura 12). Dichas fases, son una especie de mini proyectos en las que se repiten, iteración tras iteración, los pasos normales de un ciclo de vida de desarrollo. Es decir, el Análisis, el Diseño, la Implementación y las Pruebas, entre otras. Se realizan en cada una de las iteraciones, una y otra vez hasta completar la fase actual y pasar a la siguiente. Las iteraciones repetitivas van proporcionando resultados inmediatos comparables al desarrollo incremental basado en prototipos [33][39].

Las fases sirven para alcanzar hitos o puntos de toma de decisiones en cuanto a continuar o no con el desarrollo del proyecto dependiendo de los resultados obtenidos.

Las fases son [33][39]:

- ✓ *Inicio*: Se realizará una adecuada delimitación del alcance del software. Se establecerán los temas, subtemas y ejercicios que abordan tanto el módulo de información teórica como el módulo de ejercicios prácticos. Igualmente se establecerá el alcance del módulo de ejercicios planteados por el usuario.

  En cuanto a los criterios de éxito, se determinará el resultado esperado al terminar cada una de las iteraciones.

- ✓ *Elaboración*: Se determinará el mayor número de requisitos específicos del aplicativo y se realizará un prototipo con los casos de uso más significativos.

  De esta manera se determinará de forma detallada el contenido de cada uno de los temas, subtemas y ejercicios, además de los respectivos requisitos del solucionador de ejercicios, entre ellos: la forma cómo el usuario se comunicará con él, el debido procedimiento que se llevará a cabo tras cada iteración en el desarrollo de un ejercicio y la forma en que el sistema proporcionará los resultados obtenidos.

- ✓ *Construcción*: Se desarrollará cada uno de los módulos diseñados para el sistema. El módulo de información teórica deberá explicar cualquiera de los temas, el módulo de ejercicios prácticos debe estar en capacidad de explicar cualquiera de los ejercicios del sistema y el solucionador de ejercicios debe poder realizar sin ningún problema cualquier ejercicio que el usuario le plantee. De cada una de las operaciones se realizarán las pruebas respectivas.

- ✓ *Transición*: Se realizarán las pruebas finales del aplicativo y se procederá a la utilización del sistema en una prueba piloto. En ella se observará cómo el grupo de estudiantes responde al uso del aplicativo y se determinará si es necesario implementar un requisito adicional. Al final de esta fase se tendrá el producto terminado: Pg_KDD.

Figura 12: Etapas de Desarrollo

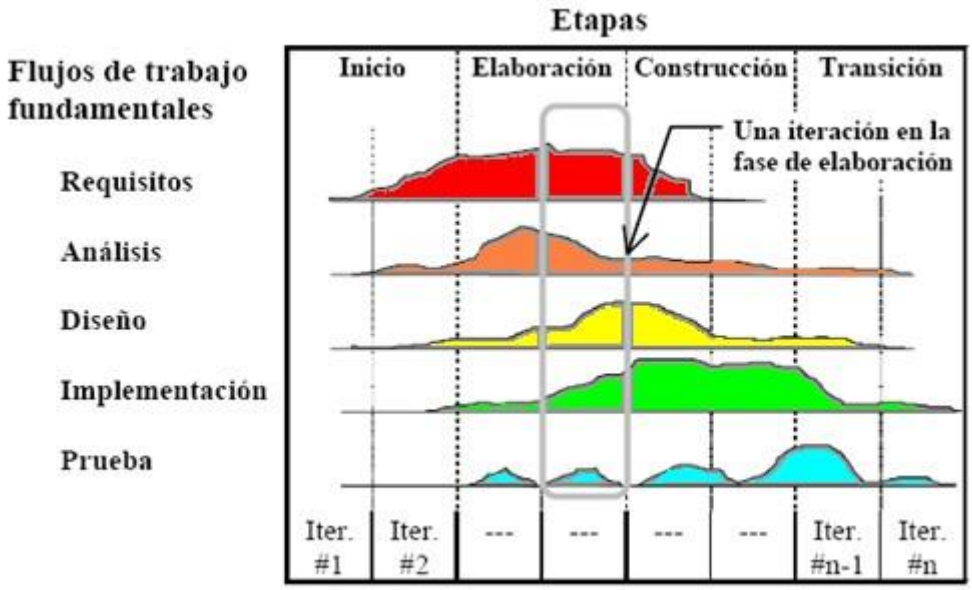

Fuente. BOOCH, GRADY; RUMBAUGH, JAMES; JACOBSON, IVAR. El Proceso Unificado de Desarrollo. Madrid, 2000, Addison Wesley. [39]

2.4 HERRAMIENTAS DE DESARROLLO

Entre las principales herramientas de desarrollo podemos encontrar al lenguaje de programación Java, el entorno de desarrollo NetBeans y la biblioteca gráfica Swing para Java.

Java es un lenguaje de programación orientado a objetos, desarrollado por Sun Microsystems a principios de los años 90. El lenguaje en sí mismo toma mucha de su sintaxis de C y C++, pero tiene un modelo de objetos más simple y elimina herramientas de bajo nivel, que suelen inducir a muchos errores, como la manipulación directa de punteros o memoria [34].

Las aplicaciones Java están típicamente compiladas en un bytecode, aunque la compilación en código máquina nativo también es posible. En el tiempo de ejecución, el bytecode es normalmente interpretado o compilado a código nativo para la ejecución, aunque la ejecución directa por hardware del bytecode por un procesador Java también es posible.

La implementación original y de referencia del compilador, la máquina virtual (VM) y las bibliotecas de clases de Java fueron desarrolladas por Sun Microsystems en 1995. Desde entonces, Sun ha controlado las especificaciones, el desarrollo y evolución del lenguaje a través del Java Community Process, si bien otros han desarrollado también implementaciones alternativas de estas tecnologías de Sun, algunas incluso bajo licencias de software libre. Pero actualmente Oracle quien compro a Sun en el año 2009, es quien, junto con sus desarrolladores, lidera el desarrollo Java en el momento [34].

A continuación se explican brevemente los conceptos preliminares de estas herramientas para ser tenidas en cuenta en la posterior descripción de la implementación que se realiza en este capítulo.

2.4.1 Lenguaje de Programación Java. Java es un lenguaje de programación orientado a objetos desarrollado por James Gosling y sus compañeros de Sun Microsystems al inicio de la década de 1990. A diferencia de los lenguajes de programación convencionales, que generalmente están diseñados para ser compilados a código nativo, Java es compilado en un bytecode que es ejecutado

usando normalmente un compilador JIT (Just in Time), por una máquina virtual Java [34].

El lenguaje Java se crea con cinco objetivos principales [34]:

- ✓ Deberá usar la metodología de la programación orientada a objetos.
- ✓ Deberá permitir la ejecución de un mismo programa en múltiples sistemas operativos.
- ✓ Deberá incluir por defecto soporte para trabajo en red.
- ✓ Deberá diseñarse para ejecutar código en sistemas remotos de forma segura.
- ✓ Deberá ser fácil de usar y tomar lo mejor de otros lenguajes orientados a objetos, como C++.

Entre sus principales características se encuentran:

Orientado a Objetos [34]. La primera característica, orientado a objetos (”OO”), se refiere a un método de programación y al diseño del lenguaje. Aunque hay muchas interpretaciones para OO, una primera idea es diseñar el software de forma que los distintos tipos de datos que use están unidos a sus operaciones. Así los datos y el código (funciones o métodos) se combinan en entidades llamadas objetos. Un objeto puede verse como un paquete que contiene el “comportamiento” (el código) y el “estado” (datos) [34].

El principio es separar aquello que cambia de las cosas que permanecen inalterables. Frecuentemente, cambiar una estructura de datos implica un cambio en el código que opera sobre los mismos, o viceversa. Esta separación en objetos coherentes e independientes ofrece una base más estable para el diseño de un sistema software. El objetivo es hacer que grandes proyectos sean fáciles de gestionar y manejar, mejorando como consecuencia su calidad y reduciendo el número de proyectos fallidos. Otra de las grandes promesas de la programación orientada a objetos es la creación de entidades más Genéricas (objetos) que permitan la reutilización del software entre proyectos, una de las premisas fundamentales de la Ingeniería del Software. Un objeto genérico “cliente”, por ejemplo, Deberá en teoría tener el mismo conjunto de comportamiento en diferentes proyectos, sobre todo cuando estos coinciden en cierta medida, algo que suele suceder en las grandes organizaciones. En este sentido, los objetos Podría verse como piezas reutilizables que pueden emplearse en múltiples proyectos distintos, posibilitando así a la industria del software a construir

proyectos de envergadura empleando componentes ya existentes y de comprobada calidad; conduciendo esto finalmente a una reducción drástica del tiempo de desarrollo. Podemos usar como ejemplo de objeto el aluminio. Una vez definidos datos (peso, maleabilidad, etc.), y su “comportamiento” (soldar dos piezas, etc.), el objeto “aluminio” puede ser reutilizado en el campo de la construcción, del automóvil, de la aviación, etc.

Independencia de la plataforma [34]. La segunda característica, la independencia de la plataforma, significa que programas escritos en el lenguaje Java pueden ejecutarse igualmente en cualquier tipo de hardware. Es lo que significa ser capaz de escribir un programa una vez y que pueda ejecutarse en cualquier dispositivo, tal como reza el axioma de Java, “write once, run everywhere”. Para ello, se compila el código fuente escrito en lenguaje Java, para generar un código conocido como ”bytecode” (específicamente Java bytecode) que son instrucciones máquina simplificadas específicas de la plataforma Java. Esta pieza está “a medio camino” entre el código fuente y el código máquina que entiende el dispositivo destino. El bytecode es ejecutado entonces en la máquina virtual, un programa escrito en código nativo de la plataforma destino (que es el que entiende su hardware), que interpreta y ejecuta el código. Además, se suministran librerías adicionales para acceder a las características de cada dispositivo (como los gráficos, ejecución mediante hebras o threads, la interfaz de red) de forma unificada. Se debe tener presente que, aunque hay una etapa explícita de compilación, el bytecode generado es interpretado o convertido a instrucciones máquina del código nativo por el compilador JIT.

El recolector de basura [34]. Un argumento en contra de lenguajes como C++ es que los programadores se encuentran con la carga añadida de tener que administrar la memoria de forma manual. En C++, el desarrollador debe asignar memoria en una zona conocida como heap (montículo) para crear cualquier objeto, y posteriormente desalojar el espacio asignado cuando desea borrarlo. Un olvido a la hora de desalojar memoria previamente solicitada, o si no lo hace en el instante oportuno, puede llevar a una fuga de memoria, ya que el sistema operativo piensa que esa zona de memoria está siendo usada por una aplicación cuando en realidad no es así así un programa mal diseñado Podría consumir una cantidad desproporcionada de memoria. Además, si una misma Región de memoria es desalojada dos veces el programa puede volverse inestable y llevar a un eventual cuelgue.

En Java, este problema potencial es evitado en gran medida por el recolector automático de basura (o automatic garbage collector). El programador determina cuándo se crean los objetos y el entorno en tiempo de ejecución de Java (Java runtime) es el responsable de gestionar el ciclo de vida de los objetos. El programa, u otros objetos pueden tener localizado un objeto mediante una referencia a éste (que, desde un punto de vista de bajo nivel es una dirección de memoria). Cuando no quedan referencias a un objeto, el recolector de basura de Java borra el objeto, liberando así la memoria que ocupaba previniendo posibles fugas (ejemplo: un objeto creado y únicamente usado dentro de un método sólo tiene entidad dentro de éste; al salir del método, el objeto es eliminado). Aun así es posible que se produzcan fugas de memoria si el código almacena referencias a objetos que ya no son necesarios es decir, pueden aún ocurrir, pero en un nivel conceptual superior. En definitiva, el recolector de basura de Java permite una fácil creación y eliminación de objetos, mayor seguridad y frecuentemente más rápida que en C++.

La recolección de basura de Java es un proceso prácticamente invisible al desarrollador. Es decir, el programador no tiene conciencia de cuándo la recolección de basura tendrá lugar, ya que ésta no tiene necesariamente que guardar relación con las acciones que realiza el código fuente. Debe tenerse en cuenta que la memoria es sólo uno de los muchos recursos que deben ser gestionados.

2.4.2 Entorno de Desarrollo NetBeans. NetBeans se refiere a una plataforma para el desarrollo de aplicaciones de escritorio usando Java y a un Entorno integrado de desarrollo (IDE) desarrollado usando la Plataforma NetBeans [44].

La plataforma NetBeans permite que las aplicaciones sean desarrolladas a partir de un conjunto de componentes de software llamados módulos. Un módulo es un archivo Java que contiene clases de Java escritas para interactuar con las APIs de NetBeans y un archivo especial (manifest file) que lo identifica como módulo. Las aplicaciones construidas a partir de módulos pueden ser extendidas agregándole nuevos módulos. Debido a que los módulos pueden ser desarrollados independientemente, las aplicaciones basadas en la plataforma NetBeans pueden ser extendidas fácilmente por otros desarrolladores de software [44].

La Plataforma NetBeans es un framework reusable que simplifica el desarrollo de otras aplicaciones de escritorio. Cuando se ejecuta una aplicación basada en la

Plataforma NetBeans, la plataforma ejecuta la clase Main. Los módulos disponibles están localizados y puestos en un registro en memoria, y son ejecutadas las tareas de inicialización de los módulos. Generalmente el código de un módulo es cargado en memoria solo cuando se necesita. La plataforma ofrece servicios comunes a las aplicaciones de escritorio, permitiéndole al desarrollador enfocarse en la lógica específica de su aplicación [44].

Entre las características de la plataforma están [44]:

- ✓ Administración de las interfaces de usuario (ej. menús y barras de herramientas).
- ✓ Administración de las configuraciones del usuario.
- ✓ Administración del almacenamiento (guardando y cargando cualquier tipo de dato).
- ✓ Administración de ventanas.
- ✓ Framework basado en asistentes (diálogos paso a paso).

2.4.3 Controlador JDBC. JDBC es el acrónimo de Java Database Connectivity, un API que permite la ejecución de operaciones sobre bases de datos desde el lenguaje de programación Java independientemente del sistema de operación donde se ejecute o de la base de datos a la cual se accede utilizando el dialecto SQL del modelo de base de datos que se utilice [45].

El API JDBC se presenta como una colección de interfaces Java y métodos de gestión de manejadores de conexión hacia cada modelo específico de base de datos. Un manejador de conexiones hacia un modelo de base de datos en particular es un conjunto de clases que implementan las interfaces Java y que utilizan los métodos de registro para declarar los tipos de localizadores a base de datos (URL) que pueden manejar. Para utilizar una base de datos particular, el usuario ejecuta su programa junto con la librería de conexión apropiada al modelo de su base de datos, y accede a ella estableciendo una conexión, para ello provee en localizador a la base de datos y los parámetros de conexión específicos. A partir de allí puede realizar cualquier tipo de tareas con la base de datos a las que tenga permiso: consultas, actualizaciones, creado modificado y borrado de tablas, ejecución de procedimientos almacenados en la base de datos, etc. [45].

Cada base de datos emplea un protocolo diferente de comunicación, protocolos que normalmente son propietarios. El uso de un manejador, una capa intermedia

entre el código del desarrollador y la base de datos, permite independizar el código Java que accede a la BD del sistema de BD concreto a la que estamos accediendo, ya que en nuestro código Java emplearemos comandos estándar, y estos comandos serían traducidos por el manejador a comandos propietarios de cada sistema de BD concreto. Si queremos cambiar el sistema de BD que empleamos lo único que deberemos hacer es remplazar el antiguo manejador por el nuevo, y seremos capaces de conectarnos la nueva BD [45].

2.4.4 Manejador de Protocolo Nativo (tipo 4). El manejador traduce directamente las llamadas al API JDBC al protocolo nativo de la base de datos (ver Figura 13). Es el manejador que tiene mejor rendimiento, pero está más ligado a la base de datos que empleemos que el manejador tipo JDBC-Net, donde el uso del servidor intermedio nos da una gran flexibilidad a la hora de cambiar de base de datos. Este tipo de manejadores también emplea Tecnología 100 % Java [46].

Figura 13: Representación manejo protocolo nativo JAVA

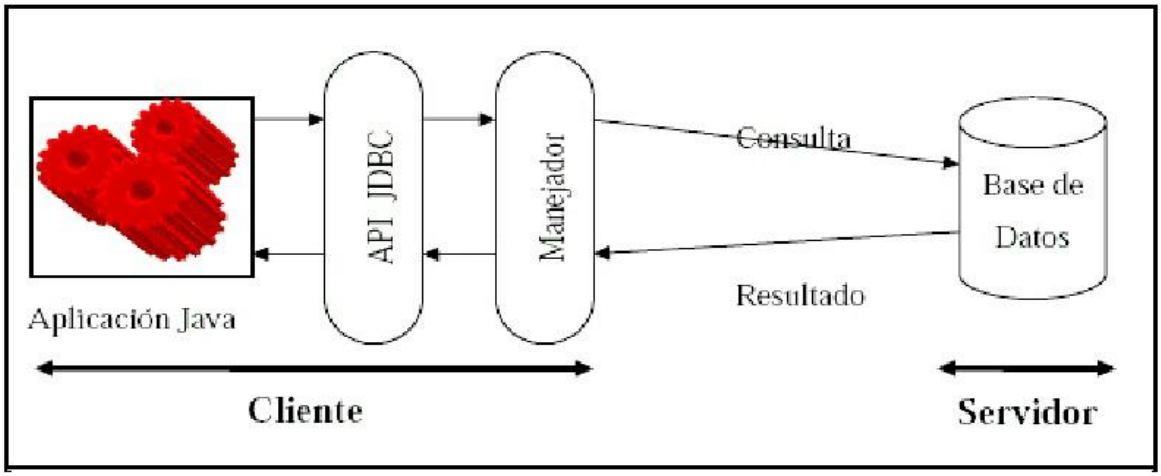

Fuente. El ABC de Jdbc. http://es.scribd.com/doc/84530902/El-ABC-Jdbc2.

2.4.5 Biblioteca gráfica Swing de Java. Swing es una biblioteca gráfica para Java que forma parte de las Java Foundation Classes (JFC). Incluye componentes para interfaz gráfica de usuario tales como cajas de texto, botones, listas desplegables y tablas [47].

Las Internet Foundation Classes (IFC) eran una biblioteca gráfica para el lenguaje de programación Java desarrollada originalmente por Netscape y que se publicó en 1996. En 1997, Sun Microsystems y Netscape Communications Corporation anunciaron su intención de combinar IFC con otras Tecnología de las Java Foundation Classes. Además de los componentes ligeros suministrados originalmente por la IFC, Swing introdujo un mecanismo que permite que el aspecto de cada componente de una aplicación pudiese cambiar sin introducir cambios sustanciales en el código de la aplicación. La introducción de soporte ensamblable para el aspecto permitió a Swing emular la apariencia de los componentes nativos manteniendo las ventajas de la independencia de la plataforma [47].

Algunos de los componentes utilizados en el desarrollo de este proyecto y pertenecientes a la biblioteca Swing se explican a continuación:

- ✓ JComponent. La clase base para todos los componentes de Swing exceptuando los contenedores de nivel superior. Para utilizar un componente que herede de JComponent, se debe poner el componente en una jerarquía de la contención cuya raíz sea un contenedor de nivel superior Swing tal como Ventanas o Paneles. Los contenedores de nivel superior son los componentes especializados que proporcionan un lugar para que otros componentes de Swing puedan pintarse.
- ✓ JFrame. Un JFrame es una ventana de nivel superior con un título y un borde. El tamaño del JFrame incluye cualquier área señalada por los bordes donde puede ser incluido uno o más componentes de Swing.
- ✓ JPanel. El JPanel es la clase más simple del contenedor. Un JPanel proporciona el espacio en el cual una aplicación puede unir cualquier otro componente, incluyendo otros paneles.
- ✓ JTabbedPane. Un componente que deja a usuario cambiar entre un grupo de componentes pulsando en una etiqueta con un título dado y/o un icono. Las etiquetas y los componentes son agregados a un objeto de TabbedPane usando los métodos del addTab e insertTab. Una etiqueta es representada por un índice que corresponde a la posición que fue agregado adentro, donde la primera etiqueta tiene un índice igual a 0 y la etiqueta pasada tiene un índice igual a la cuenta de la etiqueta menos 1.
- ✓ JSplitPane. JSplitPane se utiliza para dividir dos (y solamente dos) componentes. Los dos componentes se pueden entonces volver a clasificar según el tamaño recíprocamente por el usuario. La información sobre cómo usar JSplitPane está en cómo utilizar los paneles partidos en la clase

particular de Java. Se pueden incluir nuevos componentes en cada una de las divisiones de un JSplitPane. Los dos componentes en un panel partido se pueden alinear a la izquierda y a la derecha usando JSplitPane.HORIZONTAL SPLIT, o en la parte superior o inferior de la ventana con JSplitPane.VERTICAL SPLIT.

- ✓ JScrollPanne. JScrollPanne proporciona una vista deslizante de un componente ligero. Un JScrollPanne maneja un viewport, barras de desplazamiento vertical y horizontal opcional, y viewports opcionales del título de la fila y de columna. El viewport, o punto de vista, proporciona una ventana sobre una fuente de datos, por ejemplo, un archivo de texto o una imagen sobre la cual se va a deslizar.
- ✓ JFileChooser. Los seleccionadores de archivos proporcionan una interfaz gráfica de usuario para navegar el sistema de ficheros, y después elegir un archivo o un directorio de una lista o incorporar el nombre de un archivo o un directorio. Para exhibir un seleccionador de archivo, se utiliza generalmente el JFileChooser para mostrar un diálogo modal que contiene el seleccionador de archivo. Otra manera de presentar un seleccionador es agregar una instancia.
- ✓ JTable. Con la clase de JTable se puede exhibir una tabla de datos, permitiendo opcionalmente que el usuario edite el contenido de las celdas que contienen los datos. JTable no contiene ni deposita datos; es simplemente una vista de los datos.
- ✓ JTree. Con la clase JTree, puedes exhibir datos jerárquicos. Un objeto JTree no contiene realmente los datos sino que proporciona simplemente una vista de ellos. Como cualquier componente no trivial del Swing, el árbol consigue los datos conectándose a un modelo de los datos, un excelente componente para manejo de visualización de conexiones, bases de datos, tablas, campos, restricciones y demás en para este proyecto en específico y para proyectos similares o que requieran de manejo de este útil objeto de la Swing de Java.
- ✓ JTextArea. Un JTextArea es un área multilínea que exhibe el texto plano y que permite opcionalmente que el usuario corrija el texto. Este es un componente ligero que provee de compatibilidad a la hora de introducción o despejar pequeñas cantidades de información.
- ✓ JSpinner. Esta clase provee en una sola línea la posibilidad al usuario de entrar o seleccionar un valor de una secuencia pedida. Los JSpinner proporciona típicamente un par de los botones minúsculos de flechas para cambiar entre los elementos de la secuencia. Las teclas de flecha arriba/abajo del teclado también completan un ciclo a través de los

elementos. El usuario puede también mecanografiar el valor directamente en un JSpinner.

- ✓ JComboBox. Un componente que combina un botón o un campo editable y una lista desplegable. El usuario puede seleccionar un valor de la lista, que aparece a petición del usuario. Si la caja de texto es editable, entonces se incluye un campo en el cual el usuario pueda mecanografiar un valor.
- ✓ JRadioButton. Una puesta en práctica de un botón de radio. Este es un componente que puede ser seleccionado o deseleccionado, y que exhibe su estado al usuario. Utilizado con un objeto ButtonGroup crea un grupo de botones en los cuales solamente un botón puede ser seleccionado a la vez.

2.4.6 Look and Feel (Skin para aplicaciones JAVA). Normalmente las ventanas JAVA tienen su propio aspecto, su propio estilo de botones y demás. Con Java es muy fácil cambiar el aspecto (Look and Feel o skin) de nuestras ventanas para que tengan aspecto Java, aspecto Linux, Windows, Mac etc. Basta con tener la librería adecuada y una sola línea de código [35][36].

Para obtener el aspecto de ventanas propio del sistema operativo en el que estemos (Linux, Windows Xp, Solaris, etc.), basta con estas líneas de código antes de crear ninguna ventana [48]:

```
import Javax.swing.UIManager;
...
try
{
UIManager.setLookAndFeel(UIManager.getSystemLookAndFeelClassName());
}
catch (Exception e)
{
 e.printStackTrace();
}
```

Con UIManager.getSystemLookAndFeelClassName() obtenemos el nombre del Look and Feel por defecto del sistema operativo en el que estemos. Con UIManager.setLookAndFeel decimos qué Look and Feel queremos.

Hay muchos skins look and feel para las ventanas y solo es necesario descargar la librería y agregarla a la biblioteca en el proyecto de NetBeans, para Pg_KDD se utilizó NimROD muy útil para aplicaciones de múltiples ventanas [35][36].

También, se utilizó una librería denominada InfoNode que contiene al igual que NimROD, skins para visualización agradable de las aplicaciones JAVA, pero este también contiene manejo de ventaneo, distribución de paneles (Tabbed Panel) y acoplamiento de ventanas (Docking Windows) que hace fácil el manejo de las ventanas para el usuario final.

2.4.6.1 NimROD (Look & Feel). NimROD es un Look & Feel para mejorar el aspecto de las aplicaciones de Java, de fácil implementación dentro del código fuente, NimROD Look & Feel se libera bajo licencia LGPL, de este modo se puede usar el binario de la librería sin ningún problema, tanto desde aplicaciones que tengan su código liberado como para los que tengas código restringido por derechos de autor. También es posible consultar el código fuente y modificarlo para uso personal, pero si hace público ese código modificado de cualquier manera está obligado a hacer públicas también las fuentes. [35][36]

En la Figura 14, Figura 15 y Figura 16 se muestran algunos pantallazos de la última versión de NimROD Look & Feel:

Figura 14: Representación NimROD Tipical

Fuente. Internet - Look & Feel - Nilo J. González, Madrid, http://personales.ya.com/nimrod/index.html

Figura 15: Representación NimROD Blue

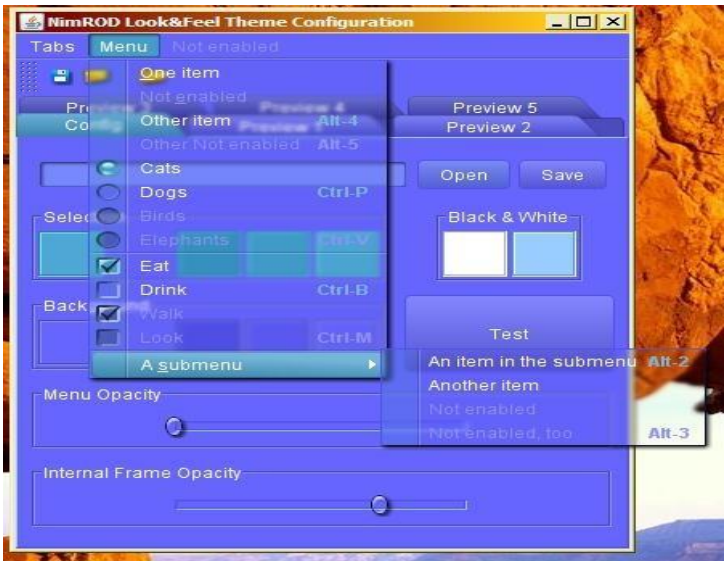

Fuente. Internet - Look & Feel - Nilo J. González, Madrid, http://personales.ya.com/nimrod/index.html

Figura 16: Representación NimROD Red

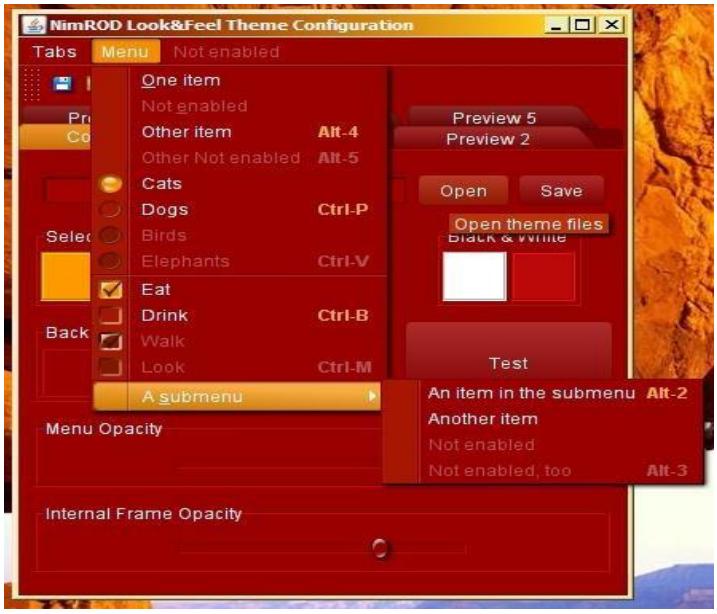

Fuente. Internet - Look & Feel - Nilo J. González, Madrid, http://personales.ya.com/nimrod/index.html

2.4.6.2 InfoNode (Doking Windows – Tabbed Panel). InfoNode es una gama de productos de software de NNL Technology AB. Ofrece soluciones

basadas en Java Swing GUI. Sus productos permiten construir modernas y avanzadas interfaces gráficas de usuario para las aplicaciones Java y así reducir sus costos de desarrollo y acortar el tiempo de comercialización [36].

Los productos ofrecidos por NNL Technology AB con InfoNode son [36]:

- ✓ InfoNode Docking Windows: Un componente Java basada en Swing que permite el acoplamiento de ventanas.

  El Doking Windows InfoNode permite crear una GUI Swing de gran eficacia para su aplicación y con muy poco código. La aplicación sólo contendrá los componentes Swing normal con contenido de aplicación y los colocará dentro de las ventanas del marco. Las ventanas pueden estar dispersas u ordenadas en diseños avanzados utilizando Split, ventanas en pestañas y ventanas flotantes.

  Una ventaja importante de InfoNode Docking Windows es que a través de un GUI Swing normal el usuario puede personalizar el diseño de la aplicación a su preferencia o gusto. El usuario puede minimizar, maximizar, cerrar, desacoplar, acoplar y moverse por las ventanas para crear un diseño de ventana personalizada. Usted puede incluso tomar ventaja de las pantallas múltiples desacoplando ventanas y pasar a otras pantallas. Cuando el usuario está satisfecho con el diseño puede ser fácilmente guardado y restaurado cada vez que se inicie la aplicación. Por supuesto no hay ninguna limitación en el número de diseños de ventana que se pueden guardar [36].

  También puede utilizar InfoNode Docking Windows (Figura 17) para experimentar con prototipos y diseños de interfaz de usuario diferente para su aplicación. Se mueven alrededor de las ventanas hasta que esté satisfecho con su diseño, guardar el diseño y el uso está a disposición permanentemente como el diseño predeterminado que el usuario mismo diseño y así todo el diseño quede congelado según la preferencia del mismo.

Figura 17: Representación InfoNode Doking Windows

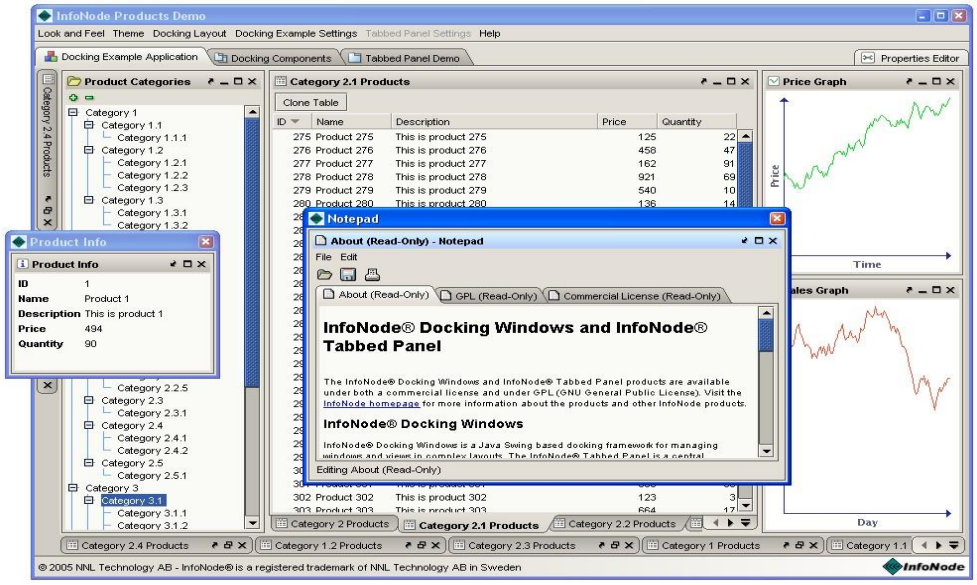

Fuente. InfoNode – Doking Windows – Tabbed Panel, NNL Technology AB. 2009, http://www.infonode.net/index.html?idw

- ✓ InfoNode Tabbed Panel: Un componente basado en Java Swing que permite crear un panel de pestañas.

  El Doking Windows utiliza el potente Tabbed Panel de InfoNode el cual se incluye en la distribución de las ventanas de la aplicación y se puede utilizar como un componente independiente para el manejo de pestañas que incluyen ventanas dentro de un panel. De acuerdo a ello InfoNode también incluye un estilo ordenado en la distribución de las aplicaciones JAVA que requieran del manejo de varias ventanas a la vez [36].

- ✓ InfoNode Look and Feel: Una variante de Java look and feel con un aspecto metálico.

  Casi todos los aspectos de la apariencia del marco InfoNode Docking Windows son personalizables a través de un sistema de propiedades avanzadas. Hay más de 2.500 propiedades que se pueden cambiar.
  Se tiene la posibilidad de crear una apariencia única para su aplicación o elegir uno de los temas incluidos en la distribución. InfoNode Docking Windows le permite crear fichas de cualquier forma, crear fondos

degradados, crear interesantes efectos de la liberación del ratón y añadir sombras a las ventanas de la ficha (Figura 18).

Figura 18: Representación Look and Feel InfoNode Windows XP

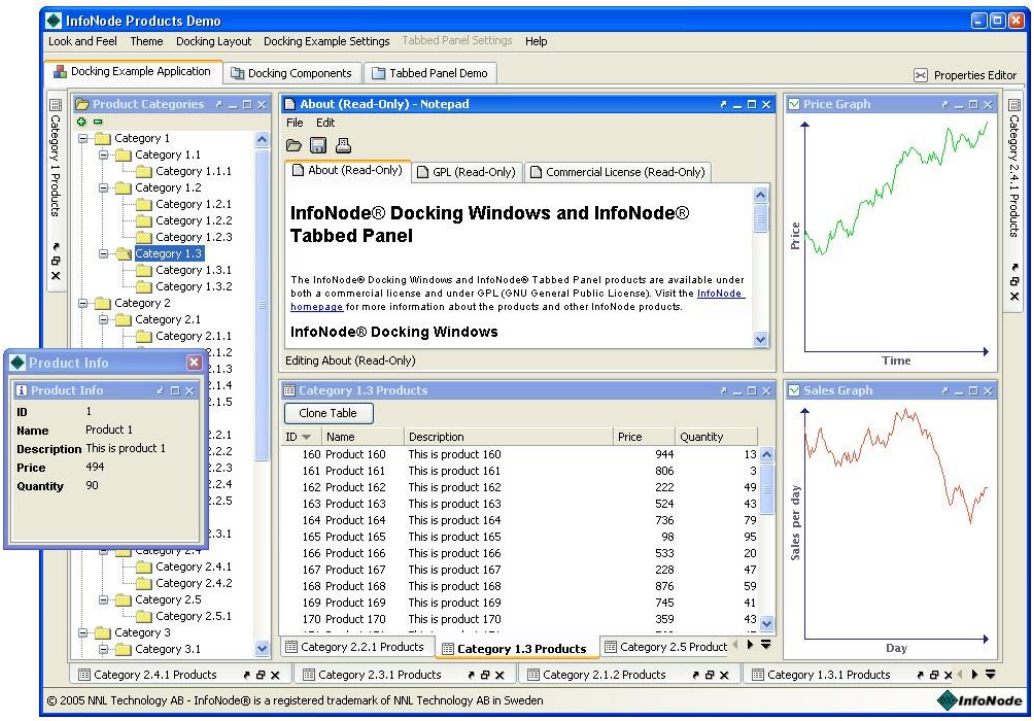

Fuente. InfoNode – Doking Windows – Tabbed Panel, NNL Technology AB. 2009, http://www.infonode.net/index.html?idw

3. OPERADORES ALGEBRAICOS, PRIMITIVAS SQL Y ALGORITMOS PARA LAS TAREAS DE ASOCIACIÓN Y CLASIFICACIÓN

PostgresKDD es una herramienta computacional para el descubrimiento de conocimiento fuertemente acoplado con el SGBD PostgreSQL, al cual se la han implementado operadores y primitivas SQL propuestas por Timaran [31] para dotarlo de las capacidades de realizar minería de datos en las tareas de Asociación y Clasificación. Los operadores y primitivas SQL propuestos e implementados en PostgresKDD son:

3.1 OPERADORES DEL ÁLGEBRA RELACIONAL Y NUEVAS PRIMITIVAS SQL PARA ASOCIACIÓN

Los siguientes son los nuevos operadores con los cuales se extiende el álgebra relacional para soportar eficientemente la tarea de Asociación propuestos por Timaran [31].

3.1.1 Operador Associator y la primitiva Associator Range. A continuación se describe el operador Associator y la primitiva Associator Range.

Operador Associator (α) [31]

Associator (α) es un operador algebraico unario que a diferencia del operador Selección o Restricción (σ), aumenta la cardinalidad de una relación. *Associator* genera, a partir de cada tupla de una relación, todas las posibles combinaciones (de diferente tamaño) de los valores de sus atributos, como tuplas de una nueva relación, conservando el esquema de la relación inicial. Los atributos de la relación inicial pueden pertenecer a diferentes dominios [31].

Su sintaxis es la siguiente:

$\alpha_{tamaño\_inicial,\ tamaño\_final}(R)$

Donde <*tamaño_inicial*> y <*tamaño-final*> son dos parámetros de entrada que determinan el tamaño inicial y tamaño final de las combinaciones.
El operador *Associator* genera, por cada tupla de la relación *R*, todos sus posibles subconjuntos (conjuntos de ítems) de diferente tamaño. *Associator* toma cada tupla *t* de *R* y dos parámetros :<*tamaño_inicial*> y <*tamaño_final*> como entrada, y retorna, por cada tupla *t*, las diferentes combinaciones de atributos X_i, de tamaño <*tamaño_inicial*> hasta tamaño <*tamaño_final*>, como tuplas en una nueva relación. El orden de los atributos en el esquema de *R* determina los atributos en los subconjuntos con valores, el resto se hacen nulos. El tamaño máximo de un ítemset y por consiguiente el tamaño final máximo (<*tamaño_final*>) que se puede tomar como entrada es el correspondiente al valor del grado de la relación [31].

A pesar de que generar todas las posibles combinaciones de los valores, para cada tupla de una relación, es un proceso computacionalmente costoso, *Associator* lo hace en una sola pasada sobre la base de datos.

Associator facilita el cálculo de ítemsets frecuentes para el descubrimiento de reglas de asociación multidimensionales.

Ejemplo. Timarán [31]. Sea la relación *R*(*A, B, C, D*) de la Tabla 1, Encontrar las diferentes combinaciones de tamaño 2 hasta tamaño 4, es decir *R1*= $\boldsymbol{\alpha}_{2,4}(R)$.

Tabla 1: Relación R

A	B	C	D
a1	b1	c1	d1
a1	b2	c1	d2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 5 [31]

El resultado del operador *Associator* se muestra en la Tabla 2.

Tabla 2: Resultado Associator

A	B	C	D
a1	b1	null	null
a1	null	c1	null
a1	null	null	d1
null	b1	c1	null
null	b1	null	d1
null	null	c1	d1
a1	b1	c1	null
a1	b1	null	d1
a1	null	c1	d1
null	b1	c1	d1
a1	b1	c1	d1
a1	b2	null	null
a1	null	c1	null
a1	null	null	d2
null	b2	c1	null
null	b2	null	d2
null	null	c1	d2
a1	b2	c1	null
a1	b2	null	d2
a1	null	c1	d2
null	b2	c1	d2
a1	b2	c1	d2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 5 [31]

Primitiva Associator Range [31].

Esta primitiva implementa el operador algebraico *Associator* en la cláusula SQL SELECT. Associator permite obtener por cada tupla de una tabla, todos los posibles subconjuntos desde un tamaño inicial hasta un tamaño final determinado por la cláusula RANGE [31].

Dentro de la cláusula SELECT, la primitiva *Associator Range* tiene la siguiente sintaxis [31]:

SELECT <*ListaAtributosTablaDatos*> [INTO <*NombreTablaAssociator*>]
FROM <*NombreTablaDatos*>
WHERE <*CláusulaWhere*>
ASSOCIATOR RANGE <*valor1*> UNTIL <*valor2*>
GROUP BY <*ListaAtributosTablaDatos*>

<*ListaAtributosTablaDatos*>::=<*Atributo*>,
<*ListaAtributos*><*ListaAtributos*>::=<*Atributo*>,
<*ListaAtributos*><*ListaAtributos*>::=<*Atributo*>

<*valor1*>::= *1,2,3, 4 ...*
<*valor2*>::= *1,2,3,4 ...*

Donde:

La cláusula SELECT <*ListaAtributosTablaDatos*> permite seleccionar los atributos de la tabla de datos <*NombreTablaDatos*> cuyos valores formarán los diferentes subconjunto o ítemsets como tuplas de la nueva tabla <*NombreTablaAssociator*> [31].

La cláusula INTO <*NombreTablaAssociator*> define el nombre de la tabla <*NombreTablaAssociator*> donde se almacenarán los resultados de ASSOCIATOR RANGE con los atributos especificados en la cláusula SELECT <*ListaAtributosTablaDatos*> como esquema. Si no se especifica la cláusula INTO, el resultado se almacenará en una tabla temporal como sucede normalmente en el lenguaje SQL [31].

La cláusula FROM <*NombreTablaDatos*> WHERE <*CláusulaWhere*> determina el nombre de la tabla <*NombreTablaDatos*> de donde se extraerá el conjunto de tuplas que cumplan las restricciones de la <*CláusulaWhere*> para formar las diferentes combinaciones o ítemsets [31].

La cláusula ASSOCIATOR RANGE <*número1*> UNTIL <*número2*> determina el tamaño inicial hasta el final de los diferentes subconjuntos o ítemsets que formará el operador *Associator* [31].

La cláusula GROUP BY *<ListaAtributosTablaDatos>* agrupa la tabla *<NombreTablaDatos>* por los atributos especificados en *<ListaAtributosTablaDatos>*

La primitiva ASSOCIATOR RANGE facilita el cálculo de los ítemsets frecuentes para el descubrimiento de Reglas de Asociación en tablas multicolumna [31].

Ejemplo. Timarán [31]. Sea la siguiente tabla, Estudiantes(PROGRAMA, EDAD, SEXO, ESTRATO, PROMEDIO), cuya descripción se observa en la Tabla 3. Para la tabla Estudiantes, calcular el soporte para las ítemsets de tamaño 2 y 3 formados por lo atributos PROGRAMA, SEXO, ESTRATO y almacenar los resultados en la tabla Assostudent.

Tabla 3: Tabla Estudiantes

PROGRAMA	EDAD	SEXO	ESTRATO	PROMEDIO
Sistemas	16..20	M	2	Medio alto
Idiomas	21..25	F	3	Regular
Sistemas	16..20	F	3	Regular
Física	21..25	M	2	Bajo
Psicología	21..25	F	4	Alto

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 20 [31]

Utilizando la nueva primitiva *Associator Range*, esta consulta se realiza con la siguiente sentencia SQL [31]:

```
SELECT programa, sexo, estrato, count(*) AS soporte INTO assostudent
FROM estudiantes
ASSOCIATOR RANGE 2 UNTIL 3
GROUP BY programa,sexo,estrato
```

La anterior sentencia SQL se ejecuta de la siguiente manera [31]:

Inicialmente se seleccionan de la tabla *Estudiantes*, los atributos *programa, sexo y estrato*. Luego se ejecuta la cláusula ASSOCIATOR RANGE, es decir, se procede a generar los ítemsets de tamaño 2 y 3 como se muestra en la Tabla 4.

Tabla 4: Resultado Associator Range.

PROGRAMA	SEXO	ESTRATO
Sistemas	M	Null
Sistemas	Null	2
Null	M	2
Sistemas	M	2
Idiomas	F	Null
Idiomas	Null	3
Null	F	3
Idiomas	F	3
Sistemas	F	Null
Sistemas	Null	3
Null	F	3
Sistemas	F	3
Idiomas	M	Null
Idiomas	Null	3
Null	M	3
Idiomas	M	3
Sistemas	F	Null
Sistemas	Null	2
Null	F	2
Sistemas	F	2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 21 [31]

Finalmente se agrupa por *programa, sexo y estrato* de acuerdo a la cláusula GROUP BY, se calcula la función agregada *count()* y el resultado se almacena en la tabla *Assostudent* como lo muestra en la Tabla 5 [31].

Tabla 5: Assostudent

PROGRAMA	SEXO	ESTRATO	SOPORTE
Sistemas	F		2
Sistemas	M		1
Sistemas	F	2	1
Sistemas	M	2	1
Sistemas		2	2
Sistemas	F	3	1
Sistemas		3	1
Idiomas	F		1
Idiomas	M		1

PROGRAMA	SEXO	ESTRATO	SOPORTE
Idiomas	F	3	1
Idiomas	M	3	1
Idiomas		3	2
	F	2	1
	M	2	1
	F	3	2
	M	3	1

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 21 [31]

Ejemplo. Timarán [31]. Obtener de la tabla *Estudiantes* del ejemplo anterior, los ítemsets frecuentes de tamaño 2 y 3 que cumplan con un soporte mínimo mayor o igual a 2.

Los ítemsets frecuentes se obtienen con la siguiente sentencia SQL [31]:

SELECT *programa, sexo, estrato, count(*)* AS soporte INTO assostudent
FROM *estudiantes*
ASSOCIATOR RANGE 2 UNTIL 3
GROUP BY *programa,sexo,estrato* HAVING *count(*)>=2*

El resultado final se muestra en la Tabla 6.

Tabla 6: temsets frecuentes tamaño 2 y 3 con soporte >= 2

PROGRAMA	SEXO	ESTRATO	SOPORTE
Sistemas	F		2
Sistemas		2	2
Idiomas		3	2
	F	3	2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 21 [31]

3.1.2 Operador Assorow y la primitiva Assorow Range. A continuación se describe el operador Assorow y la primitiva Assorow Range.

Operador Assorow (ρ) [31].

Assorow, al igual que *Associator*, es un operador unario que genera, por cada tupla de la relación *R*, todos sus posibles subconjuntos (ítemsets) de diferente tamaño, pero sin hacer nulos los atributos que no forman el ítemset. Los valores de los atributos que se hacen nulos siempre serán los atributos de la parte derecha de cada tupla, que por el tamaño del ítemset, no se combinan. *Assorow* es un operador que requiere que todos los atributos de la relación *R* a la cual se aplica, sean del mismo dominio (i.e. del mismo tipo) [31].

La sintaxis de Assorow es la siguiente [31]:

$\alpha\rho_{tamaño\_inicial,tamaño\_final}(R)$

Donde <*tamano_inicial*> y <*tamaño-final*> son dos parámetros de entrada que determinan el tamaño inicial y tamaño final de las combinaciones.

Assorow toma cada tupla *t* de *R* y los tamaños inicial y final (<*tamaño_inicial*>, <*tamaño_final*>) de los ítemsets como entrada, y retorna, una nueva relación con el mismo esquema de *R*, y con las diferentes combinaciones de atributos *Xi* de tamaño <*tamaño_inicial*> hasta tamaño <*tamaño_final*>, como tuplas. En cada combinación *Xi*, los atributos con valores serán los del tamaño generado, iniciando siempre del primer atributo del esquema de *R* (por tener *R* atributos de un mismo dominio), el resto de atributos se hacen nulos [31].

El tamaño máximo de un ítemset y por consiguiente el tamaño final máximo (<*tamaño_final*>) que se puede tomar como entrada es el correspondiente al valor del grado de la relación [31].

Assorow facilita el cálculo de ítemsets frecuentes para el descubrimiento de reglas de asociación unidimensionales [31].

Ejemplo. Timarán [31]. Sea la relación *R*(*A,B,C,D*) de la Tabla 1, en la cual *dom*(A)=*dom*(B)=*dom*(C)=*dom*(D), obtener el resultado de aplicar *Assorow* a la relacion R: *R1*= $\alpha\rho_{2,4}(R)$.

El resultado de *Assorow* se muestra en la Tabla 7.

Tabla 7: Resultado operación R1=αp$_{2,4}$(R)

A	B	C	D
a1	b1	null	null
a1	c1	null	null
a1	d1	null	null
b1	c1	null	null
b1	d1	null	null
c1	d1	null	null
a1	b1	c1	null
a1	b1	d1	null
a1	c1	d1	null
b1	c1	d1	null
a1	b1	c1	d1
a1	b2	null	null
a1	c1	null	null
a1	d2	null	null
b2	c1	null	null
b2	d2	null	null
c1	d2	null	null
a1	b2	c1	null
a1	b2	d2	null
a1	c1	d2	null
b2	c1	d2	null
a1	b2	c1	d2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 5 [31]

Primitiva Assorow Range [31]

Esta primitiva implementa el operador algebraico Assorow en la cláusula SQL SELECT. Assorow permite obtener por cada tupla de una tabla, todos los posibles subconjuntos desde un tamaño inicial hasta un tamaño final determinado por la cláusula RANGE siempre y cuando todos los atributos de la tabla de datos sean del mismo tipo [31].

Dentro de la cláusula SELECT, *Assorow* tiene una sintaxis equivalente a Associator [31]:

SELECT <*ListaAtributosTablaDatos*> [INTO <*NombreTablaAssorow*>]
FROM <*NombreTablaDatos*> WHERE <*CláusulaWhere*>
ASSOROW RANGE <*valor1*> UNTIL <*valor2*>
GROUP BY <*ListaAtributosTablaDatos*>

<*ListaAtributosTablaDatos*>::=<*Atributo*>,<*ListaAtributos*>
<*ListaAtributos*> : := <*Atributo*>, <*ListaAtributos*>
<*ListaAtributos*> : := <*Atributo*>
<*valor1*> : := *1,2,3, 4 ...*
<*valor2*> : := *1,2,3,4 ...*

La primitiva ASSOROW facilita el cálculo de los ítemsets frecuentes para el descubrimiento de Reglas de Asociación en tablas multicolumna especíalmente en análisis de canasta de mercado [31].

Ejemplo. Timarán [31]. Sea la tabla Transaccion (TID, ID_ITEM1, ID_ITEM2, ID_ITEM3) de la Tabla 8. Calcular el soporte para las ítemsets de tamaño 2 y 3 formados por lo atributos ID_ITEM1, ID_ITEM2, ID_ITEM3 y almacenar los resultados en la tabla Assotran.

Tabla 8: Tabla Transacciones

TID	ID_ITEM1	ID_ITEM2	ID_ITEM3
100	i1	i2	
200	i2	i3	i4
300	i1	i2	i3
400	i2	i3	i4
500	i3	i4	

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 22 [31]

La sentencia SQL que resuelve esta consulta es la siguiente [31]:

SELECT *id_item1, id_item2, id_item3, count(*)* AS *soporte* INTO *assotran*
FROM *transaccion*
ASSOROW RANGE *2* UNTIL *3*
GROUP BY *id_item1, id_item2, id_item3*

Inicialmente se selecciona los atributos id_item1, id_item2, id_item3 de la tabla transacción. Luego *ASSOROW* genera todos los ítemsets de tamaño 2 y 3 (ver Tabla 9) y finalmente se agrupa por los atributos especificados en la cláusula GROUP BY, se cuenta la frecuencia de los ítemsets y se genera la tabla assotran (ver Tabla 10) [31].

Tabla 9: Assorow

ID_ITEM1	ID_ITEM2	ID_ITEM3
i1	i2	null
i2	i3	null
i2	i4	null
i3	i4	null
i2	i3	i4
i1	i2	null
i1	i3	null
i2	i3	null
i1	i2	i3
i2	i3	null
i2	i4	null
i3	i4	null
i2	i3	i4

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 23 [31]

Tabla 10: Assotran

ID_ITEM1	ID_ITEM2	ID_ITEM3	SOPORTE
i1	I2		2
i1	I2	I3	1
i1	I3		1
i2	I3		4
i2	I3	I4	2
i2	I4		2
i3	I4		3

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 23 [31]

Ejemplo. Timarán [31]. Obtener de la tabla Transacciones del ejemplo anterior, los ítemsets frecuentes de tamaño 2 y 3 que cumplan con un soporte mínimo mayor o igual a 2.

Los ítemsets frecuentes se obtienen con la siguiente sentencia SQL [31]:

SELECT *id_item1, id_item2, id_item3, count(*)* AS *soporte* INTO *assotran*
FROM *transaccion*
ASSOROW RANGE *2* UNTIL *3*
GROUP BY *id_item1, id_item2, id_item3* HAVING *count(*)*>=2

El resultado final se muestra en la Tabla 11.

Tabla 11: Ítemsets frecuentes tamaño 2 y 3 con soporte >= 2.

ID_ITEM1	ID_ITEM2	ID_ITEM3	SOPORTE
i1	i2		2
i2	i3		4
i2	i3	i4	2
i2	i4		2
i3	i4		3

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 23 [31]

3.1.3 Operador EquiKeep y la primitiva EquiKeep On. A continuación se describe el operador EquiKeep y la primitiva EquiKeep On.

Operador EquiKeep ( ) [31]

EquiKeep ( ) es un operador unario, que se asemeja a la Selección o Restricción por tener una expresión lógica que evaluar sobre una relación R, y conserva su esquema. Se diferencia de la Restricción (σ) en que en lugar de aplicar la condición a las filas (tuplas) de la relación, *EquiKeep* aplica la expresión lógica a las columnas (atributos) de *R*, es decir restringe los valores de los atributos de cada una de las tuplas de la relación *R,* a únicamente aquellos que satisfacen

una condición determinada, haciendo nulos al resto de valores y conserva el esquema de la relación [31].

Su sintaxis es la siguiente [31]:

$$_{\text{expresión\_lógica}}(R)$$

donde <*expresión lógica*> es la condición que deben cumplir los valores de los atributos de la relación R para no hacerse nulos.

El operador *EquiKeep*, restringe los valores de los atributos de cada una de las tuplas de la relación *R* a únicamente los valores de los atributos que satisfacen una expresión lógica <*expresión_lógica*>, la cual esta formada por un conjunto de cláusulas de la forma *Atributo=Valor*, conectivos lógicos AND, OR y NOT. En cada tupla, los valores de los atributos que no cumplen la condición <*expresión_lógica*> se hacen nulos. *EquiKeep* elimina las tuplas vacías, es decir, aquellas tuplas en las cuales los valores de todos sus atributos son nulos [31].

EquiKeep optimiza el trabajo de los operadores *Associator* o *Assorow* en el cálculo de ítemsets frecuentes en la tarea de Asociación, al disminuir el número de combinaciones [31].

Ejemplo. Timarán [31]. Sea la relación R(A,B,C,D) de la Tabla 12. Restringir los valores de los atributos A=a1, B=b1, C=c2 y D=d1, es decir, R1= $_{A=a1 \vee B=b1 \vee C=c2 \vee D=d1}(R)$. El resultado del operador *EquiKeep* se muestra en la Tabla 13.

Tabla 12: Relación R

A	B	C	D
a1	b2	c1	d2
a2	b2	c2	d2
a2	b1	c1	d1
a2	b2	c1	d2
a1	b2	c2	d1

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 10 [31]

Tabla 13: Resultado de la operación R1=χ A=a1 v B=b1 v C=c2 v D=d1 (R)

A	B	C	D
a1	b1	null	d1
a1	null	null	Null
Null	null	c2	Null
Null	b1	null	d1
Null	null	null	Null
a1	null	c2	d1

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 10 [31]

En este ejemplo, la tupla {*a2,b2,c1,d2*} es eliminada por resultar todos sus valores nulos.

Primitiva EquiKeep On [31]

Esta primitiva implementa el operador algebraico *EquiKeep* en la cláusula SQL SELECT. *EquiKeep On* conserva en cada registro de una tabla los valores de los atributos que cumplen una condición determinada. El resto de valores de los atributos se hacen nulos [31].

Dentro de la cláusula SELECT, *EquiKeep On* tiene la siguiente sintaxis [31]:

SELECT <*ListaAtributosTablaDatos*> [INTO]
<*NombreTablaEquiKeep*>] FROM <*NombreTablaDatos*>
WHERE <*CláusulaWhere*>
EQUIKEEP ON <*CondiciónValoresAtributos* >

<*ListaAtributosTablaDatos*>::=<*Atributo*>,<*ListaAtributos*>
<*ListaAtributos*>::=<*Atributo*>,<*ListaAtributos*>
<*ListaAtributos*>::=<*Atributo*>
<*CondiciónValoresAtributos*>::=<*Atributo=Valor*><*operador*><*ListaCondición*>
|<*Atributo*><*operador*><*(Listavalores)*>,
<*ListaCondición*>
<*ListaCondición*>::=<*Atributo=Valor*>|<*Atributo*><*operador*><(*Listavalores*)>
<*operador*>::= *AND,OR,NOT,IN*

<Listavalores>::*=1,2,3, 4...*
<Valor>::*=1,2,3, 4...*

donde:

La cláusula SELECT *<ListaAtributosTablaDatos>* permite seleccionar los atributos de la tabla de datos *<NombreTablaDatos>* cuyos valores se conservarán si cumplen la condición *<CondiciónValoresAtributos>*, especificada en la primitiva *EquiKeep On* [31].

La cláusula INTO *<NombreTablaEquiKeep>* define el nombre de la tabla *<NombreTablaEquiKeep>* donde se almacenarán los resultados de EQUIKEEP ON con los atributos *<ListaAtributosTablaDatos>* como esquema. Si no se especificala cláusula INTO, el resultado se almacenará en una tabla temporal [31].

La cláusula FROM *<NombreTablaDatos>* WHERE *<CláusulaWhere>* determina el nombre de la tabla de datos <NombreTablaDatos> con el conjunto de registros que cumplan las restricciones de la *<CláusulaWhere>* [31].

La primitiva EQUIKEEP ON *<CondiciónValoresAtributos>* conserva los valores de los atributos de *<ListaAtributosTablaDatos>* que cumplan la condición especificada en *<CondiciónValoresAtributos>*. El resto de valores de los atributos se hacen nulos [31].

La primitiva EQUIKEEP ON facilita la generación de los ítemsets frecuentes en el descubrimiento de Reglas de Asociación, al permitir conservar en cada registro de una tabla únicamente los valores de los atributos frecuentes o ítemsets frecuentes [31].

Ejemplo Timarán [31]. Sea la tabla Transaccion (TID, ID_ITEM1, ID_ITEM2, ID_ITEM3) de la Tabla 8. Encontrar los ítemsets frecuentes de tamaño 2 y 3 formados por los atributos ID_ITEM1, ID_ITEM2, ID_ITEM3 que cumplan un soporte mínimo mayor o igual a 3. Almacenar los resultados en la tabla Equitran.

Suponiendo que ya se conocen los ítemsets frecuentes de tamaño 1: {i2:4}, {i3:4}, {i4:3}, la sentencia SQL que permite obtener esta consulta utilizando las primitivas *EquiKeep On* y *Assorow Range* es la siguiente [31]:

SELECT *id_item1, id_item2, id_item3, count(*)* AS *soporte* INTO *equitran*
FROM *transaccion*
EQUIKEEP ON *id_item1* IN (*i2,i3,i4*) , *id_item2* IN (*i2,i3,i4*), *id_item3*
IN(*i2,i3,i4*) ASSOROW RANGE *2* UNTIL *3*
GROUP BY *id_item1, id_item2, id_item3* HAVING *count(*)>=3*

En esta sentencia SQL, inicialmente se ejecuta la cláusula SELECT, en este caso se seleccionan los atributos *id_item1, id_item2, id_item3* de la tabla *transacción*. Luego sobre la tabla resultante, se ejecuta la primitiva EQUIKEEP ON que conserva los valores de los atributos que cumplan la condición *id _item1 IN(i2,i3,i4), id_item2 IN(i2,i3,i4), id_item3 IN(i2,i3,i4)* (Tabla 14) [31].

Tabla 14: Resultado primitiva EquiKeep On

ID_ITEM1	ID_ITEM2	ID_ITEM3
Null	i2	
i2	i3	i4
Null	i2	i3
i2	i3	i4
i3	i4	

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 28 [31]

Posteriormente se generan los ítemsets de tamaño 2 y 3 con la primitiva ASSOROW RANGE 2 UNTIL 3 (Tabla 15), se agrupa, se cuenta la frecuencia de los ítemsets (Tabla 16) y finalmente se hallan los ítemsets frecuentes cuyo soporte mínimo es mayor o igual a tres y se almacenan en la tabla *Equitran* (Tabla 17) [31].

Tabla 15: Resultado primitiva Assorow Range.

ID_ITEM1	ID_ITEM2	ID_ITEM3
i2	i3	Null
i2	i4	Null
i3	i4	Null
i2	i3	i4
i2	i3	Null

ID_ITEM1	ID_ITEM2	ID_ITEM3
i2	i3	Null
i2	i4	Null
i3	i4	Null
i2	i3	i4
i3	i4	Null

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 28 [31]

Tabla 16: Soporte Ítemsets tamaño 2 y 3.

ID_ITEM1	ID_ITEM2	ID_ITEM3	SOPORTE
i2	i3		4
i2	i3	i4	2
i2	i4		2
i3	i4		3

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 28 [31]

Tabla 17: Tabla Equitran.

ID_ITEM1	ID_TEM2	ID_ITEM3	SOPORTE
i2	i3		4
i3	i4		3

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 28 [31]

3.1.4 Operador Describe Associator y la primitiva Describe Association Rules.

A continuación se describe el Describe Associator y la primitiva Describe Association Rules.

Operador Describe Associator (βα) [31]

Describe Associator es un operador unario que toma como entrada la relación

resultante de los operadores A*ssociator*, A*ssorow* o *Assocol* y por cada tupla de esta relación, genera, a partir de los atributos *l* no nulos de la tupla, todos los diferentes subconjuntos de un tamaño específico de la forma *{{a}, {l-a},s}*, donde *{a}* se denomina subconjunto antecedente y *{l-a}* subconjunto consecuente.
{a} y {l-a}, son subconjuntos de atributos de *l* y *s* es el tamaño del subconjunto antecedente *{a}* [31].

La sintaxis del operador *Describe Associator* es la siguiente [31]:

$$\beta\alpha_{longitud\_regla}(R)$$

donde <*longitud_regla*> es la longitud máxima de atributos no nulos por tupla.

El operador *Describe Associator* toma cada tupla *t* de *R* y el parámetro <*longitud_regla*> como entrada, y retorna, por cada tupla *t*, los diferentes subconjuntos de atributos *Xi*, de tamaño <*longitud_regla*>, como tuplas en una nueva relación [31].

Cada tupla *Xi* se forma siguiendo la regla *({a}=> {l-a},s*), donde *l* es el conjunto de atributos no nulos de la tupla *t*, *{a}* es un subconjunto de *l* denominado antecedente, *{l-a}* se denomina subconjunto consecuente y *s* es el tamaño del subconjunto *{a}* [31].

Ejemplo. Timarán [31]. Sea la relacion R(A,B,C) de la Tabla 18. Obtener los diferentes subconjuntos de tamaño 3 con el operador *Describe Associator*, es decir R1=βα3(R). El resultado se muestra en la Tabla 19.

Tabla 18: Relación R

A	B	C
a1	b1	c1
a2	b2	c2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 12 [31]

Tabla 19: Relación R1=βα3(R).

a1	b1	c1	1

A1	A2	A3	S
b1	a1	c1	1
c1	a1	b1	1
a1	b1	c1	2
a1	c1	b1	2
b1	c1	a1	2
a2	b2	c2	1
b2	a2	c2	1
c2	a2	b2	1
a2	b2	c2	2
a2	c2	b2	2
c2	b2	a2	2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 12 [31]

Operador SQL Describe Association Rules [31]

El operador SQL Describe Association Rules implementa el operador algebraico Describe Associator en una nueva cláusula SQL. Describe Association Rules permite generar, una vez calculados los ítemsets frecuentes, todas las reglas de asociación unidimensionales o multidimensionales de una longitud específica, que cumplen con un soporte y una confianza mayor o igual que unos determinados umbrales especificados por el usuario [31].

Describe Association Rules tiene la siguiente sintaxis [31]:

RULES
DESCRIBE ASSOCIATION
*[*INTO <*TablaReglasAsociación*>*]*
FROM <*NombreTablaÍtemsetsFrecuentes*> WITH CONFIDENCE <*valor1*>
LENGTH <*valor2* >
*[*DO <*SubconsultaÍtemsetsFrecuentes*>*]*
<*valor 1*> ::=1,2,3,4,….
<*valor 2*> ::=1,2,3,4,….

donde:

< SubconsultaÍtemsetsFrecuentes >::=<SFWEAG>|<SFWEARG>|<SFWEACG>
<SFWEAG>::= <SELECT FROM WHERE EQUIKEEP ASSOCIATOR GROUP BY>
<SFWEARG>::= <SELECT FROM WHERE EQUIKEEP ASSOROW GROUP BY>
<SFWEACG>::= <SELECT FROM WHERE EQUIKEEP ASSOCOL GROUP BY>

La cláusula *DESCRIBE ASSOCIATION RULES* especifica el tipo de reglas de asociación a extraer.

La cláusula [INTO <*TablaReglasAsociación*>] permite almacenar en una tabla <*TablaReglasAsociación*> las reglas de asociación que se generen, para posteriores consultas.

La cláusula FROM <*NombreTablaÍtemsetsFrecuentes*> especifica el nombre de la tabla de datos <*NombreTablaÍtemsetsFrecuentes*> donde se encuentranlos ítemsets frecuentes para la extracción de reglas.

La cláusula WITH CONFIDENCE <*valor 1*> especifica el valor de la confianza mínima <*valor 1*> que permite la generación de reglas de asociación fuertes.

La cláusula LENGTH <*valor 2*> determina la longitud de las reglas de asociación a generar.

La cláusula opcional [DO <*SubconsultaCalculoÍtemsetsFrecuentes*>] permite especificar conjuntamente con la cláusula DESCRIBE, la subconsulta <*SubconsultaCalculoÍtemsetsFrecuentes*> que halla los ítemsets frecuentes utilizando cualesquiera de las nuevas primitivas SQL para asociación. En el caso de que esta cláusula no se especifique, los procesos de cálculo de los ítemsets frecuentes y el de generación de reglas se realizarían en órdenes SQL independientes [31].

3.1.5 EquipAsso: un Algoritmo para el Descubrimiento de Reglas de Asociación. EquipAsso es un algoritmo que se basa en los nuevos operadores del álgebra relacional *Associator*, *Assorow* y *EquiKeep* para el cálculo de conjuntos de ítems frecuentes [31]. Este hecho facilita su integración al interior de cualquier SGBD, acoplando la tarea de Asociación de una manera fuerte y favorece la aplicación de técnicas de optimización de consultas para

mejorar su rendimiento. [31],

El algoritmo es el siguiente [31]:

El primer paso del algoritmo cuenta el número de ocurrencias de cada item para determinar los 1-conjuntos de ítems frecuentes L1. En el subsiguiente paso, se aplica el operador EquiKeep para extraer de todas las transacciones en D, los conjuntos de ítems frecuentes tamaño 1, haciendo nulos el resto de valores. Luego, a la relación resultante R, se aplica el operador Associator (para reglas de asociación multidimensionales) o el operador Assorow (para reglas de asociación unidimensionales) para generar todos los conjuntos de ítems tamaño 2 (Is=2) hasta máximo tamaño n, donde n es el grado de R. Finalmente, se calculan todos los conjuntos de ítems frecuentes L, contando el soporte de las diferentes combinaciones generadas por Associator (o Assorow) en la relación R1. En la Figura 19 se muestra el algoritmo EquipAsso [31].

Figura 19 Algoritmo EquipAsso

L1={1-conjuntos de items frecuentes};
Forall transacciones t $\in$ D *do begin*
// se aplica el operador EquiKeep
$R=\chi_{L1}(D)$
k=2
g=grado(R)
//genera todos los conjuntos de items posibles
$R1=\alpha_{k,g}(R) = \{\cup_{all} X_i \mid X_i \subseteq t_i\}$
End
// conjuntos de items frecuentes
L = {count (R1)| count $\geq$ minsup}

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 43 [31]

El algoritmo EquipAsso se implementa en el lenguaje SQL, utilizando la nuevas primitivas SQL *EquiKeep On* conjuntamente con *Associator Range*, para reglas de asociación multidimensionales y *EquiKeep On* con *Assorow Range* para reglas de asociación unidimenionales. El resultado se muestra en al siguiente

sentencia [31].

SELECT *<ListaAtributosTablaDatos> , count(*)* ***AS*** *soporte* ***INTO*** *R1*
FROM *D*
EQUIKEEP ON *L1*
ASSOCIATOR RANGE *k UNTIL g*
GROUP BY *<ListaAtributosTablaDatos>* ***HAVING*** *count(*)>=minsup*

EquipAsso mejorado [31]

Genera los ítemsets frecuentes tamaño 1 hasta el grado de la tabla si es posible sin el uso del operador *Equikeep.*

SELECT *<ListaAtributosTablaDatos> , count(*)* ***AS*** *soporte* ***INTO*** *R1*
FROM *D*
ASSOCIATOR RANGE *k UNTIL g*
GROUP BY *<ListaAtributosTablaDatos>* ***HAVING*** *count(*)>=minsup*

3.2 OPERADORES DEL ÁLGEBRA RELACIONAL Y PRIMITIVAS SQL PARA CLASIFICACIÓN

La clasificación por árboles de decisión es probablemente el modelo más utilizado y popular por su simplicidad y facilidad para su entendimiento.

Durante la etapa de construcción del árbol, en forma recursiva, cada conjunto de datos se particiona en subconjuntos de acuerdo a un criterio de particionamiento, con el fin de escoger el atributo que mejor separe los ejemplos restantes en clases individuales. Seleccionar el mejor punto de particionamiento es la parte de la construcción del árbol que mayor tiempo consume [31].

Se han propuesto varias métricas para este proceso. El cálculo del valor de la métrica que permite seleccionar, en cada nodo, el atributo que tenga una mayor potencia para clasificar sobre el conjunto de valores del atributo clase, es la

parte más costosa del algoritmo utilizado [WaIS98]. Los algoritmos ID3 [40] y C4.5 [41] utilizan como métrica, para seleccionar el atributo candidato en cada nodo del árbol, la reducción de la entropía denominada *Ganancia de Información*, mientras que SLIQ [42] y SPRINT [31], usan el indice *Gini*. Para el cálculo de estas métricas, no se necesitan los datos en si, sino las estadísticas acerca del número de registros en los cuales se combinan los atributos condición con el atributo clase.

Un nuevo operador algebraico para clasificación basado en árboles de decisión debe facilitar estas combinaciones, que conjuntamente con una función agregada, permita el cálculo de estas métricas[31].

El nuevo operador algebraico que realiza las diferentes combinaciones de los atributos condición con el atributo clase y las funciones agregadas específicas que facilitan el cálculo de la Entropía y Ganancia de Información (de igual manera se puede definir las funciones agregadas para la métrica *indice Gini*) son [31]:

3.2.1 Operador Mate y la primitiva Mate By. A continuación se describe el Operador Mate y la primitiva Mate By**.**

Operador Mate (μ) [31]

El operador *Mate* genera, por cada una de las tuplas de una relación, todas los posibles combinaciones formadas por los valores no nulos de los atributos pertenecientes a una lista de atributos denominados *Atributos Condición*, y el valor no nulo del atributo denominado *Atributo Clase* [31].

Tiene la siguiente sintaxis [31]:

$\mu_{\text{lista\_atributos\_condición; atributo\_clase}}(R)$

donde <*lista_atributos_condición*> es el conjunto de atributos de la relación *R* a combinar con el atributo clase y <*atributo_clase*> es el atributo de *R* definido como clase.

Mate toma como entrada cada tupla de *R* y produce una nueva relación cuyo esquema esta formado por los atributos condición, <*lista_atributos_condición*> y el atributo clase, <*atributo_clase*> con tuplas formadas por todas las posibles combinaciones de cada uno de los atributos condición con el atributo clase, los demás valores de los atributos se hacen nulos [31].

Mate empareja en cada partición todos los atributos condición con el atributo clase, lo que facilita el conteo y el posterior cálculo de las medidas de entropía y ganancia de información. El operador *Mate* genera estas combinaciones, en una sola pasada sobre la tabla de entrenamiento (lo que redunda en la eficiencia del proceso de construcción del árbol de decisión) [31].

Ejemplo. Timarán [31]. Sea la relación *R*(*A,B,C,D*) de la Tabla 20 obtener las diferentes combinaciones de los atributos *A,B* con el atributo *D*, es decir,
R1= $\mu_{A,B;D}(R)$.

El resultado de la operación R1= $\mu_{A,B;D}(R)$, se muestra en la Tabla 21.

Tabla 20: Relación R

A	B	C	D
a1	b1	c1	d1
a1	b2	c1	d2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 14 [31]

Tabla 21: Resultado operación R1= μA,B;D(R)

A	B	D
a1	null	d1
null	b1	d1
a1	b1	d1
a1	null	d2
null	b2	d2
a1	b2	d2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 15 [31]

Primitiva Mate By [31]

Esta primitiva implementa el operador algebraico *Mate* en la cláusula SQL SELECT. *Mate By* toma los valores de los atributos de una tabla denominados *atributos condición* y por cada registro forma todas las posibles combinaciones de estos atributos con otro atributo de la misma tabla denominado *atributo clase* [31].

Este proceso lo realiza en una sola pasada sobre la tabla [31].

Dentro de la cláusula SELECT, *Mate By* tiene la siguiente síntaxis [31]:

> SELECT <*ListaAtributosTablaDatos*> [INTO
> <*NombreTablaMate*>] FROM <*NombreTablaDatos*>
> WHERE <*CláusulaWhere*>
> MATE BY<*ListaAtributosCondicion*> WITH
> <*AtributoClase*> GROUP BY <*ListaAtributosTablaDatos*>

Donde

<*ListaAtributosTablaDatos*> : := <*Atributo*>,<*ListaAtributos*>
<*ListaAtributos*>: :=<*Atributo*>, <*ListaAtributos*>
<*ListaAtributos*>: :=<*Atributo*>
<*ListaAtributosCondicion*>: :=<*Atributo*>,<*ListaAtributos*>
<*AtributoClase*>::=<*Atributo*>

La cláusula SELECT <*ListaAtributosTablaDatos*> permite seleccionar de la tabla <*NombreTablaDatos*> tanto el conjunto de atributos que serán combinados <*ListaAtributosCondicion*> como el atributo con el cual se combinará el <*AtributoClase*>.

La cláusula INTO <*NombreTablaMate*> define el nombre de la tabla <*NombreTablaMate*> donde se almacenarán los resultados de la primitiva MATE cuyo esquema estará determinado por los atributos de <*ListaAtributosTablaDatos*>. Si no se especifica la cláusula INTO, el resultado se almacenará en una tabla temporal [31].

La cláusula FROM <*NombreTablaDatos*> WHERE<*CláusulaWhere*> determina el nombre de la tabla de datos de entrada <*NombreTablaDatos*> con las restricciones <*CláusulaWhere*> que los registros deben cumplir [31].

La cláusula MATE BY <*ListaAtributosCondicion*> WITH <*AtributoClase*> determina el conjunto de atributos <*ListaAtributosCondicion*> con los cuales el atributo clase <*AtributoClase*> se combinará [31].

La cláusula GROUP BY <*ListaAtributosTablaDatos*> agrupa la tabla de entrada <*NombreTablaDatos*> por los atributos <*ListaAtributosTablaDatos*>

La primitiva MATE BY facilita la tarea de clasificación y la construcción de un árbol de decisión, al calcular conjuntamente con las funciones agregadas *Gain()* y *Entro()*, en cada partición y para cada atributo, la ganancia de información y la entropía, respectivamente [31].

Ejemplo. Timarán [31]. Sea la tabla Sintomas (SID, D_MUSCULAR, TEMPERATURA, GRIPA) de la Tabla 22. Obtener las ocurrencias de las diferentes combinaciones de los atributos d_muscular, temperatura con el atributo gripa y almacenar el resultado en la tabla clasesintomas. La orden SQL que permite obtener esta consulta es la siguiente [31]:

SELECT *d_muscular,tempeartura,gripa, count(*)* INTO *clasesintomas*
FROM *sintomas*
MATE BY *d_muscular,tempertura* WITH *gripa*
GROUP BY *d_muscular,tempertura,gripa*

Tabla 22: Tabla Síntomas.

SID	D_MUSCULAR	TEMPERATURA	GRIPA
1	Si	Alta	Si
2	No	Alta	Si
3	Si	Media	No
4	No	Media	Si
5	Si	Normal	Si
6	No	Normal	No

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 30 [31]

Una vez seleccionados los atributos especificados en la cláusula SELECT, la primitiva MATE BY forma todas las posibles combinaciones con los atributos d_*muscular*, *tempertura* y el atributo clase *gripa* (Tabla 23). El resultado se agrupa con la cláusula GROUP BY, se cuenta la frecuencia de las parejas y finalmente se almacena en la tabla *clasesintomas* (Tabla 24) [31].

Tabla 23: Resultado primitiva Mate

D_MUSCULAR	TEMPERATURA	GRIPA
Si	Null	si
Null	alta	si
Si	Alta	si
No	Null	si
Null	Alta	si
No	Alta	si
Si	null	no
Null	media	no
Si	media	no
No	null	si
Null	media	si
No	media	si
Si	Null	si
Null	Normal	si
Si	Normal	si
No	Null	no
Null	Normal	no
No	Normal	no

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 30 [31]

Tabla 24: Clasesintomas

D_MUSCULAR	TEMPERATURA	GRIPA	COUNT
si	null	si	2
si	null	no	1
si	normal	si	1
si	media	no	1
si	alta	si	1
no	null	si	2
no	null	no	1

D_MUSCULAR	TEMPERATURA	GRIPA	COUNT
no	normal	no	1
no	media	si	1
no	alta	si	1
null	normal	si	1
null	normal	no	1
null	media	si	1
null	media	no	1
null	alta	si	2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 30 [31]

3.2.2 Función algebraica agregada Entro y **Función agregada SQL Entro.** A continuación se describe la función algebraica agregada Entro y función agregada SQL Entro.

Función algebraica agregada Entro() [31]

La función *Entro()* permite calcular la entropía de una relación R con respecto a un atributo denominado atributo condición y un atributo clase [31].

Tiene la siguiente sintaxis [31]:

Entro(*atributo; atributo_clase;R*)

donde <*atributo*> es el atributo condición de la relación *R* y <*atributo_clase*> es el atributo con el que se combina el atributo <*atributo*> [31].

La función *Entro*(A_k*; Ac; R*), retorna la entropía de *R* con respecto al atributo A_k, que se obtiene de la siguiente manera :

$$Entro(A_k;Ac;R)=\{y \mid y = -\sum p_{ij} \log_2(p_{ij}),\ i=1..t,\ j=1..q,\ p_{ij} = s_{ij} / |S_j| \}$$

donde $p_{ij}= s_{ij}/ |S_j|$ es la probabilidad que una tupla en S_j pertenezca a la clase C_i. La entropía de *R* con respecto al atributo clase *Ac* es:

$Entro(Ac;Ac;R)=\{y \mid y = -\sum p_i \log_2(p_i),\ i=1..t,\ p_i = r_i / m\}$

donde p_i es la probabilidad que un tupla cualquier pertenezca a la clase C_i y r_i el número de tuplas de *r(A)* que pertenecen a la clase C_i [31].

Función agregada SQL Entro() [31]

Esta función agregada SQL implementa la función algebraica agregada *Entro()* en la cláusula SQL SELECT SQL *Entro()* permite calcular, conjuntamente con la primitiva *Mate By* la entropía de una tabla con respecto a cada una de las combinaciones de los *atributos condición* con el *atributo clase*. SQL *Entro()* se debe ejecutar conjuntamente con la función agregada *Count()* [31].

Dentro de la cláusula SELECT, SQL *Entro()* tiene la siguiente sintaxis [31]:

SELECT <*ListaAtributosTablaDatos*>, *Count(*)*, *Entro(*)*
[INTO <*NombreTablaMate*>]
FROM <*NombreTablaDatos*>
WHERE *CláusulaWhere*>
MATE BY<*ListaAtributosCondicion*> WITH <*AtributoClase*>
GROUP BY <*ListaAtributosTablaDatos*>

Ejemplo. Timarán [31]. Sea la tabla Sintomas de la Tabla 22, calcular la entropía de las diferentes combinaciones de los atributos d_muscular, temperatura con el atributo gripa y almacenar el resultado en la tabla entrosintomas.
Esta consulta se obtiene mediante la siguiente sentencia SQL [31]:

SELECT *d_muscular,temperatura,gripa, count(*), Entro(*)* INTO *entrosintomas*
FROM *sintomas*
MATE BY *d_muscular,tempertura* WITH *gripa*
GROUP BY *d_muscular,tempertura,gripa*

Una vez se obtiene el resultado de ejecutar la primitiva MATE BY, el agrupamiento y el count(*) (Tabla 24), se ejecuta la función *Entro()*, la cual,

inicialmente, por cada valor igual, no nulo, de cada atributo condicional o combinación de atributos condicionales, calcula su parte de la entropía, teniendo en cuenta los diferentes valores del atributo clase (Tabla 25). Posteriormente suma estos valores parte, obtiene la entropia y genera la tabla *entrosintomas* concatenando los diferentes valores del atributo clase en un solo valor, para cada atributo condicional o combinación de atributos condicionales, con respecto a los cuales, se calcula la entropia (Tabla 26) [31].

Tabla 25: Resultado Parcial función Entro()

D_MUSCULAR	TEMPERATURA	GRIPA	COUNT()	ENTRO()
Si	Null	Si	2	2/3log2(2/3)
Si	Null	No	1	1/3log2(1/3)
Si	Normal	Si	1	1/1log2(1/1)
Si	Media	No	1	1/1log2(1/1)
Si	Alta	Si	1	1/1log2(1/1)
No	Null	Si	2	2/3log2(2/3
No	Null	No	1	1/3log2(1/3)
No	Normal	No	1	1/1log2(1/1)
No	Media	Si	1	1/1log2(1/1)
No	Alta	Si	1	1/1log2(1/1)
Null	normal	Si	1	1/2log2(1/2)
Null	normal	No	1	1/2log2(1/1)
Null	media	Si	1	1/2log2(1/2)
Null	media	No	1	1/2log2(1/2)
Null	alta	Si	2	2/2log2(2/2)

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 31 [31]

Tabla 26: Entrosintomas

D_MUSCULAR	TEMPERATURA	GRIPA	COUNT()	ENTRO()
Si	Null	sino	3	2/3log2(2/3)+ /3log2(1/3)
Si	Normal	Si	1	1/1log2(1/1)
Si	Media	No	1	1/1log2(1/1)
Si	Alta	Si	1	1/1log2(1/1)
No	Null	sino	3	2/3log2(2/3+1/3log2(1/3)
No	Normal	No	1	1/1log2(1/1)
No	Media	Si	1	1/1log2(1/1)
No	Alta	Si	1	1/1log2(1/1)
Null	normal	sino	2	1/2log2(1/2)+1/2log2(1/2)

D_MUSCULAR	TEMPERATURA	GRIPA	COUNT()	ENTRO()
Null	media	sino	2	1/2log2(1/2)+1/2log2(1/2)
Null	alta	Si	2	2/2log2(2/2)

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 32 [31]

3.2.3 Función algebraica agregada Gain y **Función agregada SQL Gain.** A continuación se describe la función algebraica agregada Gain y función agregada SQL Gain.

Función algebraica agregada *Gain()* [31]

La función Gain() permite calcular la reducción de la entropía causada por el conocimiento del valor de un atributo de una relación [31].

Su sintaxis es la siguiente[31]:

Gain(*atributo*;*atrib_clase*;*R*)

donde <*atributo*> es el atributo condición de la relación *R* y <*atributo_clase*> es el atributo con el que se combina el atributo <*atributo*>.

La función *Gain()* permite calcular la ganancia de información obtenida por el particionamiento de la relación *R* de acuerdo con el atributo <*atributo*> y se define [31]:

$$Gain(A_k;Ac;R)=\{y\ y = Entro(Ac;Ac;R) - Entro(A_k;Ac;R)\}$$

donde *Entro* (*Ac; Ac; R*) es la entropía de la relación *R* con respecto al atributo clase *Ac* y $Entro(A_k;Ac;R)$ es la entropía de la relación *R* con respecto al atributo A_k .

Función agregada SQL Gain() [31]

Esta función agregada SQL implementa la función algebraica Gain() en la cláusula SQL SELECT. SQL Gain() permite calcular, conjuntamente con la primitiva Mate by, la ganancia de información de una tabla con respecto a cada una de las combinaciones de los atributos condición con el atributo clase. Internamente SQL Gain() calcula la entropía del atributo clase, por ello se debe ejecutar conjuntamente con las funciones agregadas Count() y Entro() [31].

Sintaxis:

SELECT <*ListaAtributosTablaDatos*>, *Count* (*), *Entro* (*), *Gain* (*)
[INTO <*NombreTablaMate*>]
FROM <*NombreTablaDatos*>
WHERE <*CláusulaWhere*>
MATE BY<*ListaAtributosCondicion*> WITH <*AtributoClase*>
GROUP BY <*ListaAtributosTablaDatos*>

Ejemplo. Timarán [31]. Sea la tabla Sintomas de la Tabla 22. Calcular la ganancia de información de las diferentes combinaciones de los atributos d_muscular, temperatura con el atributo gripa y almacenar el resultado en la tabla GanSintomas.

Esta consulta se obtiene mediante la siguiente sentencia SQL [31]:

SELECT *d_muscular,temperatura,gripa, count(*), Entro(*), Gain(*)*
INTO *gansintomas*
FROM *sintomas*
MATE BY *d_muscular,tempertura* WITH *gripa*
GROUP BY d_*muscular*,tempertura,*gripa*

El proceso para el cálculo de la ganancia es parecido a la de entropía. Una vez calculada la entropía (Tabla 26) se ejecuta la función *Gain*(), la cual, inicialmente, concatena los diferentes valores de los atributos condición y clase en un solo valor, así mismo suma las ocurrencias del resultado de la función *count*() y los valores de la función *entro*() [31].

Posteriormente se calcula la entropía del conjunto clase y la de los posibles nodos y finalmente, con estos datos, calcula la ganancia de información y la almacena en la tabla gansintomas (
Tabla 27).

Tabla 27: GanSintomas

D_MUSCULAR	TEMPERATURA	GRIPA	COUNT()	ENTRO()	GAIN()
Sino	Null	sinosino	6	(2/3log2(2/3)+ 1/3log2(1/3)) +(2/3log2(2/3)+1/3log2(1/3))	(4/6log2(4/6)+2/6log2(2/6))- 3/6(2/3log2(2/3)+1/3log2(1/3))- 3/6((2/3log2(2/3)+1/3lo
Sino	Normal	sino	2	1/1log2(1/1)+ 1/1log2(1/1)	(1/2log2(1/2)+ 1/2log2(1/2))- 1/2(1/1log2(1/1))-
Sino	Media	nosi	2	1/1log2(1/1)+ 1/1log2(1/1)	(1/2log2(1/2)+ 1/2log2(1/2))- 1/2(1/1log2(1/1))-
Sino	Alta	Sisi	2	1/1log2(1/1)+ 1/1log2(1/1)	2/2log2(2/2)- 1/2(1/1log2(1/1))- 1/2(1/1log2(1/1))
null	normal media alta	sino sino Si	6	1/2log2(1/2)+ 1/2log2(1/2)+ 1/2log2(1/2)+ 1/2log2(1/2)+ 2/2log2(2/2)	(4/6log2(4/6)+2/6log2(2/6))- 2/6(1/2log2(1/2)+ 1/2log2(1/2))- 2/6(1/2log2(1/2)+

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 33 [31]

3.2.4 Operador Describe Classifier y SQL Describe Classification Rules. A continuación se describe Operador Describe Classifier y SQL Describe Classification Rules.

Operador Describe Classifier (βμ) [31]

Describe Classifier (βμ) es un operador unario que toma como entrada la relación

resultante de los operadores *Mate By*, *Entro()* y *Gain()* y produce una nueva relación donde se almacenan los valores de los atributos que formarán los diferentes nodos del árbol de decisión [31].
La sintaxis del operador Describe Classifier es la siguiente [31]:

βμ(R)

Formalmente, sea *A={A1, .., An,E,G}* el conjunto de atributos de la relación *R* de grado *n+2* y cardinalidad *m*. El operador β*μ* aplicado a *R*:

βμ (R) = { t_i (Y) | Y={N,P,A,V,C }, si t_i=<val(N),null,val(A),null,null> ∈ raiz,

si t_i=<val(N),val(P),val(A),val(V),val(C)> ∈ hoja, si

t_i=<val(N),val(P),val(A),val(V),null> ∈ nodo interno}

produce una nueva relación con esquema *R(Y), Y={N,P,A,V,C }* donde *N* es el atributo que identifica el número de nodo, *P* identifica el nodo padre, *A* identifica el nombre del atributo asociado a ese nodo, *V* es el valor del atributo *A* y *C* es el atributo clase. Su extensión *r (Y)*, está formada por un conjunto de tuplas en las cuales si los valores de los atributos son:
N<>null, P=null, A<>null,V=null y C=null corresponde a un nodo raiz; si N<>null, P<>null, A<>null,V<>null y C<>null corresponde a una hoja o nodo terminal y si N<>null, P<>null, A<>null,V<>null y C=null corresponde a un nodo interno.

Describe Classifier facilita la construcción del árbol de decisión y por consiguiente la generación de reglas de clasificación [31].

Operador SQL Describe Classification Rules [31]

El operador SQL *Describe Classification Rules* implementa el operador algebraico *Describe Classifier* en una nueva cláusula SQL. Este operador construye el árbol de decisión y genera las reglas de clasificación. Permite la construcción del árbol de decisión de manera unificada con el cálculo de la métrica de particionamiento con la primitiva *Mate By* y las funciones agregadas *Entro*() y *Gain*() en una sola

instrucción SQL o en forma separada con sentencias SQL independientes, para luego generar las reglas [31].

Sintaxis:

DESCRIBE CLASSIFICATION RULES
[INTO <*TablaReglasClasificación*>] FROM <*NombreTablaArbol*>
USING <*NombreTablaMétrica*>
[DO <*SubconsultaCálculoMétrica*>]

<*SubconsultaCálculoMétrica*>::=<*SFWMG*>
<*SFWMG*> ::= <*SELECT FROM WHERE MATE BY GROUP BY*>

Donde:

La cláusula *DESCRIBE CLASSIFICATION RULES* especifica la obtención de reglas de clasificación.

La cláusula opcional *[INTO <TablaReglasClasificcion>]* permite almacenar en una tabla <*TablaReglasClasificación*> las reglas de clasificación que se generen, a partir de la tabla de nodos del árbol <*NombreTablaArbol*>, para posteriores consultas [31].

La cláusula *FROM <NombreTablaArbol>* especifica la tabla <*NombreTablaArbol*> donde se encuentran los datos necesarios para la construcción del árbol de decisión, que servirá de base para la generación de reglas de clasificación. La tabla <*NombreTablaArbol*>, la construye el operador *Describe*, en tiempo de ejecución, utilizando la tabla de métricas <*NombreTablaMétrica*>.

La cláusula *USING <NombreTablaMétrica>* determina la tabla <*NombreTablaMétrica*> donde se encuentran los valores de los atributos y las métricas utilizadas para construir el árbol [31].

La cláusula opcional *[DO <SubconsultaCálculoMétrica>]* permite especificar conjuntamente con la cláusula *DESCRIBE*, la subconsulta <*SubconsultaCálculoMétrica*> que permite calcular, para los atributos condición y atributo clase, las métricas Entropía y Ganancia de Información, utilizando las nuevas funciones agregadas *Entro()* y *Gain()* junto con la primitiva *MATE BY*. En

el caso de que esta cláusula no se especifique, los procesos de cálculo de la métrica y el de construcción y generación de reglas se realizarían de manera independiente. Primero se calculará la métrica de particionamiento en cada nodo del árbol mediante una sentencia *<SELECT FROM WHERE MATE BY GROUP BY>* y posteriormente se construirá el árbol y se generarán las correspondientes reglas de Clasificación [31]. Los siguientes ejemplos ilustran estos procesos:

Ejemplo. Timarán [31]. Sea la tabla Síntomas (Tabla 22), encontrar las reglas de clasificación y almacenarlas en la tabla *ReglasClasificación*.

La sentencia SQL unificada que genera las reglas de clasificación es [31]:

DESCRIBE CLASSIFICATION RULES
INTO *reglasclasificación*
FROM *nodosarbol*
USING *métricaspartición*
DO
SELECT *sid,d_muscular,temperatura,gripa*, *count(*), Entro(*), Gain(*)*
INTO *gansintomas*
FROM *sintomas*
MATE BY *sid,d_muscular,tempertura* WITH *gripa*
GROUP BY *d_muscular,tempertura,gripa*

De igual manera se procede con sentencias SQL independientes [31]:

SELECT *sid,d_cabeza,d_muscular,temperatura,gripa, count(*), Entro(*), Gain(*)*
INTO *gansintomas*
FROM *sintomas*
MATE BY *sid,d.cabeza,d_muscular,tempertura WITH gripa*
GROUP BY *d_cabeza,d_muscular,tempertura,gripa*
DESCRIBE CLASSIFICATION RULES
INTO *reglasclasificación*
FROM *nodosarbol*
USING *métricaspartición*

En este ejemplo a partir de la tabla métricaspartición, el operador Describe Classification Rules construye la tabla nodosarbol y con ella genera las reglas, almacenándolas en la tabla reglasclasificación [31].

3.2.5 Mate-Tree: un Algoritmo de Clasificación por Árboles de Decisión.

Mate-Tree es un algoritmo que se basa en los operadores del álgebra relacional *Mate, Describe Classifier*, y las funciones agregadas *Entro() y Gain()* para la generación de reglas de clasificación. Este hecho facilita su integración al interior de cualquier SGBD, acoplando la tarea de Clasificación de una manera fuerte y favorece la aplicación de técnicas de optimización de consultas para mejorar su rendimiento [31].

El algoritmo se muestra en la Figura 20 [31].

Figura 20: Algoritmo Mate-Tree

```
//Calcula entropía atributo clase Ac
Entro(Ac;Ac, R);
Forall t Î R do begin
// Se aplica el operador Mate
        R1=mLC,Ac(R)
// cuenta las ocurrencias de las diferentes combinaciones
// de los atributos condición LC y atributo clase Ac
        Count(R1)
// calcula entropía
        Entro(LC,R1)
// calcula ganancia
        R2=Gain(LC,R1)
End
//construye el arbol de decisión con operador Describe Classifier
        Arbol=bm(R2)
```

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 44 [31]

En el primer paso el algoritmo calcula la Entropía de la relación R con respecto al atributo clase. En el subsiguiente paso, se aplica el operador *Mate* con el fin de generar todas las posibles combinaciones de los atributos condición con el atributo clase. Se calcula el número de ocurrencias de cada combinación y a la relación resultante R1, se aplica la funcion agregada *Entro()* que calcula para cada combinación de atributos condición y clase la entropía de la relación R1 con respecto a estos atributos. Posteriormente, se calcula con la función agregada *Gain(),* la Ganancia de Información obtenida por el particionamiento de la relación R1 por las diferentes combinaciones de atributos condición y clase. Finalmente, con la relación resultante R2, el operador *describe classifier* construye el árbol de decisión [31].

Ejemplo. Timarán [31]. Sea un conjunto de datos de entrenamiento, el cual es representado en la
Tabla 28.

Tabla 28: Datos de entrenamiento para Mate-Tree

SID	D_MUSCULAR	TEMPERATURA	GRIPA
1	Si	Alta	Si
2	No	Alta	Si
3	Si	Media	No
4	No	Media	Si
5	Si	Normal	Si
6	No	Normal	No

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 45 [31]

Si se aplica a esta tabla la primitiva *MATE BY*, se forman todas las posibles combinaciones con los atributos D_MUSCULAR, TEMPERATURA y el atributo clase GRIPA (Tabla 29). Se cuenta la frecuencia de las parejas y finalmente se almacena en una nueva tabla (Tabla 30) [31].

Tabla 29: Resultado Primitiva Mate

D_MUSCULAR	TEMPERATURA	GRIPA
Si	Null	Si
Null	Alta	Si
Si	Alta	Si
No	Null	Si
Null	Alta	Si
No	Alta	Si
Si	Null	No
Null	Media	No
Si	Media	No
No	Null	Si
Null	Media	Si
No	Media	Si
Si	Null	Si
Null	Normal	Si
Si	Normal	Si
No	Null	No
Null	Normal	No
No	Normal	No

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 45 [31]

Tabla 30: Clase

D_MUSCULAR	TEMPERATURA	GRIPA	COUNT
Si	Null	Si	2
Si	Null	No	1
Si	Normal	Si	1
Si	Media	No	1
Si	Alta	Si	1
No	Null	Si	2
No	Null	No	1
No	Normal	No	1
No	Media	Si	1
No	Alta	Si	1
Null	Normal	Si	1
Null	Normal	No	1
Null	Media	Si	1
Null	Media	No	1
Null	Alta	Si	2

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 46 [31]

A la Tabla 30 se le aplica la función agregada *Entro*() que calcula la entropía de una tabla con respecto a cada una de las combinaciones de los atributos condición con el atributo clase [31]. Se obtiene la tabla de entropía (ver Tabla 31 y Tabla 32).

Tabla 31: Resultdo parcial función Entro()

D_MUSCULAR	TEMPERATURA	GRIPA	COUNT	ENTRO()
Si	Null	Si	2	$2/3\log_2(2/3)$
Si	Null	No	1	$1/3\log_2(1/3)$
Si	Normal	Si	1	$1/1\log_2(1/1)$
Si	Media	No	1	$1/1\log_2(1/1)$
Si	Alta	Si	1	$1/1\log_2(1/1)$
No	Null	Si	2	$2/3\log_2(2/3)$
No	Null	No	1	$1/3\log_2(1/3)$
No	Normal	No	1	$1/1\log_2(1/1)$
No	Media	Si	1	$1/1\log_2(1/1)$
No	Alta	Si	1	$1/1\log_2(1/1)$
Null	Normal	Si	1	$1/2\log_2(1/2)$
Null	Normal	No	1	$1/2\log_2(1/2)$
Null	Media	Si	1	$1/2\log_2(1/2)$
Null	Media	No	1	$1/2\log_2(1/2)$
Null	Alta	Si	2	$2/2\log_2(2/2)$

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 33 [31]

Tabla 32: Resultado Entropia.

D_MUSCULAR	TEMPERATURA	GRIPA	COUNT	ENTRO()
Si	Null	SiNo	3	$2/3\log_2(2/3) + 1/3\log_2(1/3)$
Si	Normal	Si	1	$1/1\log_2(1/1)$
Si	Media	No	1	$1/1\log_2(1/1)$
Si	Alta	Si	1	$1/1\log_2(1/1)$
No	Null	SiNo	3	$2/3\log_2(2/3) + 1/3\log_2(1/3)$
No	Normal	No	1	$1/1\log_2(1/1)$
No	Media	Si	1	$1/1\log_2(1/1)$
No	Alta	Si	1	$1/1\log_2(1/1)$
Null	Normal	SiNo	2	$1/2\log_2(1/2) + 1/2\log_2(1/2)$
Null	Media	SiNo	2	$1/2\log_2(1/2) + 1/2\log_2(1/2)$
Null	Alta	Si	2	$2/2\log_2(2/2)$

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 46 [31]

Una vez calculada la entropía se aplica la función agregada *gain*(), la cual, inicialmente, concatena los diferentes valores de los atributos condición y clase en un solo valor, así mismo suma las ocurrencias y los valores de las entropías.

Posteriormente, se calcula la entropía del conjunto clase y la de los posibles nodos y finalmente, con estos datos, calcula la ganancia de información y la almacena en la tabla de ganancia (ver Tabla 33), y se genera la tabla contenedora de nodos (ver Tabla 34), a la cual se le aplica el operador describe classifier y genera el árbol de decisión.

Tabla 33: Ganancia

D_MUS-CULAR	TEMPE-RATURA	GRIPA	COUNT	ENTRO()	GAIN()
Si No	Null	SiNo SiNo	6	(2/3log$_2$(2/3) + 1/3log$_2$(1/3)) + (2/3log$_2$(2/3) + 1/3log$_2$(1/3))	(4/6log$_2$(4/6) + 2/6 log$_2$(2/6)) – 3/6 (2/3 log$_2$(2/3) + 1/3 log$_2$(1/3)) - 3/6 (2/3 log$_2$(2/3) + 1/3 log$_2$(1/3))
Si No	Normal	Si No	2	(1/1 log$_2$(1/1)) + (1/1log$_2$(1/1))	(1/2 log$_2$(1/2) + ½ log$_2$(1/2)) – 1/2 (1/1 log$_2$(1/1)) – 1/2 (1/1 log$_2$(1/1))
SiNo	Media	SiNo	2	(1/1 log$_2$(1/1)) + (1/1log$_2$(1/1))	2/2 log$_2$(2/2) – 1/2 (1/1 log$_2$(1/1)) – 1/2 (1/1 log$_2$(1/1))
SiNo	Alta	SiSi	1	(1/1 log$_2$(1/1)) + (1/1log$_2$(1/1))	2/2 log$_2$(2/2) – 1/2 (1/1 log$_2$(1/1)) – 1/2 (1/1 log$_2$(1/1))
Null	Normal Media Alta	SiNo SiNo Si	6	(1/2og$_2$(1/2) + 1/2og$_2$(1/2)) + (1/2og$_2$(1/2) + 1/2og$_2$(1/2)) + (2/2og$_2$(2/2))	(4/6 log$_2$(4/6) + 2/6 log$_2$(2/6)) - 2/6 (1/2 log$_2$(1/2) + 1/2 log$_2$(1/2)) - 2/6 (1/2 log$_2$(1/2) + 1/2 log$_2$(1/2)) - 2/6 (2/2 log$_2$(2/2))

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002. Pág. 46 [31]

Tabla 34: Nodos

NODO	PADRE	ATRIBUTO	VALOR	CLASE
N0	Null	Temperatura	Null	Null
N1	N0	Temperatura	Alta	Si
N2	N0	Temperatura	Media	No
N3	N0	Temperatura	Normal	Null
N4	N3	D_Muscular	Si	Si
N5	N3	D_Muscular	No	No

Fuente Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002.

4. CONSTRUCCION DE LA HERRAMIENTA Pg_KDD

4.1 ANÁLISIS UML

En esta etapa se definen los requerimientos del sistema, los casos de uso de la herramienta con sus respectivos diagramas y el diagrama de secuencia del sistema.

4.1.1 Requerimientos. Los requerimientos para el desarrollo de la herramienta PG_KDD, están distribuidos por las funciones principales que componen la herramienta; de este modo se describirán cada una de las funcones y sub funciones**:**

Los requerimientos del manejo de la ejecución y manejo de la herramienta se describen en la Tabla 35.

Tabla 35: Requerimientos Ejecucion y Manejo de Pg_KDD

# Ref.	Función	Categoría	Atributo	Observaciones	Prioridad
R1	Ejecutar la aplicación	Evidente	Interfaz		Obligatorio
R2	Mostrar interfaz gráfica de la herramienta	Evidente	Interfaz		Obligatorio
R2	Mostrar mensajes de ayuda, respuesta o error si es necesario	Evidente	Interfaz	Cuadros de dialogo, barra de estado	Deseable
R3	Modificar interfaz visual del aplicativo	Evidente	Interfaz		Opcional
R4	Permitir ocultar la Barra de Estados	Evidente	Interfaz		Obligatorio
R5	Mostrar u ocultar el área de Propiedades	Evidente	Interfaz		Obligatorio

# Ref.	Función	Categoría	Atributo	Observaciones	Prioridad
R6	Mostrar u ocultar el árbol de Conexiones	Evidente	Interfaz		Obligatorio
R7	Facilitar el cambio de Temas de la interfaz	Evidente	Interfaz		Deseable
R8	Refrescar toda la interfaz visual del sistema	Evidente	Interfaz		Obligatorio

Fuente. Esta investigación.

Los requerimientos de la administración de conexiones a la herramienta se describen en la Tabla 36.

Tabla 36: Requerimientos administracion de conexiones

# Ref.	Función	Categoría	Atributo	Observaciones	Prioridad
R1	Permitir conexiones con el SGBD PostgreSQL	Evidente	Interfaz	El SGBD debe estar instalado en el equipo	Obligatorio
R2	Mostrar listado de conexiones que hayan sido guardadas	Oculto	Información		Obligatorio
R3	Abrir el archivo de las conexiones que hayan sido guardadas	Oculto	Información	El archivo lo debe haber generado por la aplicación	Obligatorio
R4	Extraer datos del archivo de conexiones	Oculto	Información	El archivo debe tener el formato correcto	Obligatorio
R5	Autorizar creación de Nuevas conexiones	Evidente	Interfaz		Obligatorio
R6	Facilitar el que se establezcan los atributos de conexión	Evidente	Interfaz		Obligatorio
R7	Realizar la prueba del estado de la conexión	Evidente	Interfaz		Obligatorio
R8	Permitir el guardado de los datos de la conexión	Evidente	Interfaz		Obligatorio
R9	Autorizar apertura de conexiones existentes	Evidente	Interfaz	De las mostradas en el listado	Opcional
R10	Extraer los atributos de la conexión que se seleccione	Oculto	Información		Obligatorio
R11	Mostrar el listado de bases de datos	Evidente	Interfaz		Obligatorio
R12	Cargar las tablas y atributos de cada base	Oculto	Información	Organizar la información en	Obligatorio

# Ref.	Función	Categoría	Atributo	Observaciones	Prioridad
	de datos			listados en forma de árbol visual (TreeView)	

Fuente. Esta investigación.

Los requerimientos de la manipulación de archivos SQL de la herramienta se describen en la Tabla 37.

Tabla 37: Requerimientos Manipulacion de Archivos SQL

# Ref.	Función	Categoría	Atributo	Observaciones	Prioridad
R1	Manipular archivos planos SQL	Evidente	Interfaz		Obligatorio
R2	Crear archivos SQL	Evidente	Interfaz		Obligatorio
R3	Mostrar área de edición para el archivo SQL	Evidente	Interfaz		Obligatorio
R4	Abrir archivos SQL que hayan sido guardados previamente	Evidente	Interfaz		Opcional
R5	Guardar archivos SQL	Evidente	Interfaz		Opcional
R6	Ejecutar las sentencias SQL	Evidente	Interfaz		Obligatorio
R4.4.1	Indicar al SGBD qué instrucciones debe ejecutar	Oculto	Información		Obligatorio
R7	Recibir del SGBD, y mostrar, el resultado de la ejecución de las consultas	Oculto	Información		Obligatorio
R8	Mostrar los errores proporcionados por el SGBD	Oculto	Información		Obligatorio

Fuente. Esta investigación.

Los requerimientos de la administración de base de datos de la herramienta se describen en la Tabla 38.

Tabla 38: Requerimientos Administración de bases de datos.

# Ref.	Función	Categoría	Atributo	Observaciones	Prioridad
R1	Administrar las bases de da os (DB)	Evidente	Interfaz		Obligatorio
R2	ermitir la eliminación de	Evidente	Interfaz		Obligatorio

# Ref.	Función	Categoría	Atributo	Observaciones	Prioridad
	cualquier DB				
R3	Permitir la creación de bases de datos	Evidente	Interfaz		Obligatorio
R4	Editar cualquier objeto funcional de Postgres	Evidente	Interfaz		Opcional
R5	Permitir la creación de Tablas de DB	Evidente	Interfaz		Obligatorio
R6	Permitir la eliminación de Tablas de DB	Evidente	Interfaz		Obligatorio
R7	Permitir la creación de Funciones	Evidente	Interfaz		Obligatorio
R8	Permitir la eliminación de Funciones	Evidente	Interfaz		Obligatorio
R9	Permitir la creación de Triggers	Evidente	Interfaz		Obligatorio
R10	Permitir la eliminación de Triggers	Evidente	Interfaz		Obligatorio
R11	Permitir la creación de Reglas	Evidente	Interfaz		Obligatorio
R12	Permitir la eliminación de Reglas	Evidente	Interfaz		Obligatorio
R13	Permitir la creación de Vistas	Evidente	Interfaz		Obligatorio
R14	Permitir la eliminación de Vistas	Evidente	Interfaz		Obligatorio
R15	Editar cualquier Tabla de la base de datos	Evidente	Interfaz		Opcional

Fuente. Esta investigación.

Los requerimientos de la aplicación de tareas de minería de datos para el descubrimiento de conocimiento con bases de datos de la herramienta se describen en la Tabla 39.

Tabla 39: Requerimientos para la aplicacion de minería de datos.

# Ref.	Función	Categoría	Atributo	Observaciones	Prioridad
R1	Aplicar técnicas de Minería de Datos	Evidente	Interfaz		Obligatorio
R2	Algoritmo de Asociacion	Evidente	Interfaz		Obligatorio
R3	Aplicación de Algoritmo EquipAsso	Evidente	Interfaz		Obligatorio
R4	Algoritmo de Clasificacion	Evidente	Interfaz		Obligatorio
R5	Aplicación de Algoritmo Mate-Tree	Evidente	Interfaz		Obligatorio

Fuente. Esta investigación.

Los requerimientos de la administración de consultas SQL gráficas en la herramienta se describen en la Tabla 40.

Tabla 40: Requerimientos administración de consultas SQL gráficas.

# Ref.	Función	Categoría	Atributo	Observaciones	Prioridad
R1	Realizar Consultas a la base de datos	Evidente	Interfaz		Obligatorio
R2	Manipular el contenido de las tablas de la DB	Evidente	Interfaz		Opcional
R3	Mostrar todos los datos de la Tabla seleccionada	Evidente	Interfaz		Opcional
R4	Permitir la adición de nuevas Tuplas a las tablas de la DB	Evidente	Interfaz		Opcional
R5	Permitir la eliminación de Tuplas	Evidente	Interfaz		Opcional
R6	Permitir la modificación de los datos de las Tuplas	Evidente	Interfaz		Opcional
R7	Permitir digitar y ejecutar código SQL	Evidente	Interfaz		Obligatorio
R8	Facilitar la administración de consultas SQL usando un diseñador	Evidente	Interfaz		Opcional
R9	Permitir establecer las tablas que intervendrán en la consulta	Evidente	Interfaz		Obligatorio
R10	Permitir establecer las columnas que se mostrarán al ejecutar la consulta	Evidente	Interfaz		Obligatorio
R11	Permitir establecer el orden en el que aparecerán las columnas	Evidente	Interfaz		Obligatorio
R12	Permitir la creación gráfica y automática de condiciones para la consulta	Evidente	Interfaz		Obligatorio
R13	Permitir la creación gráfica y manual de condiciones para la consulta	Evidente	Interfaz	Evitando la forma convencional de los Joins (con signo “=”)	Obligatorio
R14	Permitir el uso de Agrupaciones para los resultados de la consulta	Evidente	Interfaz		Obligatorio
R15	Permitir el Ordenamiento de los resultados de la consulta	Evidente	Interfaz		Obligatorio
R16	Visualizar los resultados de la consulta diseñada	Evidente	Interfaz		Obligatorio
R17	Permitir guardar en un archivo SQL el diseño de la consulta	Evidente	Interfaz		Obligatorio

# Ref.	Función	Categoría	Atributo	Observaciones	Prioridad
	realizada				
R18	Permitir la edición manual de las consultas que se estén diseñando	Evidente	Interfaz		Obligatorio
R19	Borrar la consulta actual si se cambia de base de datos	Evidente	Interfaz		Obligatorio
R20	Preguntar si se desea guardar la consulta al salir del diseñador	Evidente	Interfaz		Obligatorio

Fuente. Esta investigación.

4.1.2 Casos de uso. Mediante este modelo se presentan los diferentes escenarios (o caminos de uso) del sistema. Partiendo de ellos, el analista de sistemas puede identificar de forma más clara, la mayoría de los objetos involucrados en realizar determinada tarea en comunicación con los diferentes roles que adquieren los usuarios del sistema.

A continuación se describen algunos de los casos de uso más representativos de la aplicación.

Caso de Uso: Conexión

Caso de uso	Conexion
Actor principal	**Usuario**
Precondiciones	✍ **Se debe haber ejecutado el aplicativo.**
Poscondiciones	✍ **Se ejecuta la opción que el Usuario haya seleccionado.**
Flujo básico	
1. Se visualiza la interfaz de conexión de la aplicación. 2. Se procede a ingresar los datos respectivos para la conexión. 3. Se presiona el botón de testeo para verificar si los datos de conexión son validos. 4. El sistema evalúa internamente los datos ingresados e indica el resultado del testeo mediante un mensaje dentro de la interfaz. 5. Si el proceso anterior es exitoso, se procede a presionar el botón conectar. 6. Se crea la nueva conexión y se cierra la interfaz de conexión. 7. Se cargan todos los controles gráficos (Objetos SQL que contenga el usuario) en el árbol de conexiones (Tree Connections).	
Flujos alternativos	
4a. En caso de que el usuario haya ingresado mal los datos de conexión: 1. El sistema muestra un mensaje, indicando que la conexión ha fallado debido a un mal ingreso en los datos de la conexión.	

Caso de uso	Conexion

2. Se reinicia el caso de uso.

4.b En caso de que el los datos estén ingresados correctamente, y el usuario presiona el botón guardar.

1. El sistema guarda la nueva conexión, visualizándola en la tabla de conexiones.
2. Se procede a presionar conectar.

5. En caso de que los datos estén bien ingresados, pero exista un conexión con el mismo nombre o para el mismo usuario:

1. El sistema muestra mensajes de alerta describiendo que existe un dato repetido dentro de la aplicación.
2. Se reinicia el caso de uso.

Caso de Uso: Administración Base de Datos

Caso de uso	Administración Base de Datos
Actor principal	**Usuario**
Precondiciones	✍ **Se debe haber ejecutado el aplicativo.** ✍ **Se debe haber el caso de uso conectar.**
Poscondiciones	✍ **Se ejecuta la opción que el Usuario haya seleccionado.**
Flujo básico	
1. Se visualiza la interfaz principal de la aplicación. 2. Si ya se ha realizado el camino del caso de uso conectar, el aplicativo carga automáticamente en el árbol de conexiones aquellos elementos pertenecientes al usuario de la conexión entre ellos sus bases de datos. 3. El usuario procede a desplegar la conexión del árbol, visualizando las bases de datos con sus derivados de ellas (Tablas, Columnas, llaves, reglas, disparadores, funciones). 4. Con una base de datos seleccionada, el sistema activa todas las opciones de manejo básicas (creación,modificacion,eliminación) módulos de sentencias gráficas, módulo KDD. 5. El sistema espera a que el usuario seleccione una de las opciones.	
Flujos alternativos	
2a. En caso de que el usuario aun no tenga bases de datos registradas dentro del gestor: 1. El usuario puede crear una nueva base de datos. 2. Al ser creada la base de datos, el aplicativo crea automáticamente los elementos correspondientes a tablas, funciones, en otros. Los cuales también tienen las opciones de manejo básicas. 3. Se reinicia el caso de uso. 4.b En caso de que el usuario no haya seleccionado ningún elemento partiendo de un objeto de base de datos: 3. El aplicativo mantiene inactivo las opciones de manejo básicas, módulo de sentencias gráficas y módulo KDD. 4. Se reinicia el caso de uso.	

Caso de Uso: Aplicación técnicas de minería de datos

Caso de uso	Apelación técnicas de minería de datos
Actor principal	**Usuario**
Precondiciones	✍ **Se debe haber ejecutado el aplicativo.** ✍ **Se debe haber ejecutado el caso de uso conectar** ✍ **Se debe haber ejecutado el caso de uso administrar bases de datos**
Poscondiciones	✍ **Se ejecuta la opción que el Usuario haya seleccionado.**
Flujo básico	
1. Se visualiza la interfaz de minería de datos de la aplicación. 2. Se procede a aplicar el algoritmo de asociación. 3. El usuario procede insertar nodo repositorio, configurarlo, ejecutarlo y conectarlo a un nodo operador associator/assocol. 4. El usuario procede a insertar el nodo operador associator/assocol, configurarlo y ejecutarlo y lo conecta a un nodo tabla de visualización. 5. El aplicativo visualiza la sentencia sql que se procederá a ejecutar en un marco de texto. 6. El usuario procede correr el nodo tabla de visualización anterior y el aplicativo muestra su resultado en un marco de visualización. 7. El usuario conecta el nodo operador associator/assocol a un nodo algoritmo EquipAsso. 8. El usuario procede a insertar el nodo algoritmo EquipAsso, configurarlo y ejecutarlo y se conecta a un nodo tabla de visualización. 9. El aplicativo visualiza la sentencia sql que se procederá a ejecutar en un marco de texto. 10. El usuario procede correr el nodo tabla de visualización anterior y el aplicativo muestra su resultado en un marco de visualización. 11. El usuario conecta el nodo algoritmo equipaso a un nodo describe asociation rules. 12. El usuario procede a insertar el nodo describe rules, configurarlo y ejecutarlo y se conecta a un nodo reglas de visualización. 13. El aplicativo visualiza la sentencia sql que se procederá a ejecutar en un marco de texto. 14. El usuario procede correr el nodo reglas de visualización anterior y el aplicativo muestra las reglas de asociación en un marco de visualizacion. 15. Termina el algoritmo de asoccioacion. 16. Termina el caso de uso.	
Flujos alternativos	
2a. En caso de que el usuario opte por aplicar el algoritmo de clasificacion: 1. El usuario procede insertar nodo repositorio,configurarlo, ejecutarlo y conectarlo a un nodo operador mate. 2. El usuario procede a insertar el nodo operador mate, configurarlo y ejecutarlo y lo conecta a un nodo tabla de visualización. 3. El aplicativo visualiza la sentencia sql que se procederá a ejecutar en un marco de texto. 4. El usuario procede correr el nodo tabla de visualización anterior y el aplicativo muestra su resultado en un marco de visualización. 5. El usuario conecta el nodo operador mate a un nodo algoritmo matetree. 6. El usuario procede a insertar el nodo algoritmo matetree, configurarlo y ejecutarlo y se conecta a un nodo tabla de visualización. 7. El aplicativo visualiza la sentencia sql que se procederá a ejecutar en un marco de texto 8. El usuario procede correr el nodo tabla de visualización anterior y el aplicativo muestra su resultado en un marco de visualización. 9. El usuario conecta el nodo operador matetree a un nodo función agregada entro. 10. El usuario procede a insertar el nodo función agregada entro, configurarlo y ejecutarlo y se	

Caso de uso	Apelación técnicas de minería de datos
conecta a un nodo tabla de visualización. 11. El aplicativo visualiza la sentencia sql que se procederá a ejecutar en un marco de texto 12. El usuario procede correr el nodo tabla de visualización anterior y el aplicativo muestra su resultado en un marco de visualización. 13. El usuario conecta el nodo función agregada entro a un nodo función agregada gain. 14. El usuario procede a insertar el nodo función agregada gain, configurarlo y ejecutarlo y se conecta a un nodo tabla de visualización. 15. El aplicativo visualiza la sentencia sql que se procederá a ejecutar en un marco de texto 16. El usuario procede correr el nodo tabla de visualización anterior y el aplicativo muestra su resultado en un marco de visualización. 17. El usuario conecta el nodo función agregada gain a un nodo describe clasification rules. 18. El usuario inserta el nodo describe clasification rules, configurarlo y ejecutarlo y se conecta a un nodo reglas de visualización. 19. El aplicativo visualiza la sentencia sql que se procederá a ejecutar en un marco de texto 20. El usuario procede correr el nodo reglas de visualización anterior y el aplicativo muestra las reglas de clasificacion en un marco de visualizacion. 21. El usuario inserta un nodo de visualzacion TreeViewer , conecta el nodo describe clasification rules este nodo y lo ejecuta. 22. El aplicativo visualiza el árbol de nodos procedentes a las reglas de clasificación. 23. Termina el algoritmo de clasificacion. 24. Termina el caso de uso.	
Observaciones	
Tanto para el camino básico como el alternativo, el resultado final contendrá errores, si la configuración del repositorio,los operadores, operadores de descripción es incorrecta, por ende el aplicativo informara estos errores por medio de mensajes emergentes. Si el usuario intenta realizar conexiones incoherentes de nodos, el aplicativo informa mediante mensajes emergentes el error del intento de conexión.	

Caso de Uso: Manipulación de scripts SQL

Caso de uso	Manipular de scripts SQL
Actor principal	**Usuario**
Precondiciones	✍ **Se debe haber ejecutado el aplicativo.** ✍ **Se debe haber ejecutado el caso de uso conectar.** ✍ **Se debe haber ejecutado el caso de uso administrar bases de datos**
Poscondiciones	✍ **Se ejecuta la opción que el Usuario haya seleccionado.**
Flujo básico	
1. Se visualiza la interfaz principal de la aplicación. 2. Si ya se a realizado el camino del caso de uso conectar, el aplicativo carga automaticamente en el árbol de conexiónes aquellos elementos pertenecientes al usuario de la conexión entre ellos sus bases de datos. 3. El usuario elije una base de datos automáticamente se activan los controles de gestión de archivos al igual que otros. 4. El usuario selecciona la opción de nueva hoja SQL de la barra de herramientas. 5. El aplicativo despliega una interfaz para manejo de scripts SQL como pestaña en el área vistas de	

Caso de uso	Manipular de scripts SQL
la interfaz principal. 6. El usuario tiene la posibilidad de elegir entre las opciones de abrir, crear, editar y guardar un script SQL. 7. El usuario digita código SQL dentro del marco de texto de la interfaz y selecciona la opción guardar. 8. El aplicativo despliega una interfaz de carga de archivos (FileUpLoad) y espera que el usuario elija la ruta donde desee guardar el nuevo script. 9. El usuario presiona guardar. La interfaz guarda el archivo en la ruta establecida. 10. Fin del caso de uso.	
Flujos alternativos	
7a. En caso que el usuario seleccione la opción abrir script: 1. La Interfaz despliega una interfaz de carga de archivos (FileUpLoad) y espera que el usuario elija un script de extencion SQL. 2. El usuario elije el script y selecciona la opción abrir. 3. La apliacion cierra la interfaz de carga de archivos y automáticamente visualiza el contenido del script en el marco de texto. 4. La aplicación espera a que el usuario edite el script o intente cargar uno nuevo. 5. Se reinicia el caso de uso.	

4.1.3 Diagramas de casos de uso. En esta sección se presentan los diagramas de casos de uso de Pg_KDD.

4.1.3.1 Diagrama de Caso de Uso: Diagrama General. En la Figura 21, se muestra el diagrama de casos de uso general de Pg_KDD.

Figura 21: Caso de Uso General

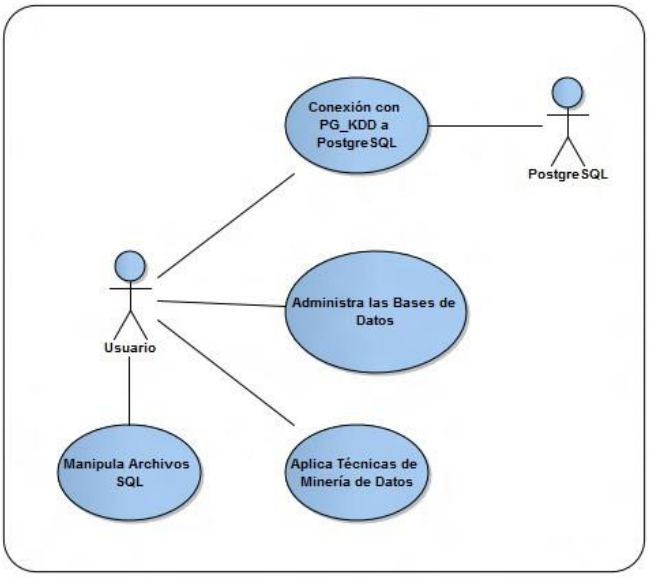

Fuente. Esta investigación.

4.1.3.2 Diagrama de Caso de Uso: Conectar. En la Figura 22, se muestra el diagrama de caso de uso que permite la conexión con el sistema PostgresKDD.

Figura 22: Caso de Uso Conectar

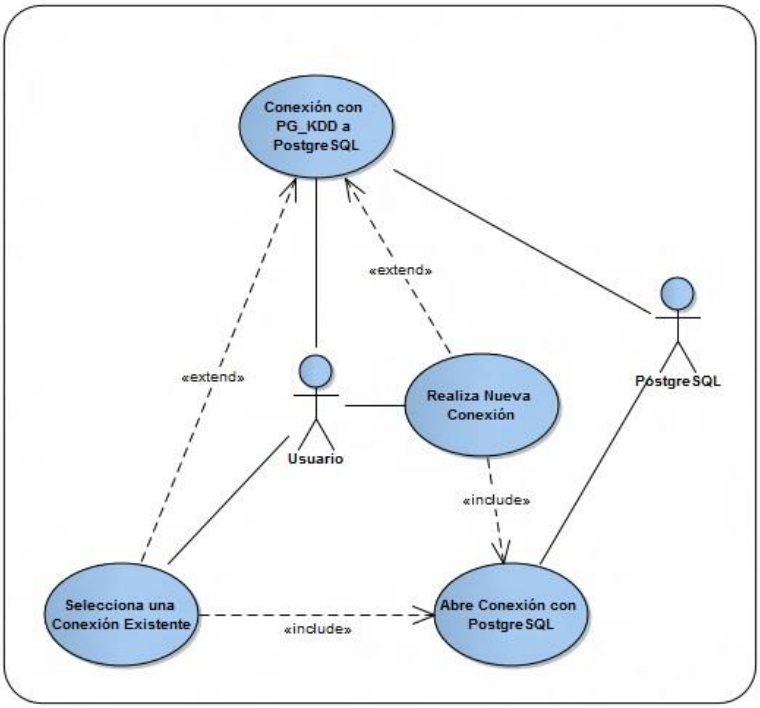

Fuente. Esta investigación.

4.1.3.3 Diagrama Caso de Uso: Administrar Bases de Datos. En la Figura 23, se presenta el caso de uso que permite la administración de base de datos.

Figura 23: Caso de Uso Adm. Base de Datos

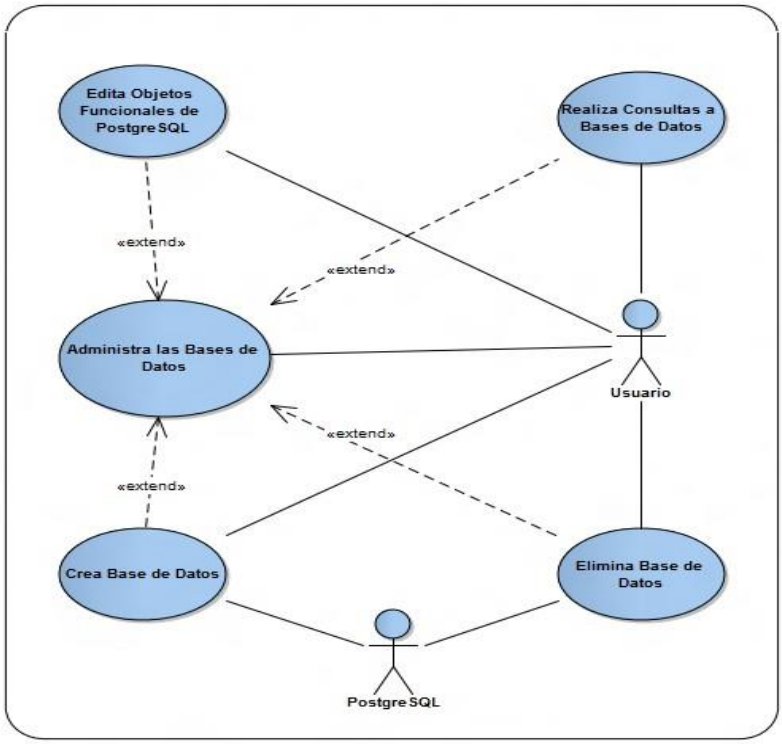

Fuente. Esta investigación.

4.1.3.4 Diagrama de Caso de Uso: Realizar de Consultas a Bases de Datos.

En la Figura 24, se describe el caso de uso que permite realizar las consultas desde Pg_KDD con las bases de datos.

Figura 24: Caso de Uso Realizar Consultas

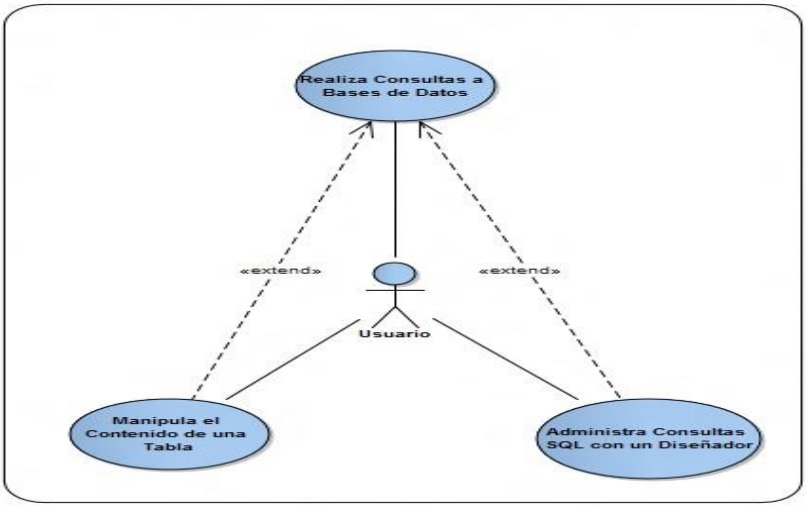

Fuente. Esta investigación.

4.1.3.5 Diagrama de Caso de Uso: Administrar Consultas SQL Gráficas.

En la Figura 25, se describe el caso de uso que permite la administración de consultas SQL de manera gráfica.

Figura 25: Caso de Uso Adm. Consultas Gráficas

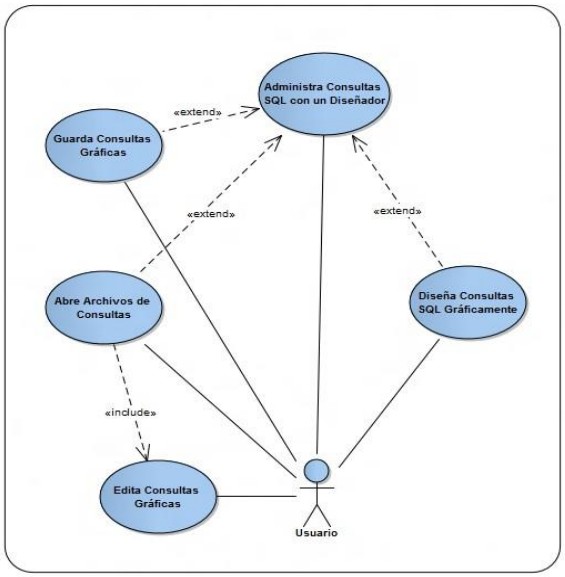

Fuente. Esta investigación.

4.1.3.6 Diagrama de Caso de Uso: Realizar de Consultas Gráficas. En la Figura 26, se describe el caso de uso que permite realizar gráficamente una consulta SQL en Pg_KDD.

Figura 26: Caso de Uso Realizar Consultas Gráficas

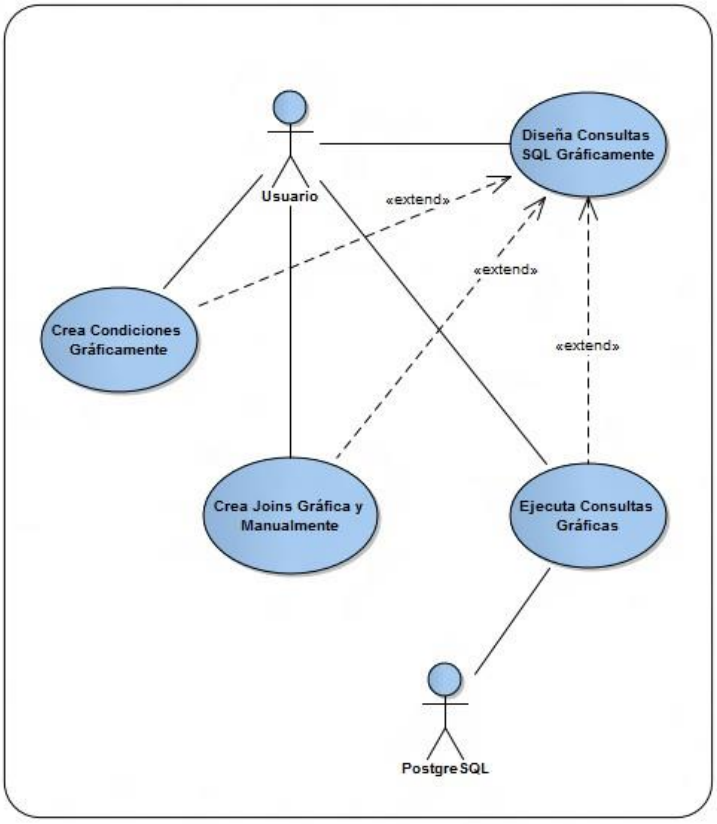

Fuente. Esta investigación.

4.1.3.7 Diagrama de Caso de Uso: Ordenar Resultados de las Consultas Gráficas. En la Figura 27, se describe el caso de uso que permite ordenar los resultados de la consulta gráfica realizada previamente.

Figura 27: Caso de Uso Ordenar Resultado Consultas Gráficas

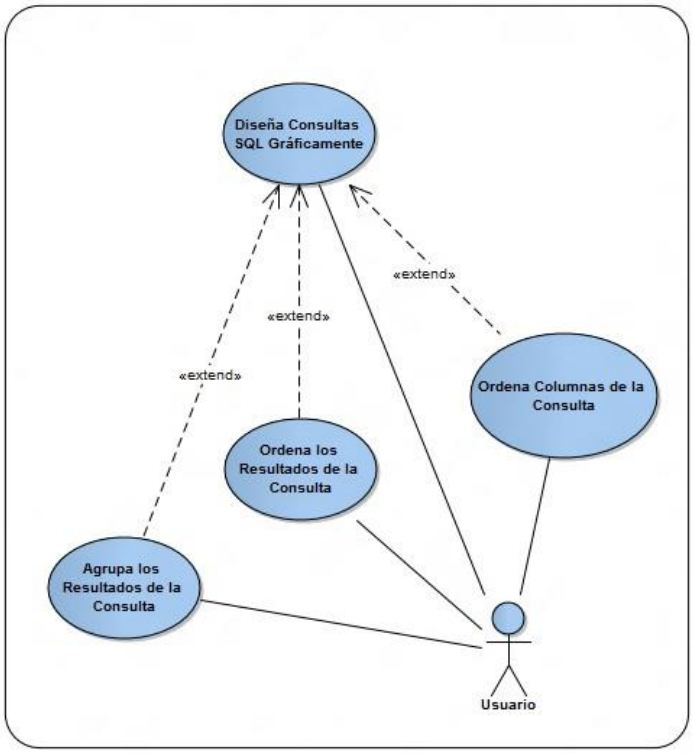

Fuente. Esta investigación.

Diagrama de Caso de Uso: Gestionar Tablas. En la Figura 28, se describe el caso de uso que permite gestionar las tablas de una base de datos.

Figura 28: Caso de Uso Gestionar Tablas

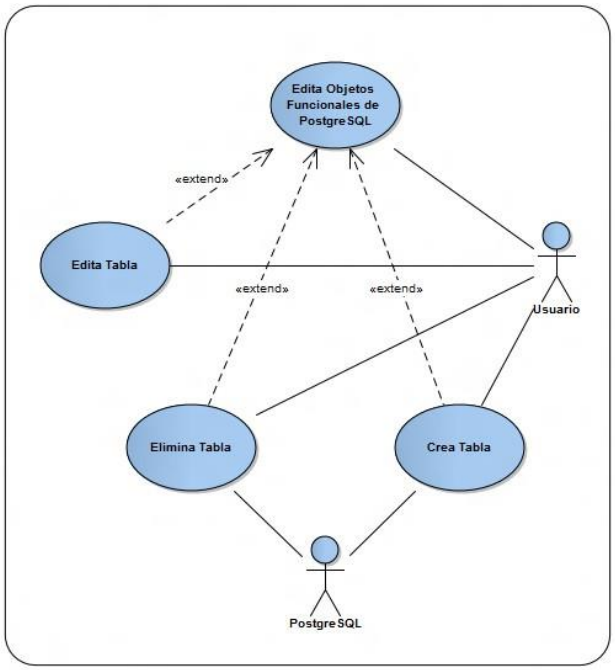

Fuente. Esta investigación.

4.1.3.8 Diagrama de Caso de Uso: Manipular el Contenido de una Tabla.

En la Figura 29 se describe el caso de uso que permite manipular los registros de una tabla de una base de datos.

Figura 29: Caso de Uso Manipular contenido de tablas

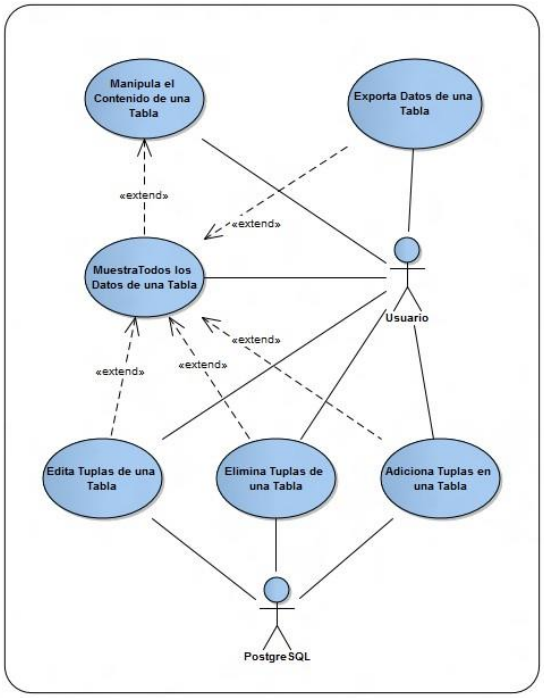

Fuente. Esta investigación.

4.1.3.9 Diagrama de Caso de Uso: Gestionar Columnas. En la Figura 30, se describe el caso de uso que permite gestionar la columna de una tabla de una base de datos.

Figura 30: Caso de Uso Gestionar Columnas

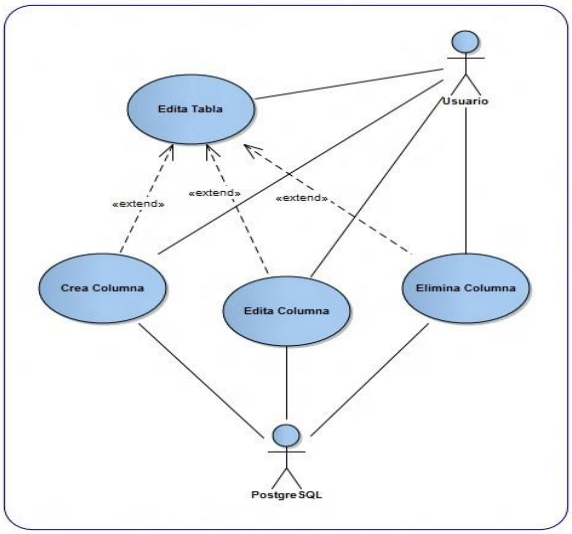

Fuente. Esta investigación.

4.1.3.10 Diagrama de Caso de Uso: Gestionar Funciones. En la Figura 31, se describe el caso de uso que permite gestionar las funciones de una base de datos.

Figura 31: Caso de Uso Gestionar Funciones

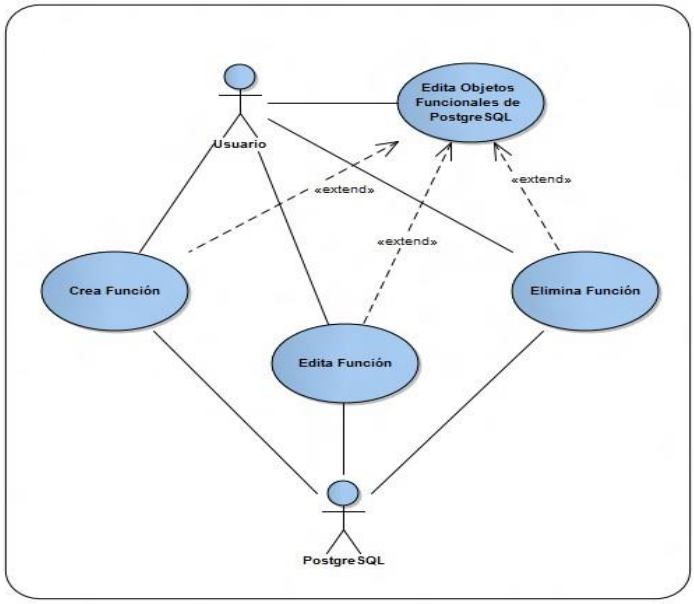

Fuente. Esta investigación.

4.1.3.11 Diagrama de Caso de Uso: Gestionar Vistas. En la Figura 32, se describe el caso de uso que permite gestionar las vistas de una base de datos.

Figura 32: Caso de Uso Gestionar Vistas

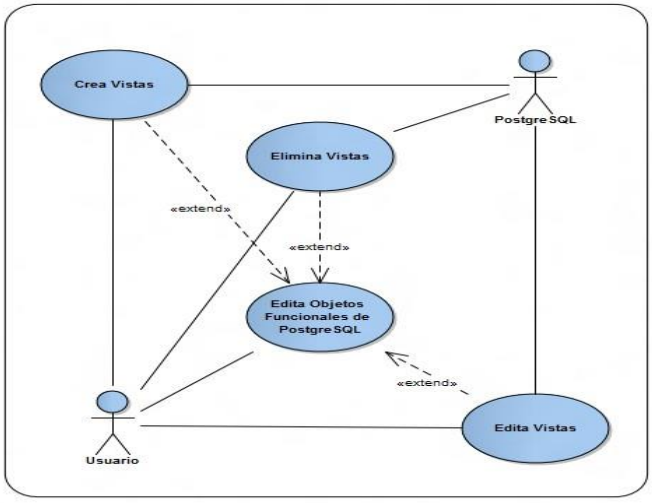

Fuente. Esta investigación.

4.1.3.12 Diagrama de Caso de Uso: Gestionar Reglas. En la **Figura 33**, se describe el caso de uso que permite gestionar las reglas de una base de datos**.**

Figura 33: Caso de Uso Gestionar Reglas

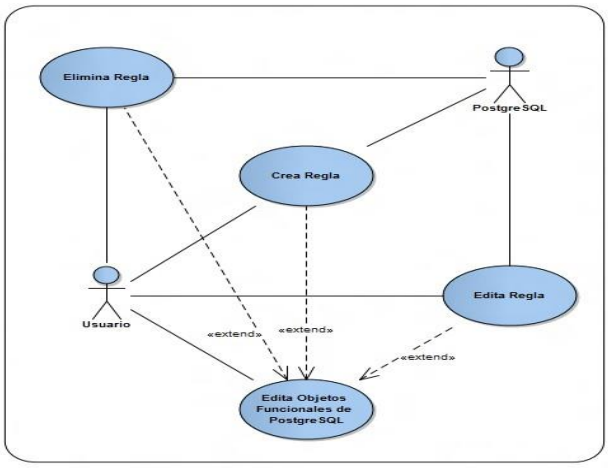

Fuente. Esta investigación.

4.1.3.13 Diagrama de Caso de Uso: Gestionar Triggers. En la Figura 34, se describe el caso de uso que permite gestionar los disparadores de una base de datos.

Figura 34: Caso de Uso Gestionar Disparadores

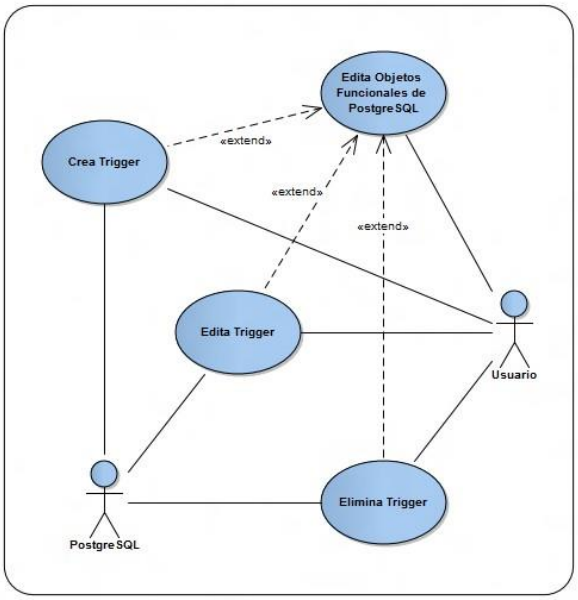

Fuente. Esta investigación.

4.1.3.14 Diagrama de Caso de Uso: Aplicar Técnicas de Minería de Datos.

En la Figura 35, se describe el caso de uso que permite realizar los algoritmos respectivos a las tareas de descubrimiento de conocimiento para asociación y clasificación.

Figura 35: Caso de Uso Minería de Datos

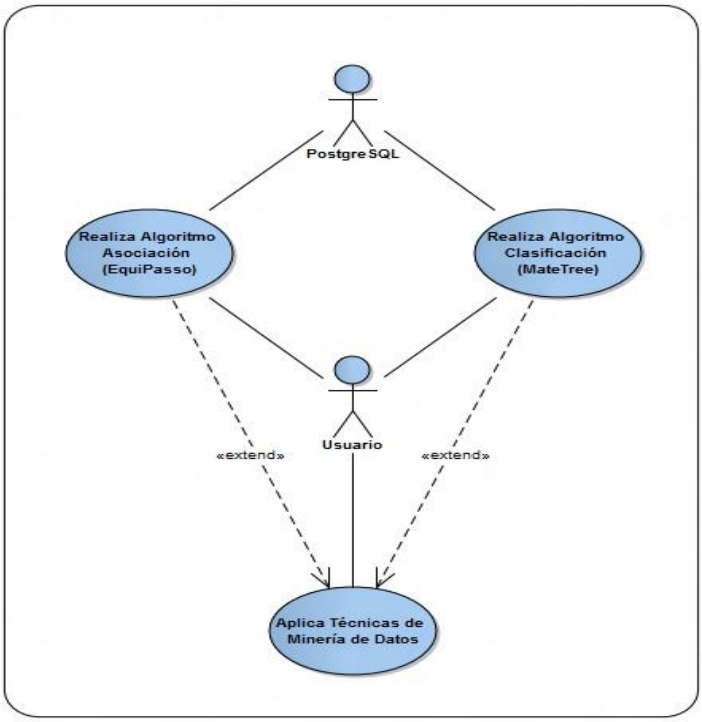

Fuente. Esta investigación.

4.1.3.15 Diagrama de Caso de Uso: Manipular scripts SQL. En la Figura 36, se describe el caso de uso que permite manipular los scripts SQL dentro de la aplicación.

Figura 36: Caso de Uso Manipular Scripts SQL

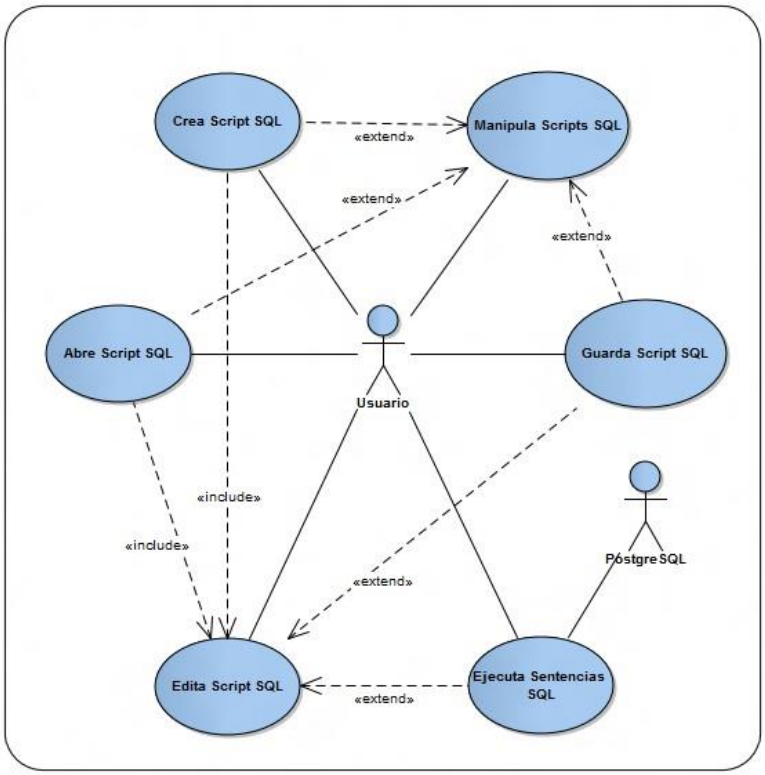

Fuente. Esta investigación.

4.2 DIAGRAMA DE SECUENCIA DEL SISTEMA.

En la Figura 37, se describe el diagrama de secuencia de Pg_KDD, ilustrando la interaccion entre el usuario con la herramienta gráfica, y este con el sistema de descubrimiento de conocimiento PostgresKDD.

Figura 37: Diagrama del Sistema

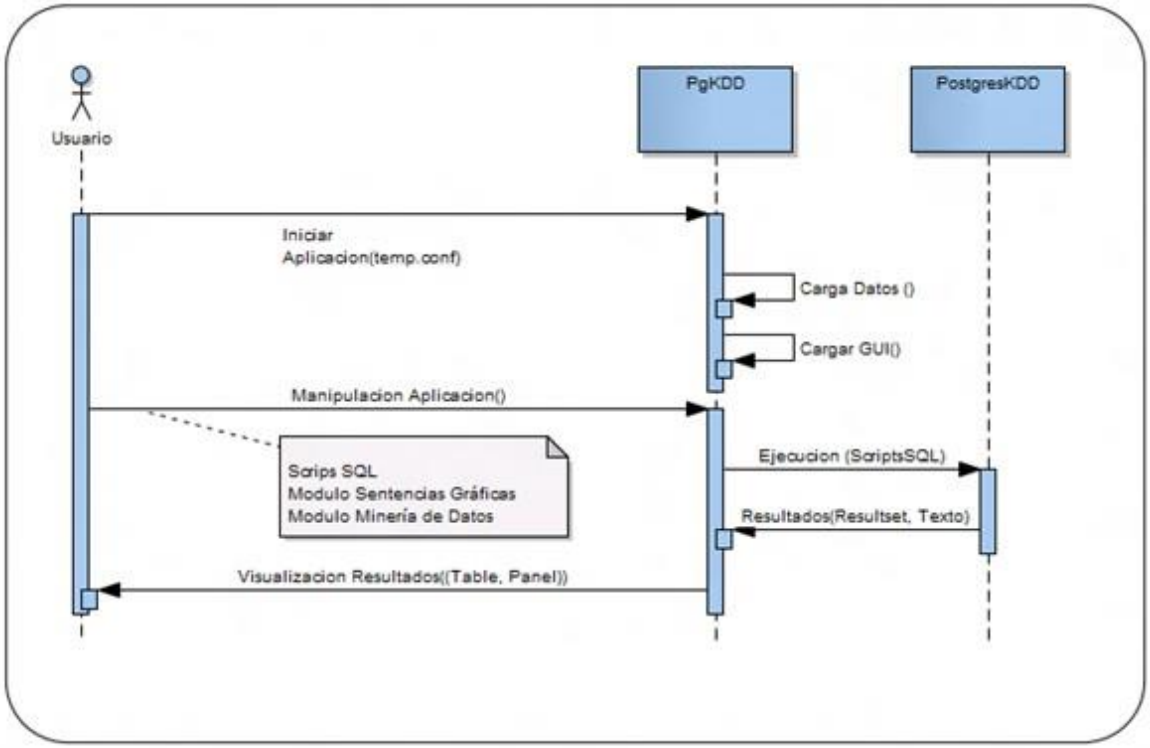

Fuente. Esta investigación.

4.3 DISEÑO UML

En esta etapa se define el diseño de la herramienta y se describen los diagramas de clase y los diagramas de paquetes.

4.3.1 Diagramas de clases. A continuación se describen los diagramas de clase del sistema.

4.3.1.1 Diagrama de Clases: Inicio de la Aplicación. En la Figura 38, se muestra el diagrama de clases del inicio de la aplicación Pg_KDD.

Figura 38: Diagrama de Clases Inicio de Aplicación

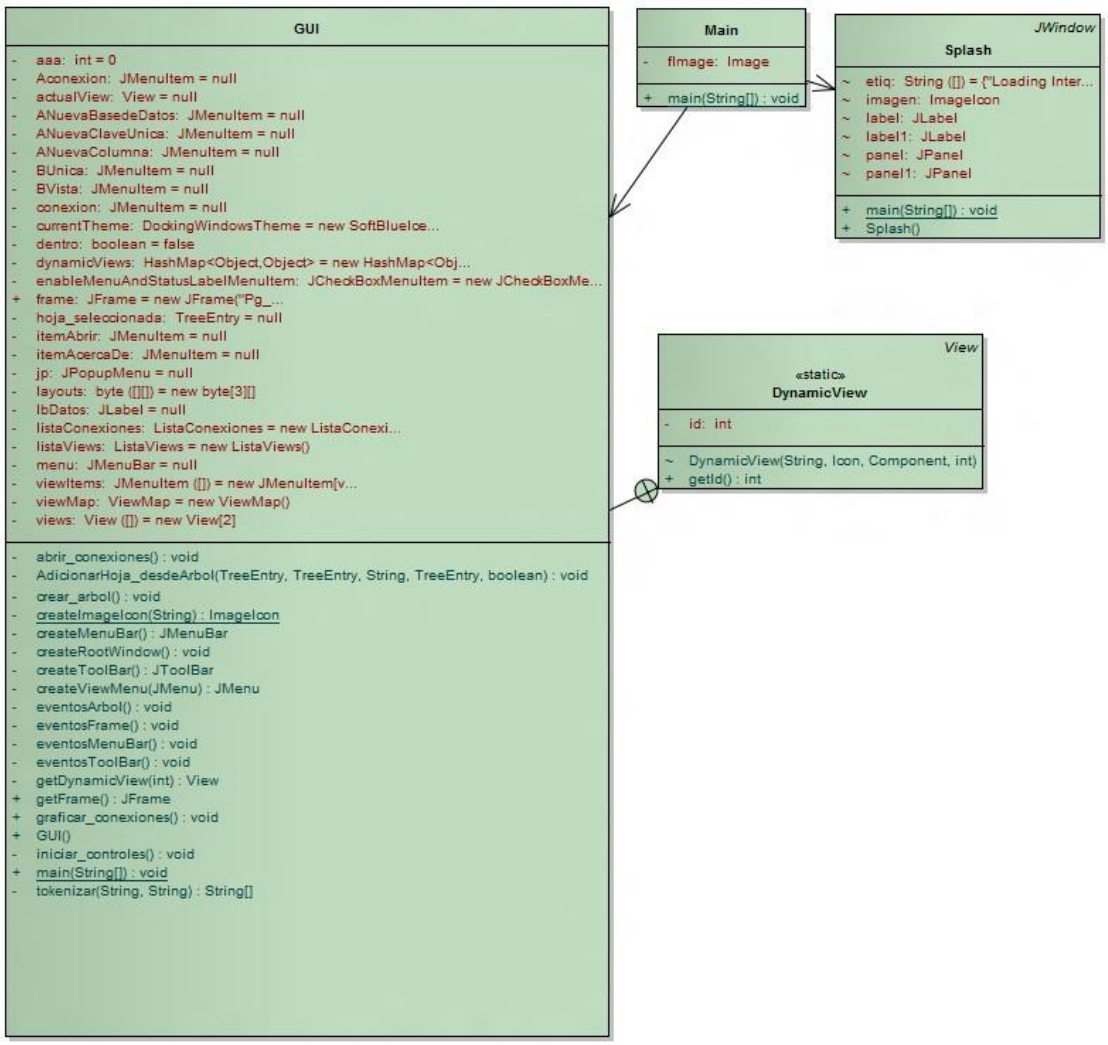

Fuente. Esta investigación.

4.3.1.2 Diagrama de Clases: Administración Visual Pg_KDD. En la Figura 39, se muestra el diagrama de clases que permite la administración visual de Pg_KDD.

Figura 39: Diagrama de Clases Adm. Visual de Pg_KDD

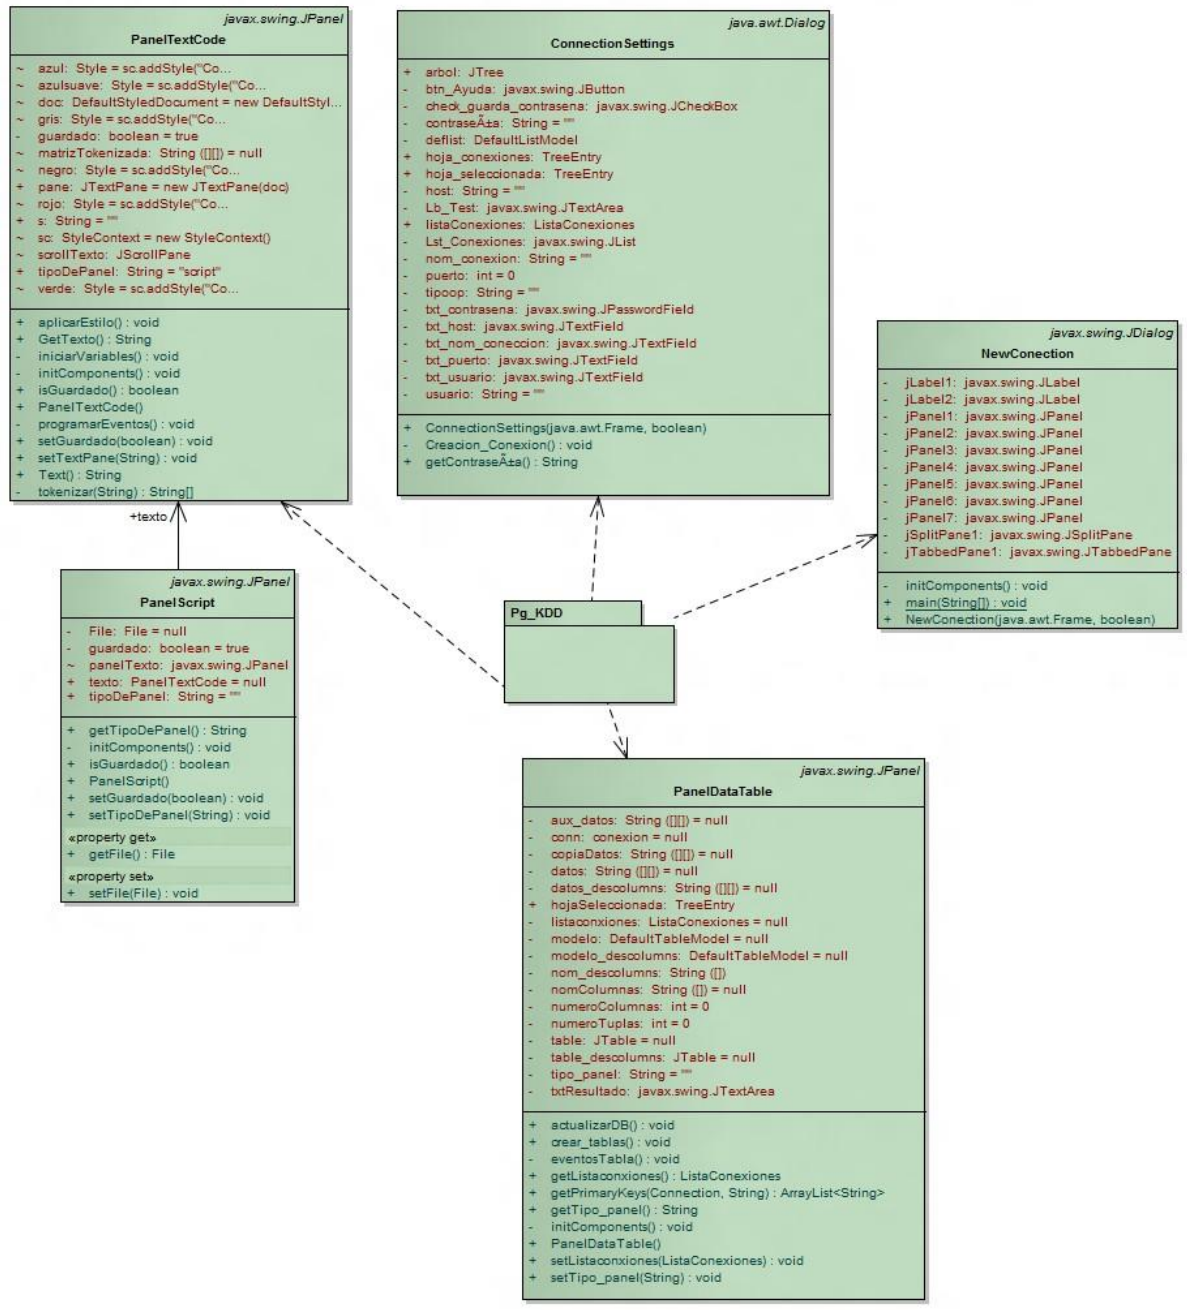

Fuente. Esta investigación.

4.3.1.3 Diagrama de Clases: Árbol de Elementos. En la Figura 40, se muestra el diagrama de clases que permite manejar los elementos del árbol de conexiones de Pg_KDD.

Figura 40: Diagrama de Clases Elementos del Árbol

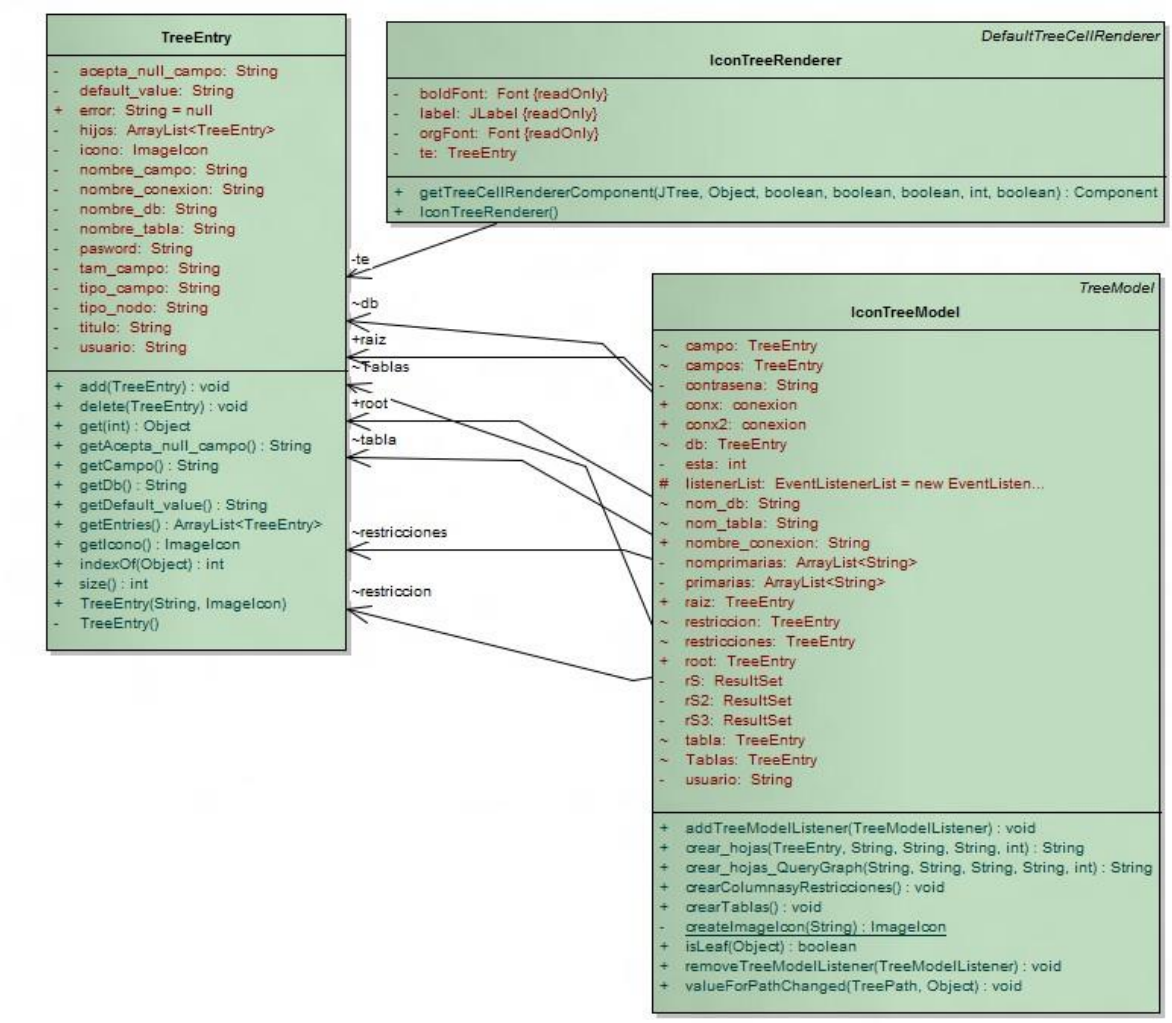

Fuente. Esta investigación.

4.3.1.4 Diagrama de Clases: Administración Lógica de las Sentencias Gráficas. En la Figura 41, se muestra el diagrama de clases que permite la administración lógica del submódulo sentencias gráficas de Pg_KDD.

Figura 41: Diagrama de Clases Adm. Logica Sentencias Gráficas

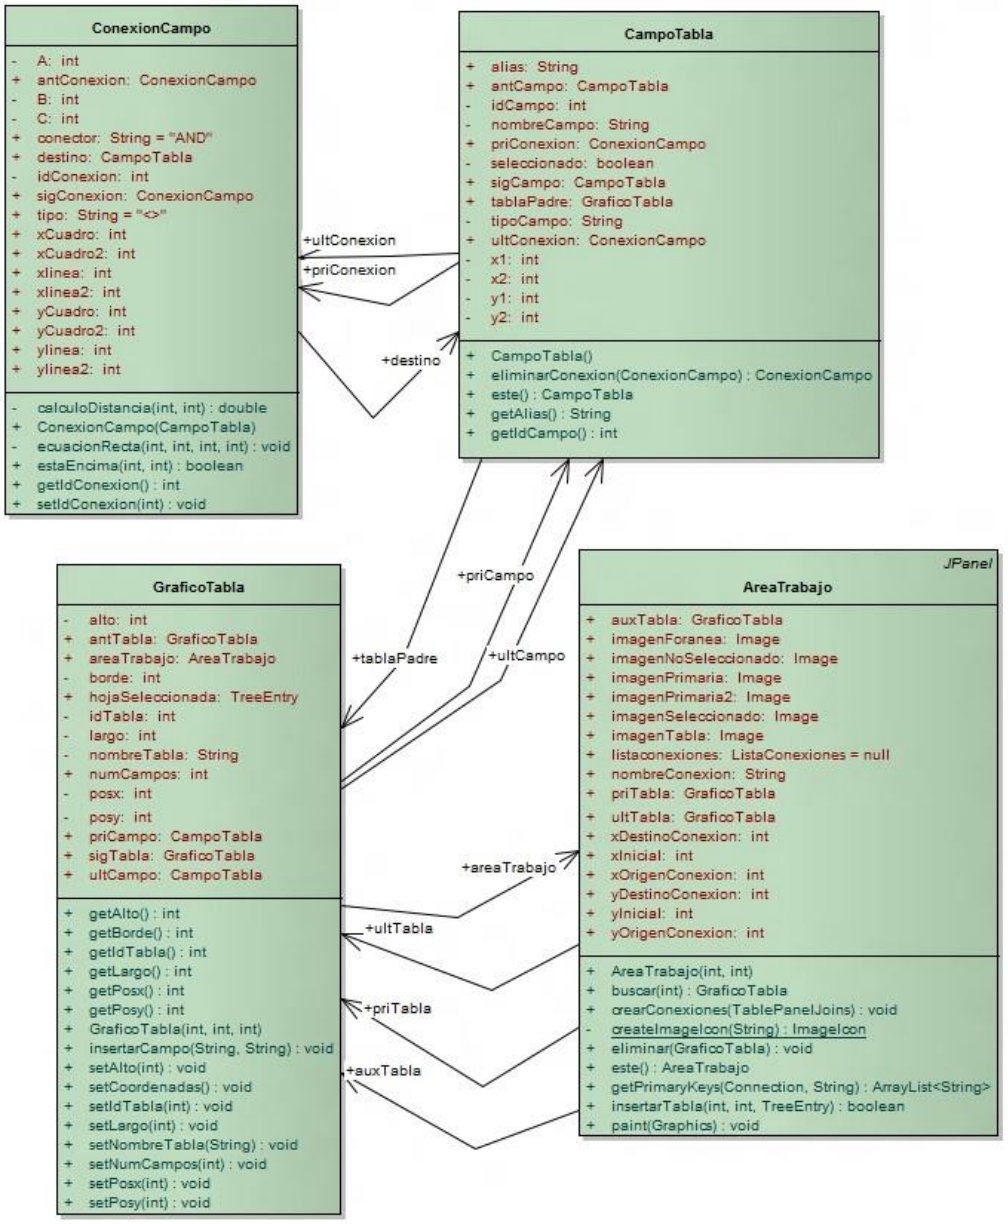

Fuente. Esta investigación.

4.3.1.5 Diagrama de Clases: Consultas Gráficas. En la Figura 42, se muestra el diagrama de clases que permite administrar gráficamente el submódulo sentencias gráficas de Pg_KDD.

Figura 42: Diagrama de Clases Consultas Gráficas

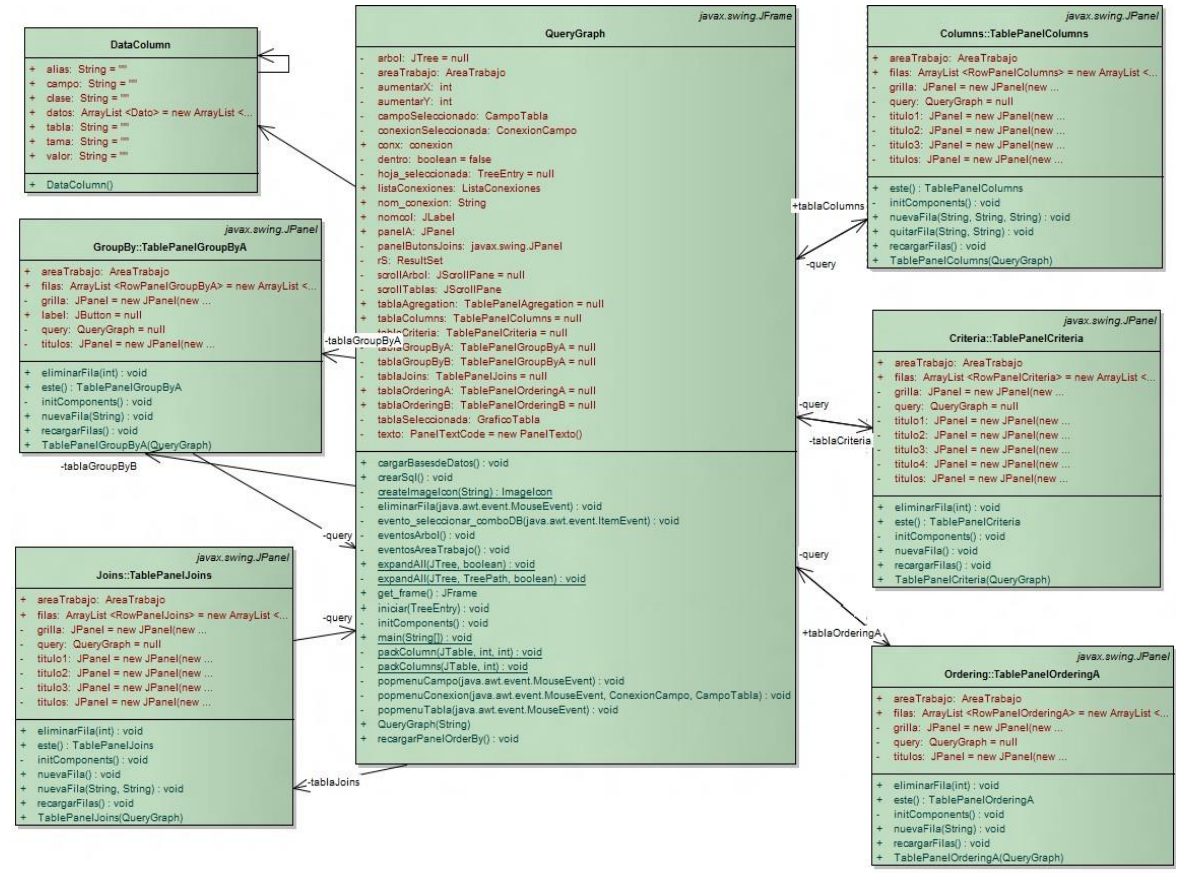

Fuente. Esta investigación.

4.3.1.6 Diagrama de Clases: Administración Lógica KDD. En la Figura 43, se muestra el diagrama de clases que permite la administración lógica del submódulo minería de datos de Pg_KDD.

Figura 43: Diagrama de Clases Adm. Logica KDD

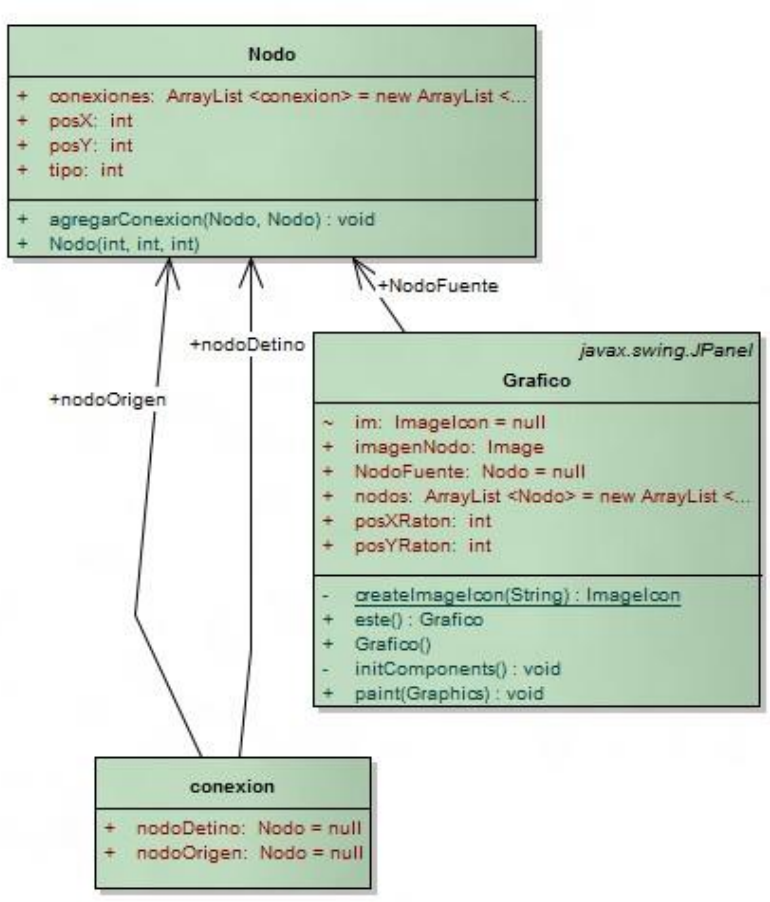

Fuente. Esta investigación.

4.3.1.7 Diagrama de Clases: Administracion de servicios gráficos KDD.

En la Figura 44, se muestra el diagrama de clases que permite la administración de los servicios gráficos del submódulo minería de datos de Pg_KDD.

Figura 44: Diagrama de Clases Adm. de Servicios KDD

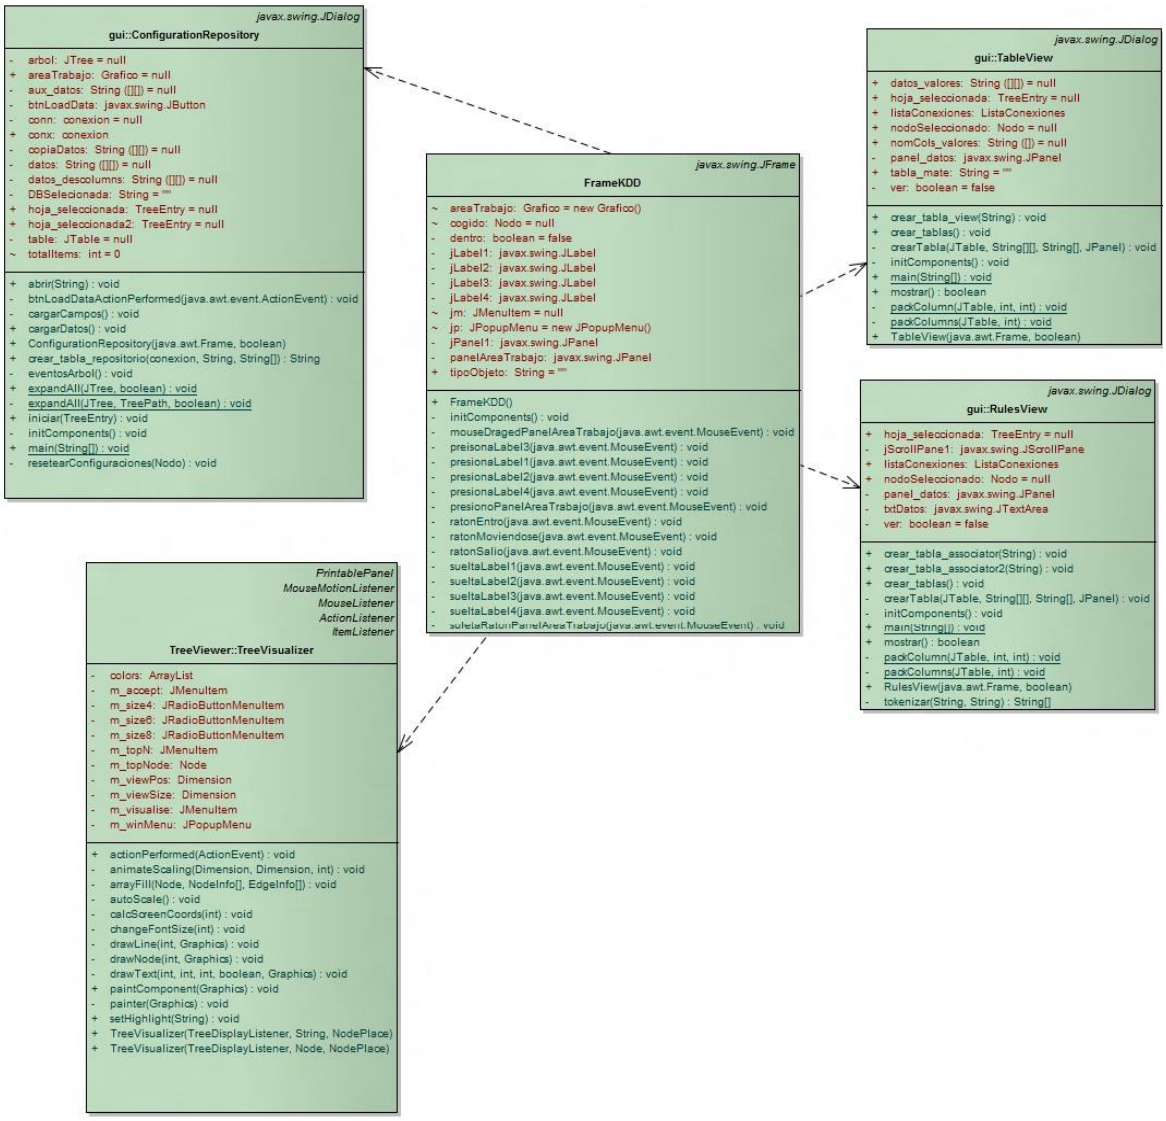

Fuente. Esta investigación.

4.3.1.8 Diagrama de Clases: Utilidades. En la Figura 45, se muestra el diagrama de clases que son de gran utilidad dentro de la herramienta Pg_KDD, para su uso general.

Figura 45: Diagrama de Clases Utilidades

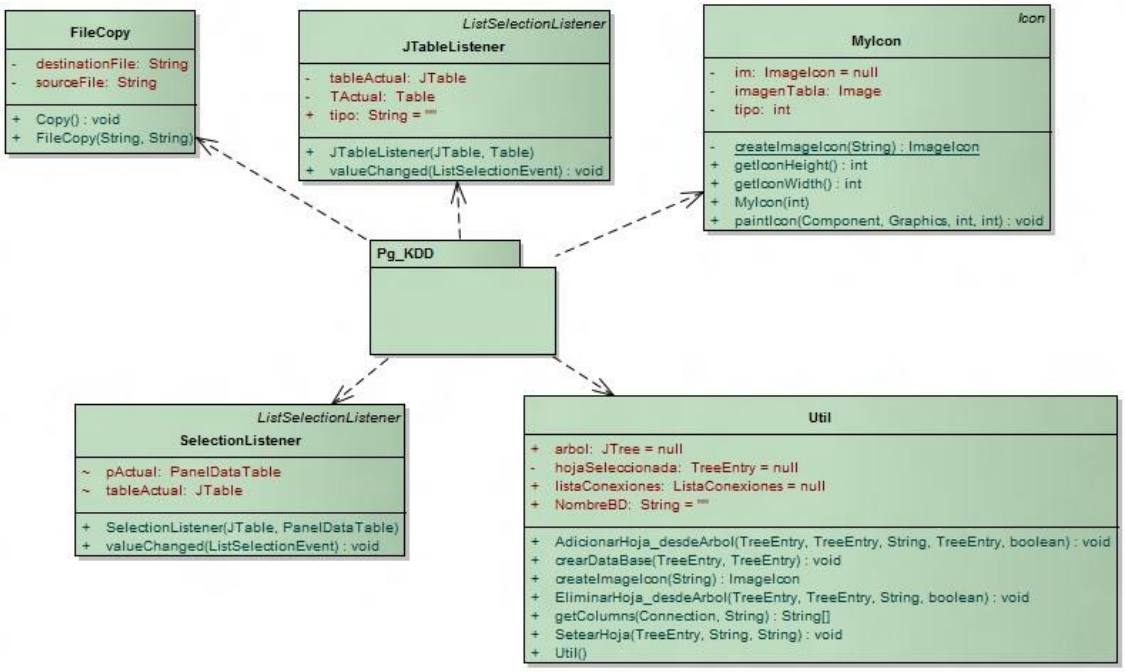

Fuente. Esta investigación.

4.3.2 Diagramas de paquetes. A continuación se describen los diagramas de paquetes.

4.3.2.1 Diagrama: Paquete Principal. En el paquete principal de la herramienta Pg_KDD, contiene los subpaquetes Class, Gui, GraphicSentences, KDD, Utilities y Media que serán descritos cada uno a continuación.

En la Figura 46, se muestra el diagrama paquetes general de la herramienta.

Figura 46: Diagrama de Paquetes Principal

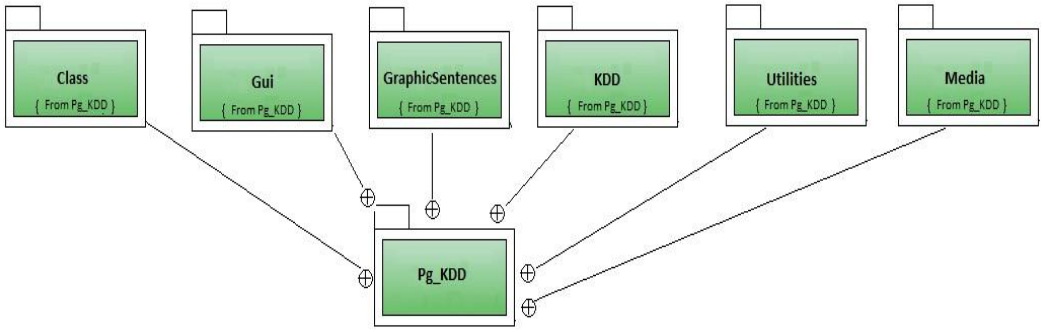

Fuente. Esta investigación.

4.3.2.2 Diagrama: Paquete Class. El subpaquete Class contiene los subpaquetes Connections, en el cual se encuentra las clases necesarias para el manejo de conexiones a la aplicación, MyTree, el cual contiene las clases necesarias para la administración del árbol de conexiones de la herramienta, Views, el cual contiene las clases necesarias para le manejo dinamico de los paneles de edición de archivos SQL.

En la Figura 47, se muestra el diagrama de paquetes que permite la administración lógica de Pg_KDD.

Figura 47: Diagrama de Paquetes Class

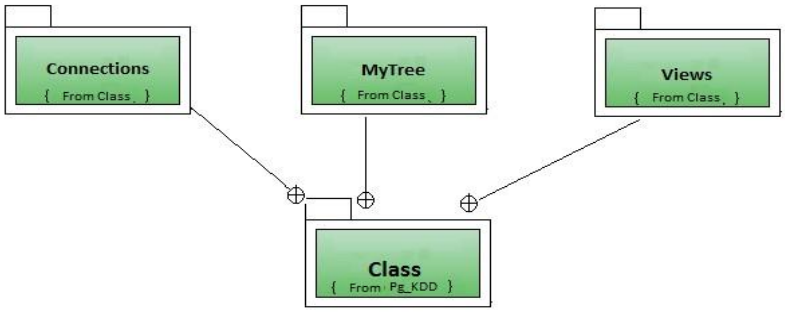

Fuente. Esta investigación.

4.3.2.3 Diagrama: Paquete Gui. El subpaquete Gui, contiene las clases que permiten al administración gráfica de la herramienta como son ventanas emergentes, paneles de visualización de datos, marcos de visualización y también contiene el subpaquete Sql Objects, el cual contiene las clases necesarias para la administración gráfica de cada componente de una bases de datos, como son sus tablas, columnas, referencias, entre otras.

En la Figura 48, se muestra el diagrama de paquetes que permite la administración gráfica de Pg_KDD.

Figura 48: Diagrama de Paquetes Gui

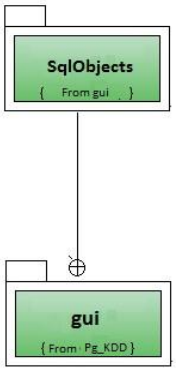

Fuente. Esta investigación.

4.3.2.4 Diagrama: Paquete GraphicSentences. El subpaquete GraphicSentences contiene los subpaquetes, Gui, para la administración gráfica y Class, para la administración lógica.

El subpaquete Gui, contiene los subpaquetes Agregation, el cual contiene las clases necesarias para la visualización y aplicación de el concepto de funciones de agregación dentro de una consulta SQL, Columns, el cual contiene las clases necesarias para la visualización y selección de los atributos de una tabla de una base de datos, Criteria, el cual contiene las clases necesarias para la visualización y aplicación del concepto de restricción dentro de una consulta SQL, GroupBy , el cual contiene las clases necesarias para la visualización y aplicación del concepto de agrupación dentro de una consulta SQL, Joins, el cual contiene las clases necesarias para la visualización y aplicación del concepto de relación entre tablas de una base de datos dentro de una consulta SQLy Ordering, el cual contiene las

clases necesarias para la visualización y aplicación del concepto de ordenamiento de atributos dentro de una consulta SQL.

En la Figura 49, se muestra el diagrama de paquetes que permite la administración general del submódulo de sentencias gráficas de Pg_KDD.

Figura 49: Diagrama de Paquetes GraphicSentences

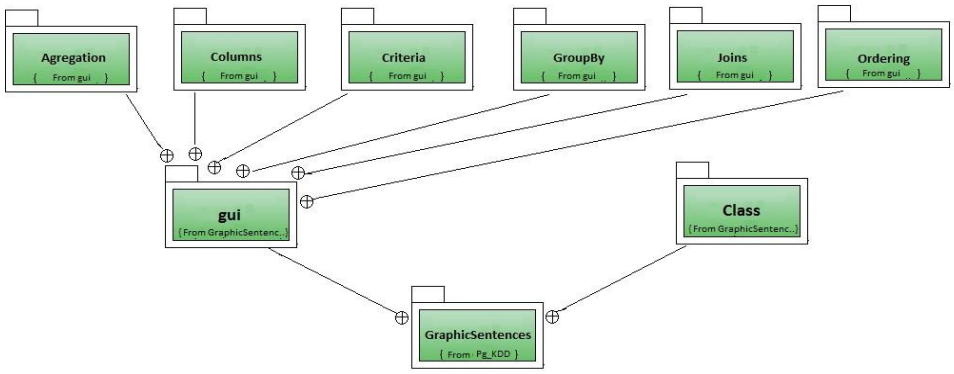

Fuente. Esta investigación.

4.3.2.5 Diagrama: Paquete KDD. El subpaquete KDD contiene los subpaquetes Class, el cual contiene las clases necesarias para la adminstracion lógica del submódulo de minería de datos y Gui, el cual contiene las clases necesarias para la administración gráfica del módulo de minería de datos, estos dos subpaquetes permiten la aplicación de las tareas de minería de datos para el descubrimiento de conocimiento con bases de datos dentro de la herramienta.

En la Figura 50, se muestra el diagrama de paquetes que permite la administración general del submódulo de minería de datos de Pg_KDD.

Figura 50: Diagrama de Paquetes KDD

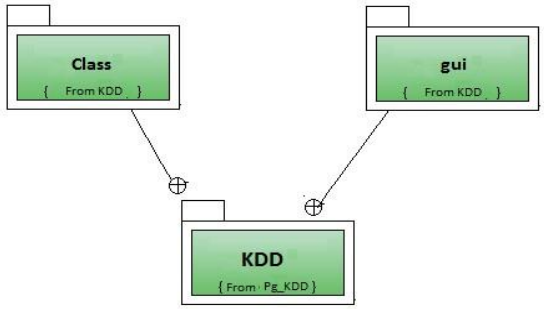

Fuente. Esta investigación.

4.3.2.6 Diagrama: Paquete Utilities. El subpaquete Utilities contiene los subpaquetes BDConnections, el cual contiene las clases necesarias para la conexión de la herramienta Pg_KDD con el sistema de descubrimiento de conociemiento PostgresKDD, este contiene las clases necesarias para la administración lógica del árbol de visualización de reglas de la tarea de clasificación para el submódulo KDD, además contiene el subpaquete Visualice, el cual contiene las clases necesarias para la administración gráfica de dicho árbol.

En la Figura 51, se muestra el diagrama de paquetes que permite la administración general del submódulo utilidades de Pg_KDD.

Figura 51: Diagrama de Paquetes Utilities

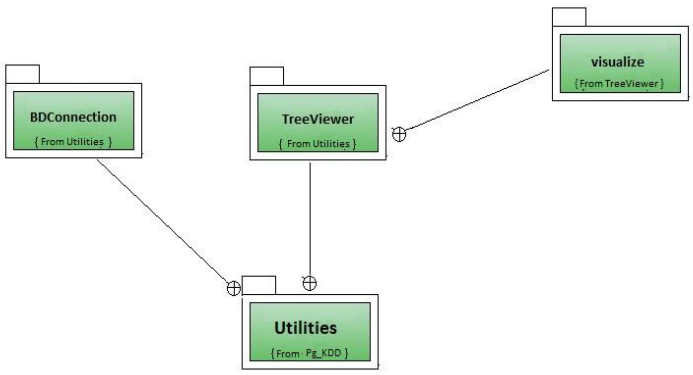

Fuente. Esta investigación.

4.4 ARQUITECTURA DE Pg_KDD

El sistema operativo sobre el cual se trabajó y se implementó Pg_KDD fue Linux Slackware 12.0. El lenguaje de programación que se utilizó para el desarrollo de la herramienta fue Java. Además se hizo uso de otras herramientas libres para el desarrollo de Pg_KDD: NetBeans 7 como IDE de desarrollo, VirtualBox para la creación de máquinas virtuales, Gimp para edición de imágenes, entre otras.

Para el proceso de descubrir conocimiento en bases de datos, Pg_KDD incluye los siguientes submódulos: conexión a SGBD, tareas de manipulación de datos y de administración gráfica de bases de datos, proceso gráfico de minería de datos, manejo de repositorios, manejo de algoritmos y visualización de resultados. Esta earquitectura se indica en la Figura 52.

Figura 52: Arquitectura Pg_KDD

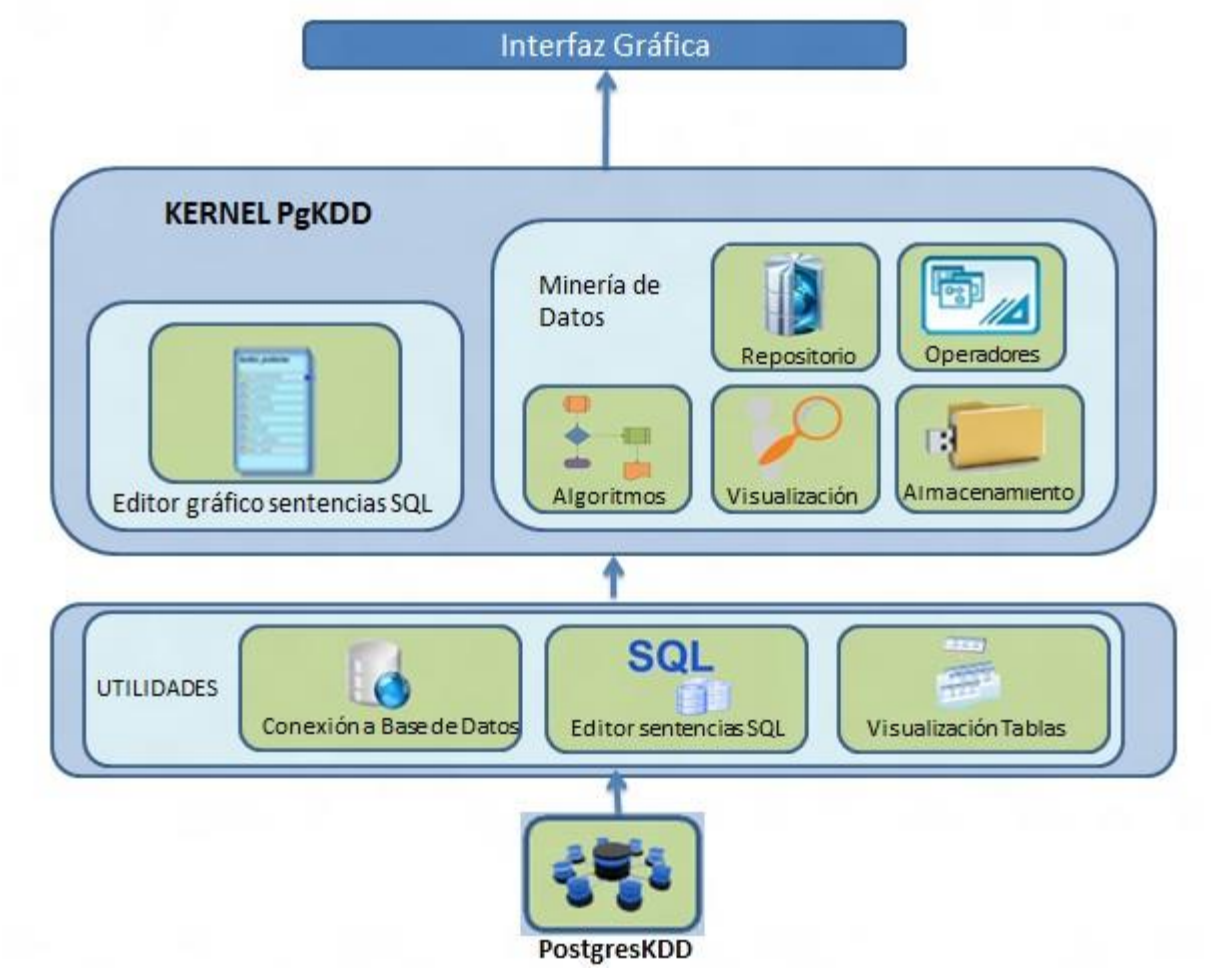

Fuente. Esta investigación.

4.4.1 Módulo de Interfaz Grafica. Este módulo da soporte visual a los módulos de utilidades, kernel Pg_KDD, y se encarga de brindar al usuario una medio agradable y facil de usar para la aplicacion de las tareas de descubrimiento de conocimiento con bases de datos que involucren la interaccion entre los diferentes componentes de la herramienta.

4.4.2 Módulo Gestión: KERNEL Pg_KDD. En este módulo reposan los paquetes primordiales para la ejecucion de las tareas de descubrimiento de

conocimiento. Este reúne los módulos de Utilidades, el módulo de Sentencias Gráficas y el módulo de Minería de Datos.

4.4.2.1 Módulo Sentencias Gráficas (Editor Grafico de Sentencias SQL).

Este módulo a través de una colección de clases y librerías permite la representación de resultados de operaciones de manipulación de datos y la administración de bases de datos de manera gráfica.

4.4.2.2 Módulo Minería De Datos.

En este módulo se gestiona de manera gráfica los operadores, primitivas y algoritmos implementados en PostgresKDD para las tareas de minería de datos, facilitando la toma de decisiones e incrementando la eficiencia del proceso KDD.

Dentro de este módulo del sistema existen los siguientes submódulos:

- **Repositorio:** Este submódulo permite manipular los repositorios utilizados para la apliacion de las tareas de descubrimiento de conocimiento con bases de datos.
- **Operadores:** Este submódulo permite la utilización de los operadores las tareas de asociación y clasificación del proceso de descubrimiento de conocimiento en bases de datos.
- **Algoritmos:** Este submódulo permite la aplicación de los algoritmos de asociación y clasificación del proceso de descubrimiento de conocimiento en bases de datos.
- **Visualización:** Este submódulo contiene las clases necesarias para construir y desplegar las estructuras que nos permitirán visualizar de manera gráfica y dinámica los resultados de la aplicacion de técnicas de minería.

  El objetivo de este módulo es permitir la interaccion y comunicación entre los diferentes componentes de los módulos involucrados, así como de proveer soporte en el caso de no ser necesaria la utilización de alguno de ellos, por ejemplo, cuando una conexión del repositorio se hace directamente hacia uno de los algoritmos de minería sin pasar por algún operador para la tarea.
- **Almacenamiento:** Este submódulo permite el almacenamiento de las tareas de asociación o clasificación del proceso de descubrimiento de conocimiento con bases de datos.

4.4.3 Módulo Utilidades. En este módulo se mantiene una colección de clases principales y librerías que son utilizadas por otras clases a lo largo de la aplicación para el desarrollo de tareas comunes como, conexión con el sistema de descubrimiento de conocimiento postresKDD, manipulación de Scripts SQL y visualización, descritos a continuación:

- **Conexión a Bases de Datos:** Este submódulo es el encargado de la conexión a una fuente de datos. El objetivo de este módulo es proveer al usuario de herramientas amigables para la selección y construcción de una vista o conjunto de datos minables.
- **Editor Sentencias SQL:** Este submódulo es el encargado de la administración de los scripts SQL. El objetivo de este módulo es proveer al usuario de herramientas amigables para la selección, edición y ejecución de scripts SQL que estén dentro de su disco duro o simplemente la creación de uno nuevo.
- **Visualización de Tablas:** Este submódulo contiene las clases necesarias para construir y desplegar las estructuras que nos permitirán visualizar de manera gráfica y dinámica el contenido de las tablas existentes dentro de una base de datos.

4.5 ARQUITECTURA DE PAQUETES Y CLASES

A continuación se describen de manera general la estructura de paquetes de Pg_KDD y las clases que pertenecen a cada paquete, dentro de ellas se describen los métodos implementados.

4.5.1 Utilidades

Pg_KDD

Este es el paquete principal del proyecto, contiene la siguiente clase:

Clase GUI: Esta es la Clase principal del aplicativo que despliega la GUI principal**,** sus métodos son:

- **GUI ()**este es el constructor de la clase y se encarga de instanciar todo el fríame de la GUI principal del proyecto Pg_KDD
- **iniciar_controles ()** este método consiste en iniciar todos los controles de la interfaz principal.
- **crearArbol ()** este método instancia el árbol de conexión creando un evento para diferenciar los pop menús que se ejecutaran en cada tipo de hoja del árbol y así llamando a los pop menús de cada una de ellas.
- **AdiocionarHoja_ desdeArbol ()** este método es un método recursivo y adiciona una hoja creada desde los pop menús generados para cada tipo de hoja del árbol de conexión.
- **Abrir_conexiones ()** este método se ejecuta al iniciar el aplicativo y carga todas las conexiones guardadas previamente en un archivo plano.
- **gráficar_conexiones ()** este método gráfica en el árbol de conexiones, las conexiones guardadas en el archivo plano nombrado anterior mente llamando al método crear_hojas de la clase IconTreeModel del Paquete Class.MyTree, si ocurre algún percance en el servicio de PostgreSQL instalado en el sistema y o ahí algún error en una conexión guardada este generara el TreeEntry pero con un icono de ERROR de carga.
- **createToolBar ()** este método crea la barra de herramientas, instanciando cada uno de sus botones asociados a ella.
- **createMenuBar ()** este método crea la Barra de Menús de la cabecera del aplicativo, instanciando cada uno de sus Menús y Menú Ítems asociados a ella.
- **eventosToolBar ()** este método trabaja todos los eventos relacionados con todos los botones asociados al ToolBar.
- **eventosMenuBar ()** este método trabaja todos los eventos relacionados con todos los menús asociados al Menú Bar, dentro de él se encuentra la creación de los “Views”, así llamados a las vistas que están contenidas en el TabView estos términos son generales del manejo de la librería Infonode que ayuda a mejorar la interfaz de usuario.
- **eventosFrame ()** este método trabaja todo lo relacionado con los eventos del GUI principal, cuando se cierra el FRAME: sobrescribe un archivo plano guardando todas la conexiones existentes en el aplicativo previamente creadas, al igual que con el mismo evento relacionado, guarda cada uno de los “Views”, de tipo “SQL Script” y “Archivo Script”, en un archivo *.SQL respectivamente, que en un caso puede ya haber sido creado al instanciar un “View” y haber accionado el botón “guardar” del ToolBar o el Ítem “Guardar”

del Menú File del Menú Bar en donde cambia un estado de “Guardado”, del Panel contenido en el View, a true.

- **eventosArbol ()** este método trabaja todo lo relacionado con los eventos referentes a la selección de cada tipo de hoja del Árbol de conexión, en la ejecución de estos eventos se podrá visualizar las siguientes funciones:

  - Actualización el estado de habilitación o de estructura de algunos objetos tanto del Menú Bar como de la barra de herramientas (ToolBar).
  - Instanciar las interfaces de creación para cada tipo de hoja seleccionada, Tablas, Bases de Datos, Restricciones etc.
  - Visualizar el “View Datos” cuyo panel Contenido es de tipo “Panel Datos”, este será visualizado solo para las hojas seleccionadas de tipo “tabla” o “campo”, este “View Datos”, no se instanciara varias veces solo se actualiza su panel contenido dependiendo de la hoja tipo “tabla” seleccionada del Árbol de conexión.

En la parte final de la clase “GUI” se encuentran los métodos utilizados de la librería INFONODE para la manipulación y automatización de la interfaz Gráfica.

Clase SplashScreen: Esta clase es la que instancia la interfaz de bienvenida de la aplicación Pg_KDD.

Clase BarraProgreso: Esta clase es la muestra una barra de progreso al recargar el árbol de conecciones.

Class

Este paquete hace referencia a la parte lógica del aplicativo en cuanto a manejo del árbol de conexión y manejo de conexiones de la aplicación, contiene los siguientes paquetes:

MyTree

Sus clases son:

Clase TreeEntry: Esta clase describe un nuevo tipo de dato, el cual va a ser objeto de relación para cada una de las hojas del árbol de conexión.

Sus métodos son acordes a Set () y Get () para cada uno de sus atributos, y también referentes a inserción, eliminación u Obtención de nodos hijo para un objeto de este tipo, entre otros**.**

Clase IconTreeRenderer: Esta clase tiene como función colocarle, a un TreeEntry u hoja del árbol de conexión, un color diferente para su título cuando esta es seleccionada, su metodo principal es.

- **getTreeCellRendererComponent ()** Este método tiene como función colocar el color de título diferente al TreeEntry cuando es seleccionada.

Clase IconTreeModel: Esta clase se encarga de crear todo el modelo a la instancia de un JTree de Java, en el caso del aplicativo se consume esta clase en las clases GUI y QueryGraph, sus métodos son:

- **IconTreeModel ()** es el constructor de la clase y es vital a la hora de instanciar el modelo del árbol ya que crea la primera hoja del árbol de conexión.
- **crear_hojas ()** este método se encarga de crear todo el modelo del árbol de conexión de la clase “GUI” de acuerdo a la estructura de los objetos que contenga el usuario que crea la nueva conexión, en este caso serán las todas bases de datos relacionadas a él con sus respectivos objetos que se relacionan con cada una de ellas (Base de Datos).
- **crear_hojas_QueryGraph ()** este método crea el modelo del árbol instanciado para la clase “QueryGraph”, en donde crea como hoja principal el nombre de la bases de datos seleccionada en un JComboBox y con base a esta selección genera hojas relacionadas a las tablas de esta base de datos.
- **getRoot ()** este método retorna el TreeEntry raíz del árbol.
- **getChild ()** este método retorna un TreeEntry hijo de un TreeEntry en específico el cual se lo manda por parámetro y un índex que se refiere a una posición en la lista de los TreeEntrys hijos.
- **getChildCount ()** retorna el número de hijos que contiene un TreeEntry.
- **isLeaf ()** este método retorna un booleano verificando como verdadero o falso si el TreeEntry contiene o no hijos.
- **getIndexOfChild ()** este método retorna la posición en que se encuentra un TreeEntry hijo con respecto a un TreeEntry padre.

- **addTreeModelListener ()** este método adiciona un Escuchador al modelo del de esta clase.
- **removeTreeModelListener ()** este método Elimina el Escuchador adicionado al modelo de esta clase.

Connections

Sus clases son:

Clase ConexionArbol Esta clase describe el objeto conexión que será instanciado cada vez que se genere una nueva conexión al aplicativo.

sus métodos son acordes a Set () y Get () para cada uno de sus atributos, nombre, usuario, contraseña, host y puerto que representan generalmente a una conexión.

Clase ListaConexiones esta clase maneja una lista de objetos tipo ConexionArbol, en donde se gestiona las conexiones del aplicativo.

Sus métodos radican en la administración de las conexiones, Adición, Eliminación y Búsqueda.

Views

Clase DatosView: Esta clase describe el objeto tipo View dinámico que se instanciará cada vez que se cree un “KDD Editor” o un Archivo de edición, la diferencia entre estos dos tipos de instancia es el atributo “tipo panel” en el panel contenido “Panel Script”.

Clase ListaViews: Esta clase administra una lista de objetos tipo DatosView, en la cual se gestiona las Views dinámicas instanciadas.

Sus métodos radican en la administración de los Views del área de gestión de pestañas o TabView del aplicativo con la funcionalidad de adición, eliminación y búsqueda.

4.5.2 Kernel Pg_KDD: Sentencias gráficas

GraphicSentences

Este paquete hace referencia a la administración de las sentencias gráficas que están directamente relacionadas con el GUI de la aplicación principal, contiene los siguientes paquetes:

Class

Este paquete administra la parte lógica o de razonamiento de las sentencias gráficas, contiene las siguientes clases:

Clase Área de Trabajo: Esta clase administra todos los elementos gráficos incluidos en ella como tablas, campos y conexiones, la lógica es sencilla de esta clase, contiene una lista de tablas inicializadas a *null* en su comienzo, y la tabla contiene una lista de campos, y estos últimos tienen una lista de conexiones, sus métodos son:

- **AreaTrabajo ():** Este método es el constructor de la clase y se encarga de inicializar el área de trabajo con parámetros de ancho y alto.
- **Paint ():** Este método se encarga de pintar todos elementos gráficos existentes en el área de trabajo, como tablas con sus respectivos campos y conexiones.
- **insertarTabla ():** Este método se encarga de agregar una nueva tabla al área de trabajo, la cual hace una sentencia SQL extrayendo el numero de campos y su nombre en un Resulset los cuales se le agregaran a la lista de la tabla creada, y a estos últimos les agrega tipo de llave si es foránea o primaria para el momento de su dibujo se aplique un icono correspondiente.
- **Buscar ():** Este método tiene como función la búsqueda de una tabla en las existentes dentro de las lista de tablas del área de trabajo.
- **Eliminar ():** Este método tiene como función eliminar una tabla del área de trabajo, internamente elimina también las conexiones que sean parte de esta tabla.

GraficoTabla: Esta clase describe el objeto tipo tabla del área de trabajo, sus métodos son los siguientes:

- **insertarCampo ():** Este método tiene como función insertar un campo a la tabla.
- **setCoordenadas ():** Este método se encarga de setear las coordenadas a la tabla dentro del área de trabajo, estas coordenadas son tomadas de la posición final del mouse.

Clase CampoTabla: Esta clase describe el objeto tipo campo de una Tabla del área de trabajo, sus métodos son los siguientes:

- **EliminarConexion ():** Este método tiene como función eliminar una conexión del campo, recorriendo los campos que la contengan.
- **insertarConexion ():** Este método tiene como función insertar una conexión al campo seleccionado.

Clase ConexionCampo: Esta clase describe el objeto tipo conexión que está relacionado con un campo en específico, sus métodos son los siguientes:

- **ecuacionRecta ():** Este método se encarga de calcular la ecuación de la recta tomando los puntos, inicial y final de la conexión campo a campo de su respectiva tabla.
- **calculoDistancia ():** Este método se encarga del cálculo de la distancia entre dos puntos.
- **estaEncima ():** Este método se encarga de averiguar, si el mouse al accionar su evento de clic sobre el área de trabajo, se encuentra a una mínima distancia en donde se encuentra una conexión dibujada.

GUI

Este paquete Administra la parte gráfica de las sentencias gráficas, contiene las siguientes clases:

Clase QueryGraph: Esta clase se encarga de administrar todo el fríame gráfico correspondiente a las sentencias gráficas, sus métodos son los siguientes:

- **Iniciar ():** Este método se encarga de inicializar los controles utilizados para el control interno de las sentencias gráficas.
- **cargarBasesdeDatos ():** Este método se encarga de cargar todas las bases de datos al JComboBox de la interfaz del usuario que instancio

QueryGraph, este usuario fue obtenido de la hoja seleccionada de del árbol de conexión del fríame principal.

- **eventosArbol ():** Este método se encarga de los eventos realizados en el árbol que contiene las tablas de la base de datos seleccionada.
- **eventosAreaTrabajo ():** Este método se encarga de los eventos realizados en el área de trabajo correspondiente a llamada de los pop menús de cada objeto tabla, campo y conexión.
- **realizarDibujo ():** Este método se encarga de dibujar las conexiones gráficas provenientes de las conexiones manuales del **Panel de Administración manual de las sentencias.**
- **crearSql ():** Este método se encarga de la creación del Código SQL que se visualiza en el "SQL Statement", este es llamado cada vez que se ejecuta un evento de realización de sentencia SQL.

Este paquete a su vez contiene los siquientes paquetes:

Joins

Este paquete describe el manejo de uniones o relaciones entre las tablas de una base de datos, contiene las siguientes clases:
Clase RowPanelJoins: Esta clase contiene las características gráficas del objeto que representa una fila en una tabla del panel Joins, el metodo más representativo de la clase es:

- **programarEventos ():** En este método se programa todos los eventos de los controles que contiene el panel de creación de JOINS manuales.

Clase TablePanelJoins: Esta clase administra las filas o los objetos tipo RowPanleJoins, contiene un metodo clave para la adicion de nuevas filas a la tabla de uniones:

- **nuevaFila ():** Este método se encarga de agregar Objetos tipo RowPanleJoins a la TablePanelJoins asignandole su posición individual en memoria.

Columns

Este paquete describe el manejo las columnas incluidas dentro de la relación gráfica.

Criterio

Este paquete describe el manejo de las restricciones que se realizan en la consulta SQL, trayendo consigo la utilización de los operadores OR o AND según sea el caso.

GroupBy

Este paquete describe el concepto de agrupamiento dentro de una sentencia SQL, utilizando controles gráficos para su mejor entendimiento.

Ordening

Este paquete describe el concepto de ordenamiento dentro de una sentencia SQL, utilizando controles gráficos para su mejor entendimiento.

Agregation

Este paquete describe el concepto de agregación en donde se utiliza a las funciones agregadas y se las restringe, con el fin de ayudar en la mejora de la sentencia SQL que se esta realizando.

4.5.3 Kernel Pg_KDD: Módulo Minería de Datos

KDD

Este paquete hace referencia a la administración del módulo de minería de datos, en el cual se maneja tanto la parte gráfica como la parte lógica, contiene los siguientes paquetes:

CLASS

Este paquete describe el manejo de la parte lógica del módulo de minería de datos, contiene las siguientes clases:

Clase Grafico: Esta clase Administra todos los elementos gráficos incluidos en ella como son los nodos y las conexiones entre ellos, la lógica es sencilla de esta

clase, contiene una lista de nodos inicializadas a null en su comienzo, cada nodo contiene una lista de conexiones, sus métodos son:

- **Paint ():** Este método se encarga de pintar todos elementos gráficos existentes en el área de trabajo, como como son los nodos con sus respectivas conexiones.
- **EliminarNodo ():** Este método tiene como función eliminar un nodo del área de trabajo (gráfico), internamente elimina también las conexiones que sean parte de él.

Clase Nodo: Esta Clase describe el objeto tipo nodo del área de trabajo, sus métodos son los siguientes:

- **Nodo ():** Este método es el constructor de la clase y se encarga de inicializar el nuevo nodo con parámetros de x,y como coordenadas de su posición en dentro de el área.
- **agregarConexion ():** Este método se encarga de agregar una nueva conexión al nodo seleccionado, determinando el nodo destino con quien se va conectar.
- **EliminarConexion ():** Este método tiene como función eliminar la conexión del nodo seleccionado.

Clase conexionKDD: Esta clase describe el objeto tipo conexión que está relacionado con un nodo en específico, sus métodos son los siguientes:

- **ecuacionRecta ():** Este método se encarga de calcular la ecuación de la recta tomando los puntos, inicial y final de la conexión nodo a nodo de su respectiva tabla.
- **calculoDistancia ():** Este método se encarga del cálculo de la distancia entre dos puntos.
- **estaEncima ():** Este método se encarga de averiguar, si el mouse al accionar su evento de clic sobre el área de trabajo (gráfico), se encuentra a una mínima distancia en donde se encuentra una conexión dibujada.

Clase TipoNodo: Esta clase se encarga de declarar el tipo de nodo que va a ser agregado al área de trabajo (gráfico), ejemplo: REPOSITORIO,ASSOCIATOR, ASSOROW, EQUIPASO, etc, esta clase no contiene métodos solo un atributo de asignación.

Clase EstadoNodo: Esta clase se encarga de declarar el estado de nodo que va a ser agregado al área de trabajo, ejemplo (gráfico): CREADO,CONFIGURADO, CORRIENDO, etc, esta clase no contiene métodos solo un atributo de asignación.

GUI

Este paquete describe el manejo de la parte gráfica del módulo de minería de datos, contiene las siguientes clases:

Clase FrameKDD: Esta clase se encarga de administrar todo el fríame gráfico correspondiente a la parte de minería de datos, sus métodos principales son los siguientes:

- **abrir():** Este método se encarga de abrir un archivo cuya extención es *.KDDg y cargar una previa configuración que el usuario haya guardado de los enlaces entre nodos.
- **guardar():** Este método se encarga de guardar un archivo cuya extención es *.KDDg en donde se encuentre la actual configuración de enlaces entre nodos en el área de trabajo.
- **crearPopmenu():** Este método se encarga de crear los popmenús para cada uno de los nodos.
- **verificarConexiones():** Este método se encarga de verificar que las conexiones que dese hacer el usuario sean las correctas, mostrando con mensajes de error emergentes las conexiónes incorrectas.

Clase ConfigurationRepository: Esta clase se encarga de configurar el repositorio seleccionado por el usuario, el cual será utilizado a lo largo del proceso KDD.

- **Iniciar():**Este método se encarga de inicializar los controles utilizados para el control interno de las sentencias gráficas.
- **cargarDatos():** Este método se encarga de cargar los datos de la tabla repositorio a la tabla de visualización.
- **cargarCampos():** Este método se encarga de cargar los campos de la tabla repositorio a la tabla de visualización.

- **crear_tabla_repositorio():** Este método se encarga de cargar de crear la tabla repositorio_nomtabla tomando las columnas seleccionadas por el usuario, generando un script SQL y ejecutándolo para su creación.

Clase ConfigurationAssociator: Esta clase se encarga de configurar el operador associator el cual será utilizado a lo largo del algoritmo de asociación.

- **btnSaveActionPerformed():** Este es un metodo que ejecuta el evento de un botón el cual toma los valores de los controles gráficos y genera un script SQL ralacionado con la sintaxis del operador Associator.

Clase ConfigurationAssorow: Esta clase se encarga de configurar el operador assorow el cual será utilizado a lo largo del algoritmo de asociación.

- **btnSaveActionPerformed():** Este es un metodo que ejecuta el evento de un botón el cual toma los valores de los controles gráficos y genera un script SQL ralacionado con la sintaxis del operador Assorow.

Clase ConfigurationEquipaso: Esta clase se encarga de configurar el operador equipaso el cual será utilizado a lo largo del algoritmo de asociación.

- **btnSaveActionPerformed():** Este es un metodo que ejecuta el evento de un botón el cual toma los valores de los controles gráficos y genera un script SQL ralacionado con la sintaxis del operador Equipaso.

Clase ConfigurationAsociatorRules: Esta clase se encarga de configurar los parámetros de la función describe_associator_rules la cual será utilizada para la obtención de las reglas de asociación.

- **btnSaveActionPerformed():** Este es un metodo que ejecuta el evento de un botón el cual toma los valores de los controles gráficos y genera un script SQL ralacionado con la sintaxis de la función definida por el usuario describe_associator_rules.

Clase ConfigurationMate: Esta clase se encarga de configurar el operador Mate el cual será utilizado a lo largo del algoritmo de clasificación.

- **btnSaveActionPerformed():** Este es un metodo que ejecuta el evento de un botón el cual toma los valores de los controles gráficos y genera un script SQL ralacionado con la sintaxis del operador Mate.

Clase TableView: Esta clase se encarga de visualizar el resultado que genera la utilización de los operadores o funciones definidas por usuario.

- **crear_tablas():** Este método se encarga de seleccionar que sentencia sql debe tomar según sea el nodo conectado a él, ya sea operador o función definida por el usuario.
- **crear_tabla_view():** Este método se encarga de cargar los datos dependiendo del Script SQL que contenga el nodo conectado y crear un nuevo objeto JTable para su posterior visualización.
- **crearTabla():**Este método se encarga modificar el modelo del objeto JTable para una mejor visualización.

Clase RulesView: Esta clase se encarga de visualizar las reglas generadas por la utilización de las funciones definidas por usuario, dependiendo si son del proceso de asociación o de clasificación.

- **crear_tablas():** Este método se encarga de seleccionar que sentencia sql debe tomar según sea el nodo conectado a él, y dependiendo de que función definida por el usuario (describe_associator_rules para asociación ó arm_rules para clasificación) se visualizara la relación de interpretación y/o las reglas obtenidas de ella.
- **crear_tabla_associator():** Este método se encarga de cargar los datos dependiendo del Script SQL que contenga el nodo conectado y crear un nuevo objeto JTable y/o un JTextArea describiendo las reglas.
- **crearTabla():** Este método se encarga de modificar el modelo de el objeto JTable para una mejor visualización.

4.5.4 Módulo Interfaz Grafica

GUI

Este paquete hace referencia al manejo de gráfico de la aplicación aquí se encuentran todas las interfaces gráficas que hacen parte de Pg_KDD, este tiene las siguientes Clases contenidas:

Clase Connection_settings: Esta clase es una interfaz gráfica que tiene como función la creación de una nueva conexión que se graficará en el modelo del árbol de conexiones, sus métodos son:

- **Iniciar():** Este método tiene como función cargar todas las conexiones existentes a un JList de Java, nótese que la ejecución de este método se hace internamente.
- **CloseDialog():** Este evento tiene como función cerrar la Ventana y liberarla en memoria aplicando el método nativo de Java dispose ().
- **setVisible():** Aquí se aplica una sobrescritura al método básico setVisible de la clase fríame de Java, la función de este método es refrescar el panel que contiene los diversos objetos funcionales de la ventana.
- **btn_TestActionPerformed():** Este método es la ejecución del evento del botón Test de la ventana cuya función es testear la conexión con PostgreSQL con los elementos capturados de la interfaz correspondientes al nombre de usuario y contraseña.
- **btn_GuardarActionPerformed():** Este método es la ejecución del evento del botón Guardar de la ventana cuya función es guardar la conexión digitada por el usuario en la lista de visualización, validando existencia del nombre de la conexión ingresada, del usuario.
- **btn_LimpiarActionPerformed():** Este método es la ejecución del evento del botón Limpiar de la ventana cuya función es borrar todos los campos de ingreso de la interfaz.
- **btn_CancelarActionPerformed():** Este método es la ejecución del evento del botón Cancelar de la ventana cuya función es la cancelación de la acción crear conexión.
- **btn_AyudaActionPerformed():** Este método es la ejecución del evento del botón Ayuda de la ventana cuya función es llamar al blog donde estatá toda la documentación del manual de usuario del aplicativo o llamar a una interfaz donde le brinde explicación sobre la utilización de esta interfaz.

- **btn_ConectarActionPerformed():** Este método es la ejecución del evento del botón Conectar de la ventana cuya función es realizar la nueva conexión del aplicativo he invocar a la clase IconTreeModel para gráficar el modelo de la nueva conexión cargando todos los elementos de Bases de datos existentes en el árbol de conexión.

Clase PanelTexto: Esta clase tiene como objetivo la aplicación de estilo a los Paneles cuyo contenido sea un texto con palabras reservadas SQL o de lenguaje procedural etc. Este panel tendrá varias instancias por ejemplo en el View dinámico "KDD Editor" el cual contiene un Panel de edición de sentencias SQL, así mismo con el "Lienzo SQL" del panel Conexiones, sus métodos son:

- **isGuardado():** Este método se encarga de averiguar el estado del atributo guardado del panel, este método es muy importante en el manejo de Views cuyo panel interno es de tipo "SQL Script" donde se controla este estado para poder guardar el contenido del texto en un archivo *.SQL si así lo desea el usuario o sobrescribirlo si ya se lo ha hecho.
- **setGuardado():** Este método se encarga de setear el estado del atributo guardado descrito anteriormente.
- **IniciarVariables():** Este método se encarga de iniciar las variables de estilo para cada palabra reservada**.**
- **ProgramarEventos():** Este método se encarga de ejecutar el evento de presionar una tecla cualquiera y aplicarlo al panel que contiene el texto de edición, llamando así a la función "aplicarEstilo" la cual se ejecuta directamente con cada palabra del texto.
- **aplicarEstilo():** Siendo consecuente con la explicación del anterior método, el actual aplica el estilo a las palabras reservadas, en un comienzo llamando al método "Tokenizar", para luego ir pintando cada palabra con su correspondiente color, así mismo se aplica estilo a los comentarios comunes en un editor de texto en este caso se accionar usando en su comienzo los caracteres "- -" del mismo modo se aplica estilo color rojo a los caracteres que estén dentro de comillas, esto para diferenciar un nombre de un campo o de una celda en una tabla de PostgreSQL ejemplo: **"SELECT** * **FROM** Tabla1,Tabla2 **WHERE** Tabla1.campo1 **LIKE** 'nombre' – sentencia SQL**".**
- **Tokenizar():** este método es el encargado de separar el texto por palabras y retornar una matriz de Strings cuyo contenido es cada palabra con su posición inicial y final dentro del texto.

Clase PanelDataTable: En esta clase se instancia al momento en que se ha instanciado el View estático “ViewDatos” accionado cuando se selecciona una hoja del árbol de conexión cuyo tipo es “tabla”, este panel contiene internamente un JTable en el cual se contendrán todos los datos de la tabla seleccionada y la descripción de la misma, también contiene unos botones de ejecución ya sea de inserción, eliminación o simplemente de reinicio que se aplican a la tabla.

Sus métodos son:

- **Iniciar ():** Este método instancia una conexión a PostgreSQL con la base de datos, el host y el puerto obtenidos de la hoja seleccionada de la árbol de conexión.
- **SetTipo_panel():** Este método se encarga de setear el atributo “tipo panel” de la clase.
- **GetTipo_panel():** Este método se encarga de obtener el valor del atributo “tipo panel” de la clase.
- **SetListaconxiones():** Este método se encarga de setear el atributo “ListaConexiones” de la clase.
- **GetListaconxiones():** Este método se encarga de obtener el valor del atributo “ListaConexiones” de la clase.
- **crear_tablas():** Este método se encarga de cargar los datos de la tabla seleccionada del árbol de conexión al JTable, validando su edición con respecto a la existencia de llave primaria de la misma forma como lo hace internamente PostgreSQL.
- **eventosTabla():** Este método se encarga de adicionarle los eventos al JTable y crear el pop menú cuyos ítems de selección son la exportación de los datos a una página en HTML o un archivo de extensión csv, y también ejecutando el evento de tecla presionada para la post-modificación de la tabla llamando así al método “actualizarDB”.
- **actualizarDB():** Este método se encarga de ejecutar las sentencias SQL correspondientes a la Inserción y modificación que se le realicen al Jtable.

Clase PanelScript: Esta clase se instancia cada vez que se instancia un View dinámico “KDD Editor”, internamente contiene un objeto tipo PanelTexto descrito anteriormente y otro panel el cual contiene un Tabpanel que contiene dos pestañas, una de ellas visualiza el resultado textual de PostgreSQL con respecto a las sentencias SQL escritas en el PanelTexto y la otra pestaña describirá el

resultado de datos si es el caso de una sentencia que arroje como resultado un “ResulSet”.

Sus métodos competen a Get () y Set () de sus atributos de clase.

El paquete GUI contiene el siguiente paquete:

SqlObjects

Clase DataBase: Esta clase se instancia cada vez que se crea o modifica una base de datos, esta contiene un fríame en el cual se encuentra el nombre de la base de datos y una instancia de PanelTexto con el fin de visualizar el código sql generado para el objeto este varía dependiendo si es creación o modificacion, sus métodos son los siguientes:

btn_OKActionPerformed(): Este es un metodo que ejecuta el evento de un botón el cual da como resultado la creación o modificación de la base de datos.

Clase Table: Esta clase instancia cada vez que se crea o modifica una tabla de base de datos, esta contiene un fríame en el cual se encuentra el nombre de la tabla y una instancia de PanelTexto con el fin de visualizar el código sql para el objeto este varia dependiendo si es creación o modificacion, sus métodos son los siguientes:

btn_OKActionPerformed(): Este es un metodo que ejecuta el evento de un botón el cual da como resultado la creación o modificación de la tabla.

Clase Column: Esta clase instancia cada vez que se crea o modifica una columna de una tabla, esta contiene un fríame en el cual se encuentra el nombre de la columna y una instancia de PanelTexto con el fin de visualizar el código sql para el objeto este varia dependiendo si es creación o modificacion,, sus métodos son los siguientes:

btn_OKActionPerformed(): Este es un metodo que ejecuta el evento de un botón el cual da como resultado la creación o modificación de la columna.

Clase PrimaryKey: Esta clase instancia cada vez que se crea o modifica una llave primaria, esta contiene un fríame que describe a la nueva o antigua llave

primaria con una instancia de PanelTexto con el fin de visualizar el código sql generado para el objeto, sus métodos son los siguientes:

btn_OKActionPerformed(): Este es un metodo que ejecuta el evento de un botón el cual da como resultado la creación o modificación de la llave primaria.

Clase ForeignKey: Esta clase instancia cada vez que se crea o modifica una llave foránea, esta contiene un fríame que describe a la nueva o antigua llave foránea con una instancia de PanelTexto con el fin de visualizar el código sql para el objeto, sus métodos son los siguientes:

btn_OKActionPerformed(): Este es un metodo que ejecuta el evento de un botón el cual da como resultado la creación o modificación de la llave foránea.

Clase Function: Esta clase instancia cada vez que se crea una función definida por el usuario, esta contiene un fríame que describe a la nueva funcion con una instancia de PanelTexto con el fin de visualizar el código sql generado para el objeto, sus métodos son los siguientes:

btn_OKActionPerformed(): Este es un metodo que ejecuta el evento de un botón el cual da como resultado la creación de la función.

Clase Rule: Esta clase instancia cada vez que se crea una regla, esta contiene un fríame que describe a la nueva regla con una instancia de PanelTexto con el fin de visualizar el código sql generado para el objeto, sus métodos son los siguientes:

btn_OKActionPerformed(): Este es un metodo que ejecuta el evento de un botón el cual da como resultado la creación de la regla.

Clase Trigger: Esta clase instancia cada ves que se crea un disparador, esta contiene un fríame que describe al nuevo disparador con una instancia de PanelTexto con el fin de visualizar el código sql generado para el objeto, sus métodos son los siguientes:

btn_OKActionPerformed(): Este es un metodo que ejecuta el evento de un botón el cual da como resultado la creación del disparador.

Clase Vista: Esta clase instancia cada vez que se crea una vista, esta contiene un fríame que describe la vista con una instancia de PanelTexto con el fin de visualizar el código sql generado para el objeto, sus métodos son los siguientes:

btn_OKActionPerformed(): Este es un metodo que ejecuta el evento de un botón el cual da como resultado la creación de la vista.

4.6 NUEVAS IMPLEMENTACIONES EN POSTGRESKDD

En el módulo medianamente acoplado de PostgresKDD en la ruta *.. contrib /KDD/clasificacionPg_KDD/inicio_clasificacion.sql*, tomando como referencia el trabajo realizado en [37] se realizaron los siguientes cambios, con el fin de que Pg_KDD pueda ejecutarlos.

Para la tarea de clasificación el proyecto MATE_KDD [37], propone la tarea de clasificación usando una arquitectura medianamente acoplada, usando para la generación de las reglas de decisión funciones definidas por el usuario. Estas funciones se describen brevemente a continuación.

Función matetree()

La función matetree() recibe como parámetro un tipo de dato VARCHAR que contiene el nombre del atributo clase de la tabla. Esta función tiene como fin generar un modelo de clasificación. Esta es la función principal la cual utiliza las funciones mateby() y entro() y luego junto con las funciones mate_tree() y mate_gain construye el modelo de decisión [37].

Función mateby()

La función mateby() recibe como parámetro un tipo de dato VARCHAR que contiene el nombre del atributo clase de la tabla**.** Esta función tiene como fin generar por cada una de las tuplas todas las posibles combinaciones formadas por los valores no nulos de los atributos decisión y el atributo clase de la tabla tratada y además los cuenta. Al aplicar la función mateby(‘<atributo_clase>) sobre la tabla a minar se obtiene la tabla ‘mate_clase’ [37].

Función mate_gain()

La función mate_gain() trabaja con la tabla 'mate_clase' creada por la función mateby() y calcula la ganancia de información de los atributos decisión que cumplan unas determinadas característica y devuelve este valor a la función

mate_tree(). Esta es la función que se encarga de seguir los pasos lógicos para encontrar el nodo en turno [37].

Funciones entro() y gain()

Finalmente se aplican las funciones entro() y gain() que calculan la entropía y la ganancia de los atributos condición respecto al atributo clase. El resultado de estas funciones alimentan las funciones translate_rules() y arm_rules() que se encargan respectivamente de convertir los valores discretizados de la tabla original a sus valores correspondientes y de generar la tabla mate_rules con la estructura de las reglas generadas [37].

Para la implementación en Pg_KDD de la tarea de minería se realizaron pequeñas modificaciones al proceso lógico que se utiliza en la función matetree(). Se determinó que era mucho más eficaz utilizar en los primeros pasos de la generación de las reglas la primitiva SQL *Mate by,* fuertemente acoplada dentro del motor de PostgreSQL. La información que este operador retorne será usado por las función entro() dentro del proceso lógico usado en esa implementación. Para lograr esta modificación se adicionó una función definida por el usuario llamada convertir_mate() cuya definición esta en el archivo *inicio_clasificacion.sql* en el directorio*…/contrib/KDD/clasificaciónPg_KDD* y se muestra en el Anexo A.

Adicionalmente se modificó la función mateby() agregando una llamada a la función convertir_mate() como se observa en el Anexo A. El propósito de esta función es tomar la tabla resultante de Mate by y con estos datos sobre escribir los resultados generados internamente por la función mateby(), además de discretizar los valores para el correcto funcionamiento de la función entro().

Igualmente por requerimientos de la aplicación se adicionó la inserción de los cálculos de los valores de la entropía para determinar el nodo raíz en una nueva tabla usada en la aplicación para despliegue de datos. Esta tabla, llamada *ganancias,* cuya declaración se realiza en el archivo *inicio_clasificacion.sql* en el directorio *…/contrib/KDD/clasificaciónPg_KDD,* como se muestra en el Anexo A,

se visualiza en el proceso de clasificación conectando a un nodo *gain()* un nodo *table view.*

Para la tarea de asociación, también se modificó la manera en que son usados las funciones agregadas, operadores y primitivas de asociación y minera

implementados en PostgresKDD. En la implementación original es necesario configurar manualmente la tabla a la que se le aplicará la tarea de clasificación realizando borrado y creación de tipos y de lenguajes de programación. En Pg_KDD esta configuración se realiza automáticamente al iniciar el módulo de Minería y realizar el cargado del repositorio inicial. De esta manera se resuelve una limitación importante de la implementación y se dota a la herramienta de una mejora importante.

5. PRUEBAS Y EVALUACION DE RESULTADOS

Estas pruebas se realizaron en un equipo cuyas especificaciones son las siguientes:

- Procesador Intel core Quad
- Memoria RAM de 8GB DDR3
- Disco duro de 1 TB.
- Sistema Operativo Linux Slackware 12.

Se utilizaron los repositorios de datos reales de un supermercado del municipio de Pasto y repositorios de datos obtenidos en el portal de repositorios de la universidad de California – Irvine (http://archive.ics.uci.edu/ml/). Las características de cada uno de ellos se muestran a continuación.

5.1 CARACTERISTICAS DE LOS REPOSITORIOS

A continuación se describe los repositorios usados para las pruebas de rendimiento.

5.1.1 Base de datos Universitaria. Esta base de datos fue tomado de [15] donde se relaciona información de promedios educativos.

- Número de registros: 25
- Número de atributos: 5
- Total de diferentes valores: 24

La Tabla 41, muestra los datos de los promedios educativos relacionando la especialización, el estatus, la edad, la nacionalidad y el GPA.

Tabla 41: Repositorio Universitaria

Especialización	Estatus	Edad	Nationalidad	GPA
French	M.A.	Over_30	Canada	2.8…3.2
Cs	Junior	16…20	Europe	3.2…3.6
Physics	M.S.	26…30	Latin_America	3.2…3.6
Engineering	Ph.D	26…30	Asia	3.6…4.0

Especialización	Estatus	Edad	Nationalidad	GPA
Philosophy	Ph.D	26…30	Europe	3.2…3.6
French	Senior	16…20	Canada	3.2…3.6
Chemistry	Junior	21…25	USA	3.6…4.0
Cs	Senior	16…20	Canada	3.2…3.6
Philosophy	M.S.	Over_30	Canada	3.6…4.0
French	Junior	16…20	USA	2.8…3.2
Philosophy	Junior	26…30	Canada	2.8…3.2
Philosophy	M.S.	26…30	Asia	3.2…3.6
French	Junior	16…20	Canada	3.2…3.6
Math	Senior	16…20	USA	3.6…4.0
Cs	Junior	16…20	Canada	3.2…3.6
Philosophy	Ph.D	26…30	Canada	3.6…4.0
Philosophy	senior	26…30	Canada	2.8…3.2
French	Ph.D	Over_30	Canada	2.8…3.2
Engineering	Junior	21…25	Europe	3.2…3.6
Math	Ph.D	26…30	Latin_America	3.2…3.6
Chemistry	Junior	16…20	USA	3.6…4.0
Engineering	Junior	21…25	Canada	3.2…3.6
French	M.S.	Over_30	Latin_America	3.2…3.6
Philosophy	Junior	21…25	USA	2.8…3.2
Math	Junior	16…20	Canada	3.6…4.0

Fuente. Esta investigación.

La base de datos Universitaria se transformó a ítems. En la Tabla 42 relaciona cada valor diferente de la Tabla 41con un nombre de ítem.

Tabla 42: Repositorio Universitaria en Ítems

ITEM	DESCRIPCION	ITEM	DESCRIPCION
I1	French	**I13**	16,,,,20
I2	Cs	**I14**	21,,,,25
I3	Physics	**I15**	26,,,,30
I4	engineering	**I16**	over_30
I5	philosophy	**I17**	Canada
I6	chemistry	**I18**	Europe
I7	Math	**I19**	Latin_America
I8	M.A.	**I20**	Asia
I9	Junior	**I21**	USA
I10	M.S.	**I22**	2,8,,,,3,2
I11	Ph.D	**I23**	3,2,,,,3,6
I12	Senior	**I24**	3,6,,,,4,0

Fuente. Esta investigación.

Finalmente, en la Tabla 43, se muestra la base de datos Universitaria transformada en una tabla tipo transacción-ítems, la cual será la usada en las diferentes pruebas. En la Tabla 43, se indica los valores no nulos para cada transacción.

- Número de transacciones: 25
- Número de atributos: 24 .

Tabla 43: Ítems

TID	LISTA DE ITEMS	TID	LISTA DE ITEMS
T1	I1,I8,I16,I17,I22	**T14**	I7,I12,I13,I21,I24
T2	I2,I9,I13,I18,I23	**T15**	I2,I9,I13,I17,I23
T3	I3,I10,I15,I19,I23	**T16**	I5,I11,I15,I17,I24
T4	I4,I11,I15,I20,I24	**T17**	I5,I12,I15,I17,I22
T5	I5,I11,I15,I18,I23	**T18**	I1,I11,I16,I17,I22
T6	I1,I12,I13,I17,I23	**T19**	I4,I9,I14,I18,I23
T7	I6,I9,I14,I21,I24	**T20**	I7,I11,I15,I19,I23
T8	I2,I12,I13,I17,I23	**T21**	I6,I9,I13,I21,I24
T9	I5,I10,I16,I17,I24	**T22**	I4,I9,I14,I17,I23
T10	I1,I9,I13,I21,I22	**T23**	I1,I10,I16,I19,I23
T11	I5,I9,I15,I17,I22	**T24**	I5,I9,I14,I21,I22
T12	I5,I10,I15,I20,I23	**T25**	I7,I9,I13,I17,I24
T13	I1,I9,I13,I17,I23		

Fuente. Esta investigación.

5.1.2 Base de Datos Mercado. Esta base de datos contiene transacciones de uno de los supermercados más importantes del departamento de Nariño (Colombia) durante un periodo determinado.

- Número de transacciones: 27000
- Promedio Ítems por transacción: 20

La Tabla 44 muestra los valores discretizados de la base de datos Mercado

Tabla 44: Valores transformados de Mercado

Item	Valor
I1	ANEJO VICTORIA
I2	ALPINETTE PASION VERDE

Item	Valor
I3	AROMATICAS GOURMET YERBABUENA
I4	AROMATICAS HINDU TORONJIL
I5	ARROZ FLOR HUILA
I6	CAFE PURO
I7	CEREALES MAIZENA VAINILLA
I8	CHOCOLATE LUKER
I9	CHOCOLYNE
I10	COCA COLA BOT VIDRIO
I11	COLONIA SPLASH SPORT X200 -40%
I12	CREMA DENTAL CREST
I13	CREMA LAVAPLATOS MENTA 500 GTS.250
I14	CUBIERTA DE CHOCOLATE
I15	DES. SERIES INV. W.R. 50% EXTRA CON
I16	ENDULZANTE NATURAL BIODIET SOBRES
I17	ESCOBA AGUAMARINA MADERA
I18	ESPONJILLA BONBRIL
I19	FELDENE GEL 0.5%
I20	HUEVOS CODORNIZ

Fuente. Esta investigación.

5.1.3 Base de Datos Guardería. Esta base de datos relaciona información que fue usada para determinar el acceso o no a escuelas infantiles.

- Número de transacciones: 12960
- Promedio Ítems por transacción: 8

Tabla 45: Repositorio Guardería

Nro	Nombre del Atributo
1	padres
2	en_guarderia
3	hijos
4	hogar
5	finanzas
6	Social
7	salud
8	recomendacion

Fuente. Esta investigación.

5.1.4 Base de datos JugarTenis. Esta base de datos contiene información de 14 casos de decisión, con 5 atributos (atributos nominales).

- Número de transacciones: 14
- Número de atributos: 5

Tabla 46: Repositorio JugarTenis

Nro	Nombre del Atributo
1	Estado
2	Temperatura
3	Humedad
4	Viento
5	Jugar(Clase)

Fuente. Esta investigación.

5.1.5 Base de datos Productos. Esta base de datos contiene las siguientes características:

- Número de transacciones: 9
- Número de atributos: 6

Tabla 47: Repositorio Productos con transacciones

TID	ITEM1	ITEM2	ITEM3	ITEM4	ITEM5	ITEM6
T100	leche	huevos			café	
T101		huevos		queso		
T102		huevos	pan			
T103	leche	huevos		queso		
T104	leche		pan			azucar
T105		huevos	pan			
T106	leche		pan			
T107	leche	huevos	pan		café	
T108	leche	huevos	pan			

Fuente. Esta investigación.

Para efectos de las pruebas funcionales se tomara el repositorio productos de la Tabla 47 y se lo transformara siguiendo los valores representados en laTabla 48.

Tabla 48: Valores Transformados para Productos

Item	Valor
i1	Leche
i2	Huevos
i3	Pan
i4	Queso
i5	Café
I6	Azucar

Fuente. Esta investigación.

5.2 PRUEBA DE FUNCIONALIDAD DE Pg_KDD

Estas pruebas tienen por objetivo probar el buen funcionamiento de la herramienta Pg_KDD con las tareas de minería de datos Asociación y Clasificación. Para tal fin se realizan las pruebas manualmente y con Pg_KDD y se evalúan los resultados obtenidos. Si estos coinciden se demuestra que la herramienta funciona correctamente.

5.2.1 Asociación. Para la tarea de Asociación se utilizó el repositorio transformado de la base de datos Productos denominado Ítems que se muestra en la Tabla 49. A este repositorio se le aplica el algoritmo EquipAsso para calcular el conjunto de ítems frecuentes y luego se generan las reglas:

Tabla 49: Ítems

TID	ITEM1	ITEM2	ITEM3	ITEM4	ITEM5	ITEM6
T100	I1	I2			I5	
T101		I2		I4		
T102		I2	I3			
T103	I1	I2		I4		
T104	I1		I3			I6
T105		I2	I3			
T106	I1		I3			

TID	ITEM1	ITEM2	ITEM3	ITEM4	ITEM5	ITEM6
T107	I1	I2	I3		I5	
T108	I1	I2	I3			

Fuente. Esta investigación.

Aplicación Manual:

Paso 1:

Se calcula el soporte para los ítemsets frecuentes tamaño 1 hasta el grado de la tabla utilizando la primitiva SQL *Associator Range*. Esta consulta se realiza con la siguiente sentencia SQL, y se obtiene el resultado mostrado en la Tabla 50.

Select *item,item2,item3,item4,item5,item6,count(*)* as *soporte*
From *D*
Associator Range *1 until 7*
Group by *item1,item2,item3,item4,item5,item6;*

Paso 2.

Se obtienen el conjunto de ítems frecuentes que cumplan con un soporte mínimo mayor o igual a 2 *(i.e. minsup=2/9=22%)*. Para ello se ejecuta la siguiente sentencia SQL. El resultado se muestra en la Tabla 51.

Select *item,item2,item3,item4,item5,item6,count(*)* As *soporte*
INTO *fre_directos*
FROM *ïtems*
ASSOCIATOR RANGE *1* Until *7*
GROUP By *item1,item2,item3,item4,item5,item6*
HAVING *count(*) >=2*

Tabla 50: Associator Range

item1	item2	item3	item4	item5	item6	soporte
I1	I2	I3		I5		1
I1	I2	I3				2
I1	I2		I4			1
I1	I2			I5		2
I1	I2					4
I1		I3		I5		1
I1		I3			I6	1

item1	item2	item3	item4	item5	item6	soporte
I1		I3				4
I1			I4			1
I1				I5		2
I1					I6	1
I1						6
	I2	I2		I5		1
	I2	I3				4
	I2	I3				4
	I2		I4			2
	I2			I5		2
	I2					7
		I3		I5		1
		I3			I6	1
		I3				6
			I4			2
				I5		2
					I6	1

Fuente. Esta investigación.

Tabla 51: fre_directos

Item1	Item2	Item3	Item4	Item5	Item6	soporte
I1	I1	I3				2
I1	I2			I5		2
I1	I2					4
I1		I3				4
I1				I5		2
I1						6
	I2	I3				4
	I2		I5			2
	I2					7
		I3				6
			I4			2
				I5		2

Fuente. Esta investigación.

Paso 3

Se generan las reglas de tamaño 3 de la tabla *fre_directos* con una confianza mínima del 20% se ejecuta la siguiente sentencia SQL. El resultado se muestra en la Tabla 52.

SELECT * FROM *DESCRIBE_ASSOCIATOR_RULES*(‘*fre_directos*,2,20).

Tabla 52: Resultado de Describe_Associator_Rules

Item1	Item2	Item3	Item4	Item5	n_regla	Implica	Soporte	confianza
I1					1	A	6	33.33
	I2	I3			1	C	4	
	I2				2	A	7	28.57
I1		I3			2	C	4	
		I3			3	A	6	33.33
I1	I2				3	C	4	
I1	I2				4	A	4	50.00
		I3			4	C	6	
I1		I3			5	A	4	50.00
	I2				5	C	7	
	I2	I3			6	A	4	50.00
I1					6	C	6	
I1					7	A	6	33.33
	I2			I5	7	C	2	
	I2				8	A	7	28.57
I1				I5	8	C	2	
				I5	9	A	2	100.00
I1	I2				9	C	4	
I1	I2				10	A	4	50.00
				I5	10	C		
I1				I5	11	A	2	100.00
	I2				11	C	7	
	I2			I5	12	A	2	100.00
I1					12	C	6	

Fuente. Esta investigación.

Con esta tabla se generan las reglas siguiendo el orden lógico que ella nos presenta. La columna *n_regla* indica el número de la regla. Para cada regla en la columna *implica* se detalla cual es el antecedente y cual el consecuente. También se muestra el soporte de la regla.

Las reglas que se generan son las siguientes:

- $I1 \Rightarrow I2 \wedge I3$ confianza = 2/6 = 33.33%
- $I2 \Rightarrow I1 \wedge I3$ confianza = 2/7 = 28.57%
- $I3 \Rightarrow I1 \wedge I2$ confianza = 2/2 = 33.33%
- $I1 \wedge I2 \Rightarrow I3$ confianza = 2/4 = 50%
- $I1 \wedge I3 \Rightarrow I2$ confianza = 2/2 = 50%
- $I2 \wedge I3 \Rightarrow I1$ confianza = 2/2 = 50%

- $I1 \Rightarrow I2 \wedge I5$ confianza = 2/6 = 33.33%
- $I2 \Rightarrow I1 \wedge I5$ confianza = 2/7 = 28.57%
- $I5 \Rightarrow I1 \wedge I2$ confianza = 2/2 = 100%
- $I1 \wedge I2 \Rightarrow I\ 5$ confianza = 2/4 = 50%
- $I1 \wedge I5 \Rightarrow I\ 2$ confianza = 2/2 = 100%
- $I2 \wedge I5 \Rightarrow I\ 1$ confianza = 2/2 = 100%

Aplicación en Pg_KDD

En la pantalla principal de la aplicación Pg_KDD, se crea una nueva database llamada *asociación* como se lo observa en la Figura 53.

Figura 53: Creación de la nueva database asociación

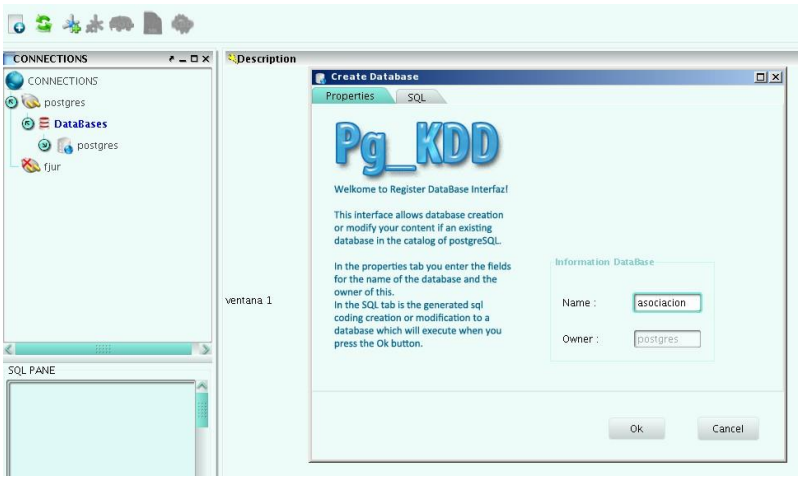

Fuente. Esta investigación.

En la Figura 54, se crea la tabla *ítem* dentro de la database *asociación.*

Figura 54: Script - Tabla item

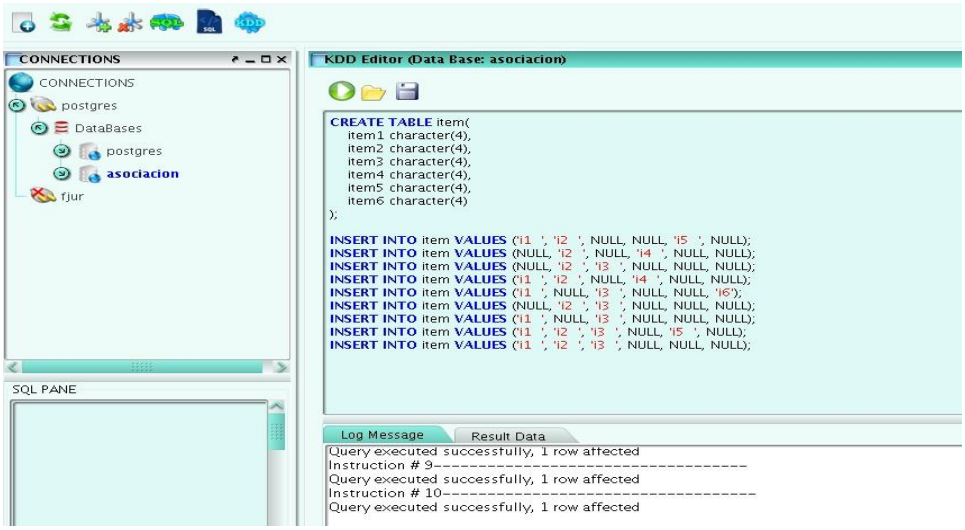

Fuente. Esta investigación.

Paso 1

Se carga el módulo de data mining y agregamos hacia el work area el objeto KDD *repository* (Figura 55). Cargamos la tabla *ítem*, seleccionando todos sus atributos (Figura 56). Y con clic derecho se da clic en *Run* para que el nodo se ejecute.

Figura 55: Cargar repositorio para asociación

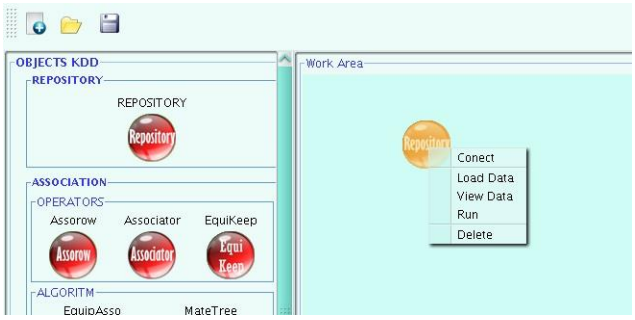

Fuente. Esta investigación.

Figura 56: Selección de los atributos

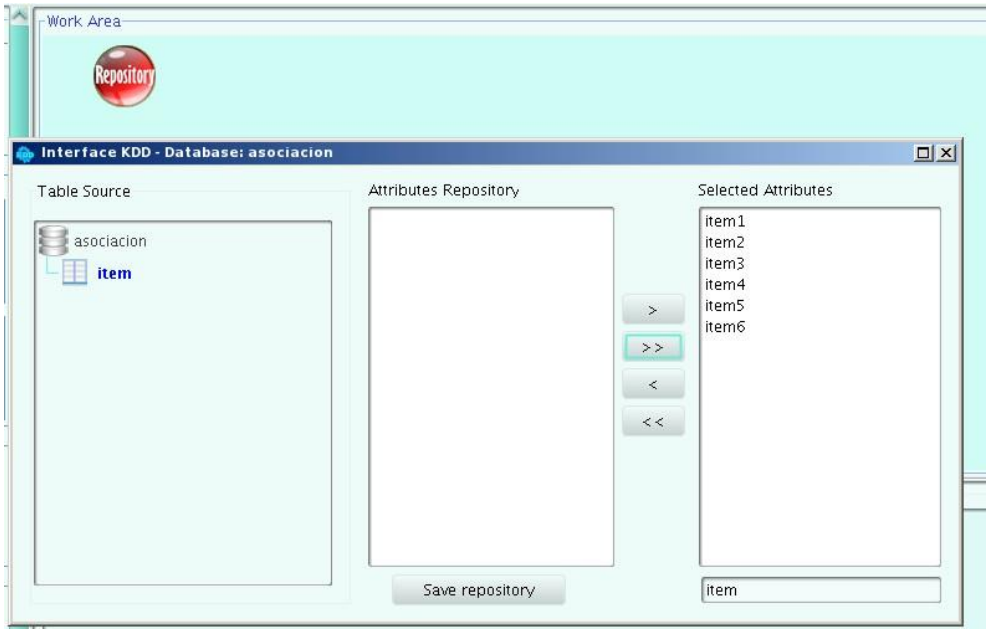

Fuente. Esta investigación.

Paso 2

Se agrega un objeto tipo *Associator* al área de trabajo. Se conecta al nodo *repository* y se configura el rango de trabajo del operador *Associator (*Figura 57).

Figura 57: Configuración del operador Associator

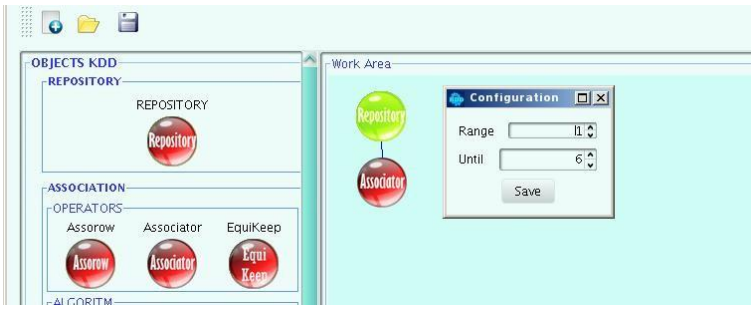

Fuente. Esta investigación.

Se agrega un nodo *Table View,* se lo conecta al nodo *Associator.* Con clic derecho se lo ejecuta, y se muestra la tabla resultado de la primitiva *Associator range* (Figura 58).

Figura 58: Resultado de Associator Range

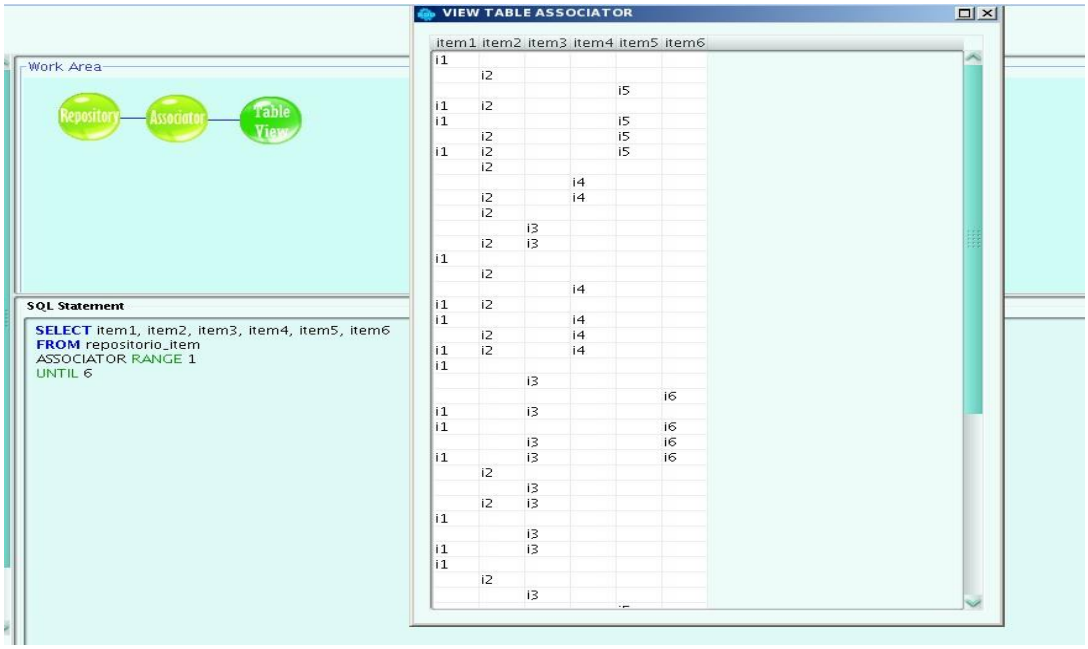

Fuente. Esta investigación.

Paso 3

Se agrega un nodo *EquipAsso* al área de trabajo, se lo conecta al nodo *Associator*, se lo configura y se lo ejecuta (Figura 59).

Figura 59: Configuración del operador Equipaso

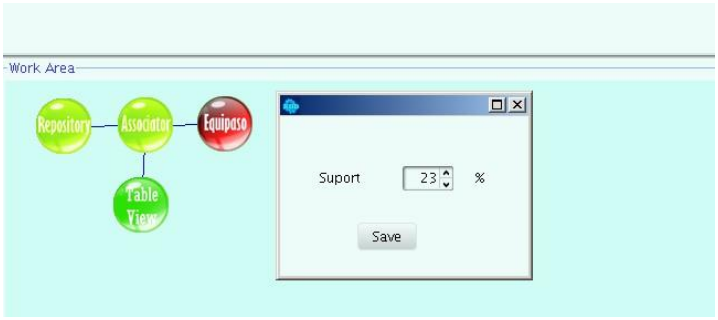

Fuente. Esta investigación.

Se arrastra un nodo *Table view,* se lo conecta al nodo *EquipAsso,* se ejecuta y se muestra el resultado de la primitiva Associator Range, restringiendo el resultado a los ítemset con un soporte mayor igual a 2 *(i.e. minsup=2/9=22%*) (Figura 60), en este caso el soporte es mayor al que nos da como resultado al calcularlo debido a requerimientos de la aplicación.

Figura 60: Resultado de Equipaso

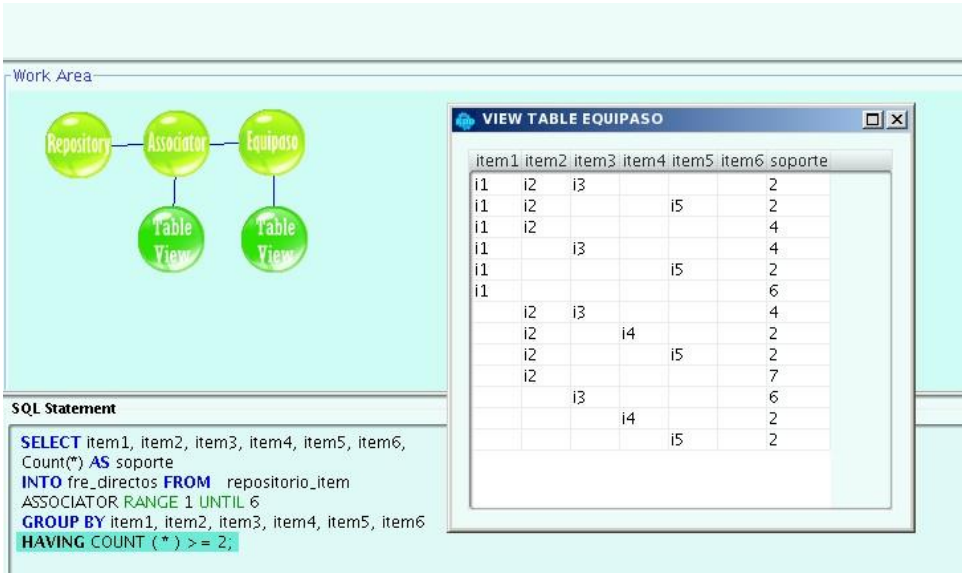

Fuente. Esta investigación.

Paso 4

Finalmente se agrega un nodo *Associator Rules,* conectado al nodo *EquipAsso*.. Se configura el tamaño de las reglas, si se desea generar todas las reglas hasta ese tamaño, y la confianza minima (Figura 61).

Figura 61: Configuración del nodo Associator Rules

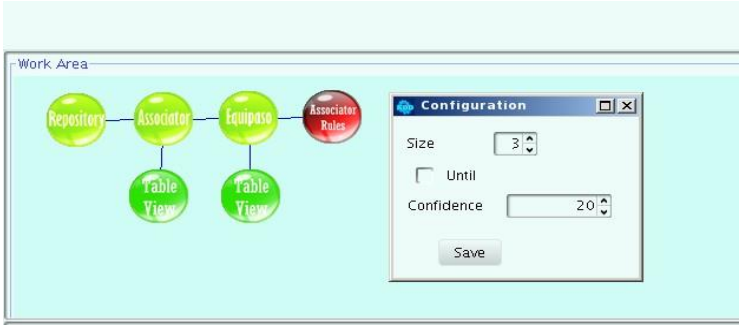

Fuente. Esta investigación.

Se agrega un nodo *Rules View,* se lo ejecuta y se muestran las reglas generadas por la función agregada *describe_associator_rules (*Figura 62),

Figura 62: Reglas generadas por la función describe_associator_rules

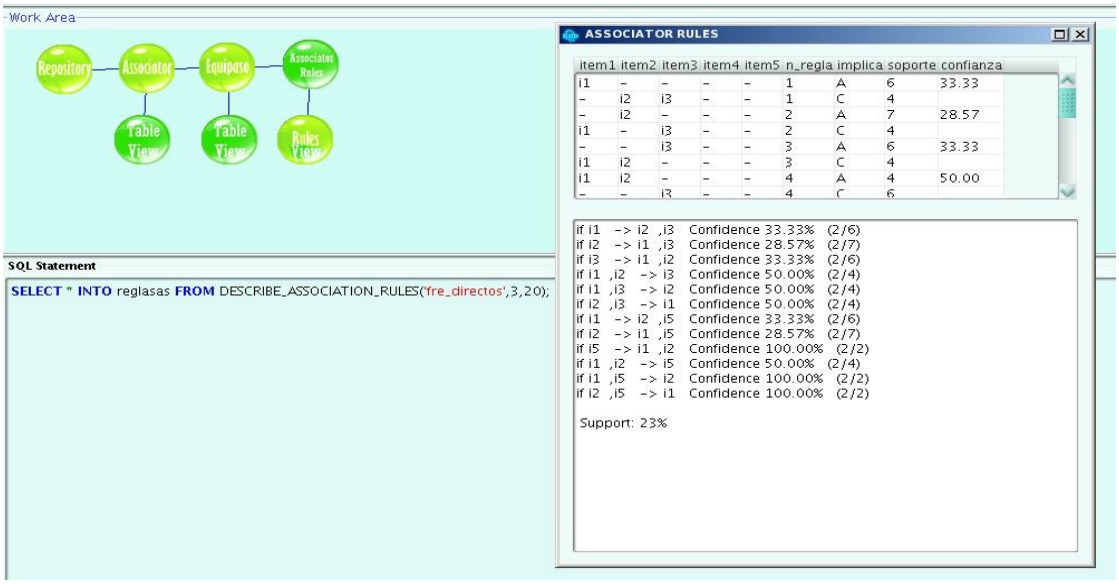

Fuente. Esta investigación.

Del proceso anterior se verifica que las reglas que se generan corresponden a las encontradas anteriormente, como lo indica la Figura 63.

Figura 63: Comparación de resultados

	Proceso Manual	Pg_KDD
I1 ⇒ I2 ∧ I3	**confianza = 2/6 = 33.33%**	if i1 -> i2 ,i3 Confidence 33.33% (2/6)
I2 ⇒ I1 ∧ I3	**confianza = 2/7 = 28.57%**	if i2 -> i1 ,i3 Confidence 28.57% (2/7)
I3 ⇒ I1 ∧ I2	**confianza = 2/2 = 33.33%**	if i3 -> i1 ,i2 Confidence 33.33% (2/6)
I1 ∧ I2 ⇒ I3	**confianza = 2/4 = 50%**	if i1 ,i2 -> i3 Confidence 50.00% (2/4)
I1 ∧ I3 ⇒ I2	**confianza = 2/2 = 50%**	if i1 ,i3 -> i2 Confidence 50.00% (2/4)
I2 ∧ I3 ⇒ I1	**confianza = 2/2 = 50%**	if i2 ,i3 -> i1 Confidence 50.00% (2/4)
I1 ⇒ I2 ∧ I5	**confianza = 2/6 = 33.33%**	if i1 -> i2 ,i5 Confidence 33.33% (2/6)
I2 ⇒ I1 ∧ I5	**confianza = 2/7 = 28.57%**	if i2 -> i1 ,i5 Confidence 28.57% (2/7)
I5 ⇒ I1 ∧ I2	**confianza = 2/2 = 100%**	if i5 -> i1 ,i2 Confidence 100.00% (2/2)
I1 ∧ I2 ⇒ I 5	**confianza = 2/4 = 50%**	if i1 ,i2 -> i5 Confidence 50.00% (2/4)
I1 ∧ I5 ⇒ I 2	**confianza = 2/2 = 100%**	if i1 ,i5 -> i2 Confidence 100.00% (2/2)
I2 ∧ I5 ⇒ I 1	**confianza = 2/2 = 100%**	if i2 ,i5 -> i1 Confidence 100.00% (2/2)

Fuente. Esta investigación.

Analizando los resultados obtenidos manualmente en las Tabla 50, Tabla 51 y Tabla 52 y los obtenidos en las Figura 58, Figura 60 y Figura 62 se puede observar que estos coinciden en su totalidad, por lo tanto la herramienta Pg_KDD funciona correctamente para la tarea de Asociación.

5.2.2 Clasificación. Para la tarea de Clasificación se utilizó el repositorio denominado *Jugartenis* que se muestra en la Figura 64. A este repositorio se le aplica el algoritmo Mate-Tree para calcular construir el árbol de decisión y luego se generar las reglas de clasificación.

Figura 64: jugartenis

DIA	ESTADO	TEMPER.	HUMEDAD	VIENTO	JUGAR TENIS
D1	Soleado	Caliente	Alta	Debil	No
D2	Soleado	Caliente	Alta	Fuerte	No
D3	Nublado	Caliente	Alta	Debil	SI
D4	Lluvioso	Templado	Alta	Debil	Si
D5	Lluvioso	Fresco	Normal	Debil	Si
D6	Lluvioso	Fresco	Normal	Fuerte	No
D7	Nublado	Fresco	Normal	Fuerte	Si
D8	Soleado	Templado	Alta	Debil	No
D9	Soleado	Fresco	Normal	Debil	Si
D10	Lluvioso	Templado	Normal	Debil	Si
D11	Soleado	Templado	Normal	Fuerte	Si
D12	Nublado	Templado	Alta	Fuerte	Si
D13	Nublado	Caliente	Normal	Debil	Si
D14	Lluvioso	Templado	Alta	Fuerte	No

Fuente. Timarán,R. Clasificación: una tarea de descubrimiento de conocimiento en bases de datos, Pasto, 2009 [49].

Aplicación manual [49]:

Paso 1

Se define como atributo clase S, al atributo *jugarTenis,* se calcula la Entropía de *S,* el conteo para Si=9 y el conteo para No=5. Aplicando la fórmula para la entropia, tenemos:

Entropía(S)=E(S)= -Σpi log_2 *pi,* donde pi es la probabilidad que un ejemplo arbitrario pertenezca a la clase Ci.

$E([9+,5-])=-(9/14)log_2(9/14)-(5/14)log_2(5/14)$
$E([9+,5-])=0.940$

Calculo de ganancias

Se calcula la ganancia de cada atributo condición respecto al atributo clase S, usando la siguiente formula:

Gain(S,A)= Entropía(S) – Σv ∈ Valores(A) |Sv|/ |S |* Entropía(Sv)*
Donde:

Valores(A) es el conjunto de todos los valores del atributo *A*
Sv es el subconjunto de *S* para el atributo *A* que toma valores *v.*

- Para el Atributo viento.

  valores(viento)=debil,fuerte.
  Sdebil=[6+,2-]
  Sfuerte=[3+,3-]

  *Gain(S,Viento)=Entropia(S)-(Sdebil*Entropia(Sdebil)+Sfuerte*Entropia(Sfuerte)*
  = 0.940 -8/14Entropia(Sdebil) -6/14Entropia(Sfuerte)

  Calculamos *E(Sdebil)=E([6+,2-])=-(6/8)log2(6/8) –(2/8)log2(2/8)=0.811*
  E(Sfuerte)=E([3+,3-])=-(3/6)log2(3/6)-(3/6)log2(3/6)=1

  Reemplazando:
  *Gain(S,viento)=0.940 -0.463-0.428=**0.048***

- Para el atributo Estado:
  *Gain(S,Estado)=0.940-(5/14)0.97 – (4/14)0 - (5/14)0.97=**0.246***

- Para el atributo Humedad: *Gain(S,Humedad)=**0.151***

- Para el atributo Temperatura: *Gain(S,Temperatura)=**0.029***

Paso 2

Construcción del árbol

De acuerdo a la ganancia de información, el atributo que mayor ganancia tiene es *estado*, por lo tanto este atributo se selecciona como el nodo *raíz*. Los nodos hijos son los diferentes valores que puede tomar *estado* (Figura 65).

Figura 65: Árbol de decisión 1

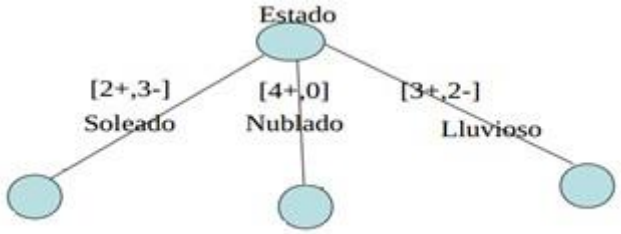

Fuente. Timarán,R. Clasificación: una tarea de descubrimiento de conocimiento en bases de datos, Pasto, 2009 [49].

De la
Figura 66, siguiente podemos determinar que para el estado *nublado* para cada valor se presenta una clasificación positiva sobre la clase decisión *JugarTenis*, por lo tanto el nodo esta formado por un nodo hoja en la cual la clasificación *JugarTenis=si* y el valor de la entropía = 0.

Figura 66: Valores para el estado nublado

DIA	ESTADO	TEMPERATURA	HUMEDAD	VIENTO	JUGARTENIS
D3	Nublado	Caliente	Alta	Débil	Si
D7	Nublado	Fresco	Normal	Fuerte	Si
D12	Nublado	Templado	Alta	Fuerte	Si
D13	Nublado	Caliente	Normal	Débil	Si

Fuente. Timarán,R. Clasificación: una tarea de descubrimiento de conocimiento en bases de datos, Pasto, 2009 [49].

Paso 3

La Figura 67, nos muestra que para el estado soleado, no hay uniformidad en los valores sobre la clase decisión, por lo que es necesario calcular la ganancia de *soleado* respecto los atributos condición y su valor en el atributo clase.

Figura 67: Valores para el estado soleado

DIA	ESTADO	TEMPERATURA	HUMEDAD	VIENTO	JUGARTENIS
D1	Soleado	Caliente	Alta	Débil	No
D2	Soleado	Caliente	Alta	Fuerte	No
D8	Soleado	Templado	Alta	Débil	No
D9	Soleado	Fresco	Normal	Débil	Si
D11	Soleado	Templado	Normal	Fuerte	Si

Fuente. Timarán,R. Clasificación: una tarea de descubrimiento de conocimiento en bases de datos, Pasto, 2009 [49].

- Ganancia en Soleado

  Humedad (Alta[0+,3-])
  Humedad(Normal[2+,0-])

  *Gain(Soleado,Humedad)=0.970 – (3/5)*0 –(2/5) * 0= 0.970*

- Ganancia en Temperatura

  Temperatura(Caliente[0+,0-])
  Temperatura(Templado[1+,1-])
  Temperatura(fresco[1+,0-])

  *Gain(Soleado,Temperatura)=0.970 – (2/5)*0 – (2/5) * 1 – (1/5) * 0 = 0.570*

- Ganancia en Viento

  Viento(Débil[1+,2-])
  Viento(fuerte[1+,1-])

  *Gain(Soleado,Viento)=0.970 – (3/5)*0.918 – (2/5)* 1=0.019*

Construcción del árbol

De los cálculos anteriores determinamos que el atributo con mayor ganancia de información es humedad, por lo tanto lo ubicamos como nodo hijo de *estado=soleado.*

Figura 68: Árbol de Decisión 2

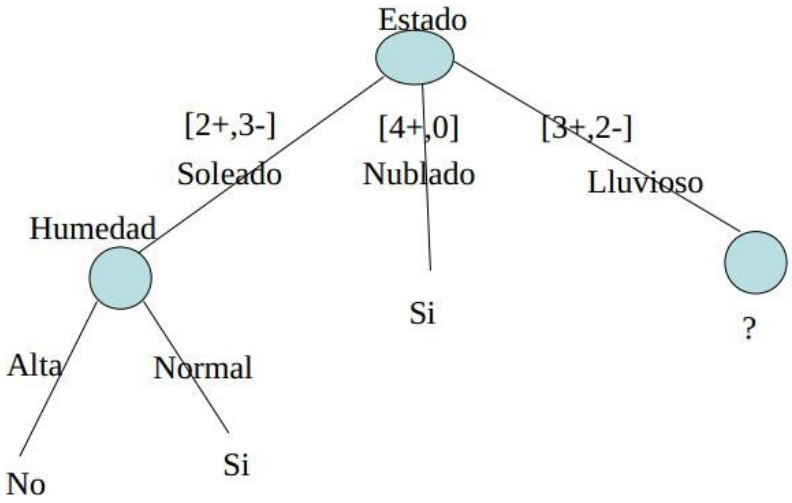

Fuente. Timarán,R. Clasificación: una tarea de descubrimiento de conocimiento en bases de datos, Pasto, 2009 [49].

De la Figura 68, se observa que para *humedad=alta,* para cada valor se presenta una clasificación negativa sobre la clase decisión *JugarTenis*, por lo tanto el nodo esta formado por un nodo hoja en la cual la clasificación *JugarTenis=no* y el valor de la entropía =0. Igual ocurre con *humedad=normal,* con un valor para *JugarTenis=si.*

Ahora para *estado=lluvioso, l*a Figura 69, nos muestra que no hay uniformidad en los valores sobre la clase decisión, por lo que es necesario calcular la ganancia de *lluvioso* respecto los atributos condición y su valor en el atributo clase.

Figura 69: Valores para estado lluvioso

DIA	ESTADO	TEMPERATURA	HUMEDAD	VIENTO	JUGARTENIS
D4	Lluvioso	Templado	Alta	Débil	Si
D5	Lluvioso	Fresco	Normal	Débil	Si
D6	Lluvioso	Fresco	Normal	Fuerte	No
D10	Lluvioso	Templado	Normal	Débil	Si

Fuente. Timarán,R. Clasificación: una tarea de descubrimiento de conocimiento en bases de datos, Pasto, 2009 [49].

- Ganancia en Lluvioso

  Humedad(Alta[1+,1-])
  Humedad(Normal[2+,1-])

  *Gain(Lluvioso,Humedad)=0.97 – (2/5)*1 –(3/5) * 0.917= 0.0198*

- Ganancia enTemperatura

  Temperatura(Caliente[0+,0-])
  Temperatura(Templado[2+,1-])
  Temperatura(fresco[1+,1-])

  *Gain(Lluvioso,Temperatura)=0.97 –0 – (3/5) *0.917 – (2/5) *1 = 0.0198*

- Ganancia en Viento

  Viento(Debil[3+,0-])
  Viento(Fuerte[0+,2-])

  *Gain(Lluvioso,Viento)=0.970 – (3/5)*0 – (2/5)* 0=0.970*

Construcción del árbol

De los cálculos anteriores determinamos que el atributo con mayor ganancia de información es viento, por lo tanto lo ubicamos que el nodo hijo de e*stado=lluvioso*.

De la Figura 69, se observa que para *viento=debil,* para cada valor se presenta una clasificación positiva sobre la clase decisión *JugarTenis*, por lo tanto el nodo esta formado por un nodo hoja en la cual la clasificación *JugarTenis=si* y el valor de la entropía =0. Igual ocurre con *viento=fuerte,* con un valor para *JugarTenis=no.*

Aquí termina la construcción del arbol pues todos los nodos finales son nodos hoja. El árbol generado se muestra en la
Figura 70. Ahora es posible generar las reglas siguiendo el orden establecido en el árbol. Las reglas se muestran en la Figura 71.

Figura 70: Árbol de decisión final

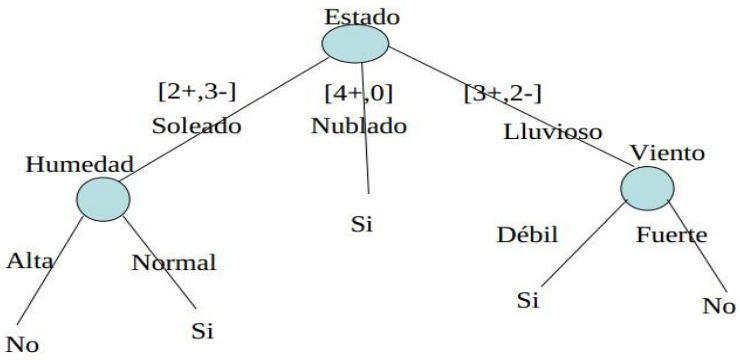

Fuente. Timarán,R. Clasificación: una tarea de descubrimiento de conocimiento en bases de datos, Pasto, 2009 [49].

Figura 71: Reglas Generadas

1. Estado=Soleado ^ Humedad=alta -->JugarTenis = No
2. Estado=Soleado ^ Humedad=Normal -->JugarTenis = Si
3. Estado=Nublado -->JugarTenis = Si
4. Estado=Lluvioso ^ Viento=Debil -->JugarTenis = Si
5. Estado=Lluvioso ^ Viento=Fuerte -->JugarTenis = No

Fuente. Timarán,R. Clasificación: una tarea de descubrimiento de conocimiento en bases de datos, Pasto, 2009 [49].

Aplicación con Pg_KDD:

Para la tarea de clasificación, Pg_KDD hace uso de los operadores Mate by, y de las funciones agregadas matetree(), test_rules(), translate_rules() y arm_rules() para la creación del árbol de decisión.

En la pantalla principal de la aplicación Pg_KDD, se crea una nueva database llamada *clasificación* (Figura 72).

Figura 72: Creación de la nueva database clasificacion

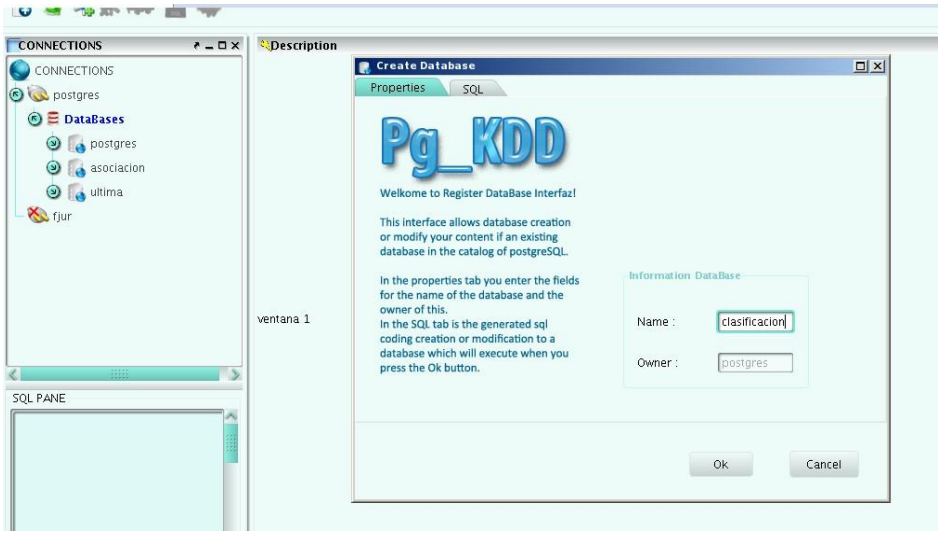

Fuente. Esta investigación.

Se crea la tabla *JugarTenis* dentro de la database *clasificación* Figura 73.

Figura 73: Creación de la table jugartenis

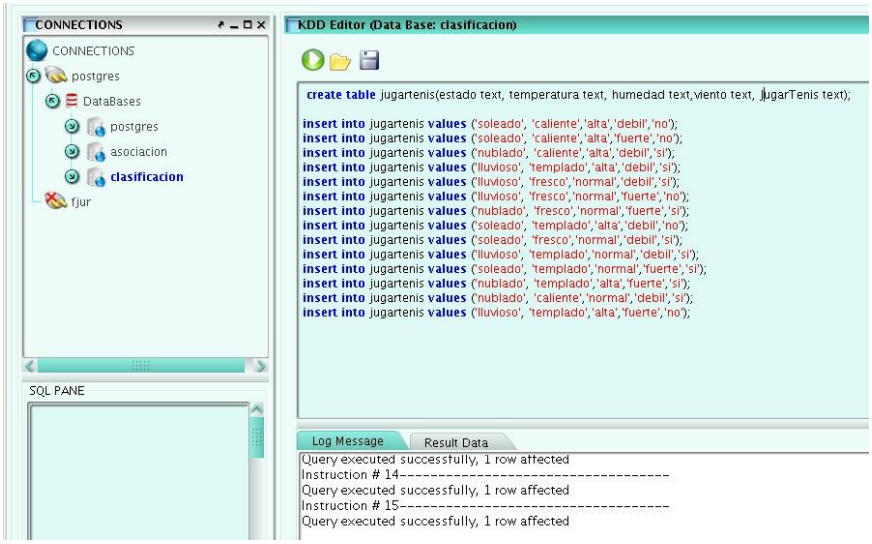

Fuente. Esta investigación.

Se carga el módulo de data mining y agregamos en el work area el objeto KDD *repository* (Figura 74). Cargamos la tabla *jugartenis*, seleccionando todos sus atributos (
Figura 75). Y con clic derecho se da clic en *Run* para que el nodo se ejecute.

Figura 74: Carar repositorio para clasificación

Fuente. Esta investigación.

Figura 75: Selección de los atributos

Paso 1.

Se agrega un objeto tipo *Mate* al área de trabajo. Se conecta al nodo *repository* y se configura el atributo clase (Figura 76).

Figura 76: Configuración del operador Mate

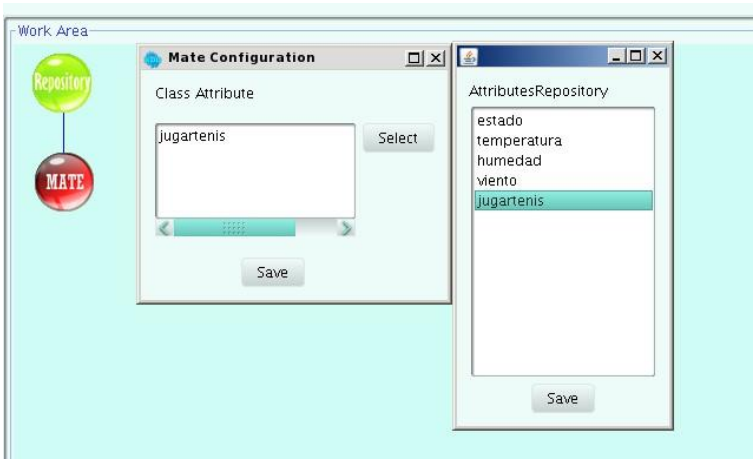

Fuente. Esta investigación.

Se agrega un nodo *Table view,* se lo ejecuta y visualizamos la tabla generada por el operador *Mate By (* Figura 77*).*

Figura 77: Resultado del operador Mate By

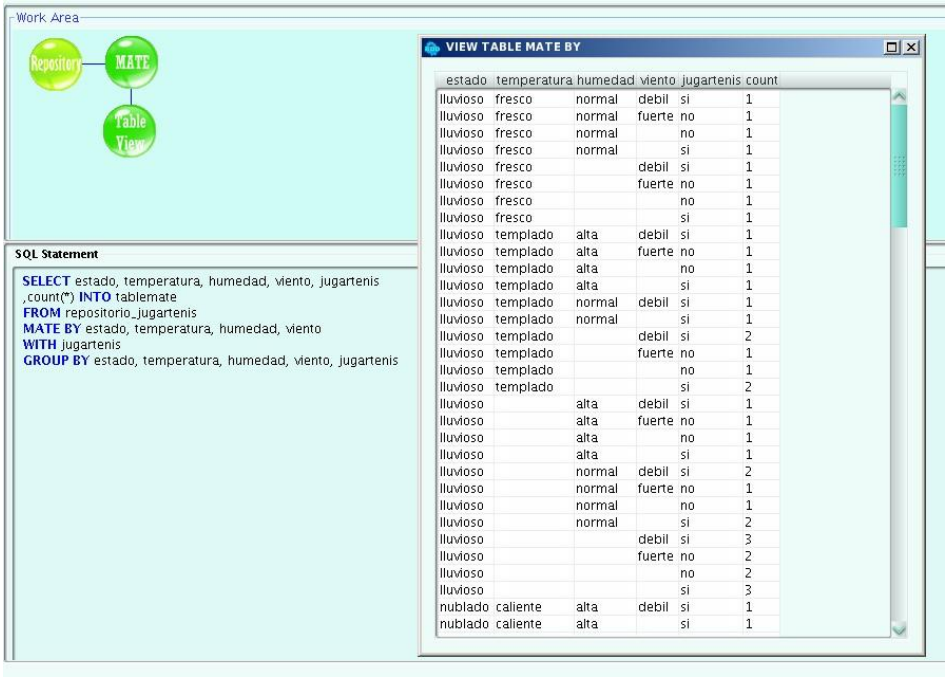

Fuente. Esta investigación.

Paso 2.

Ahora, se agrega un nodo *entro* conectado al nodo mate, igualmente se agrega un nodo *table view* conectado al nodo *entro,* se lo configura y se visualiza el resultado de la función matetree() (Figura 78).

Figura 78: Cálculo de la entropía

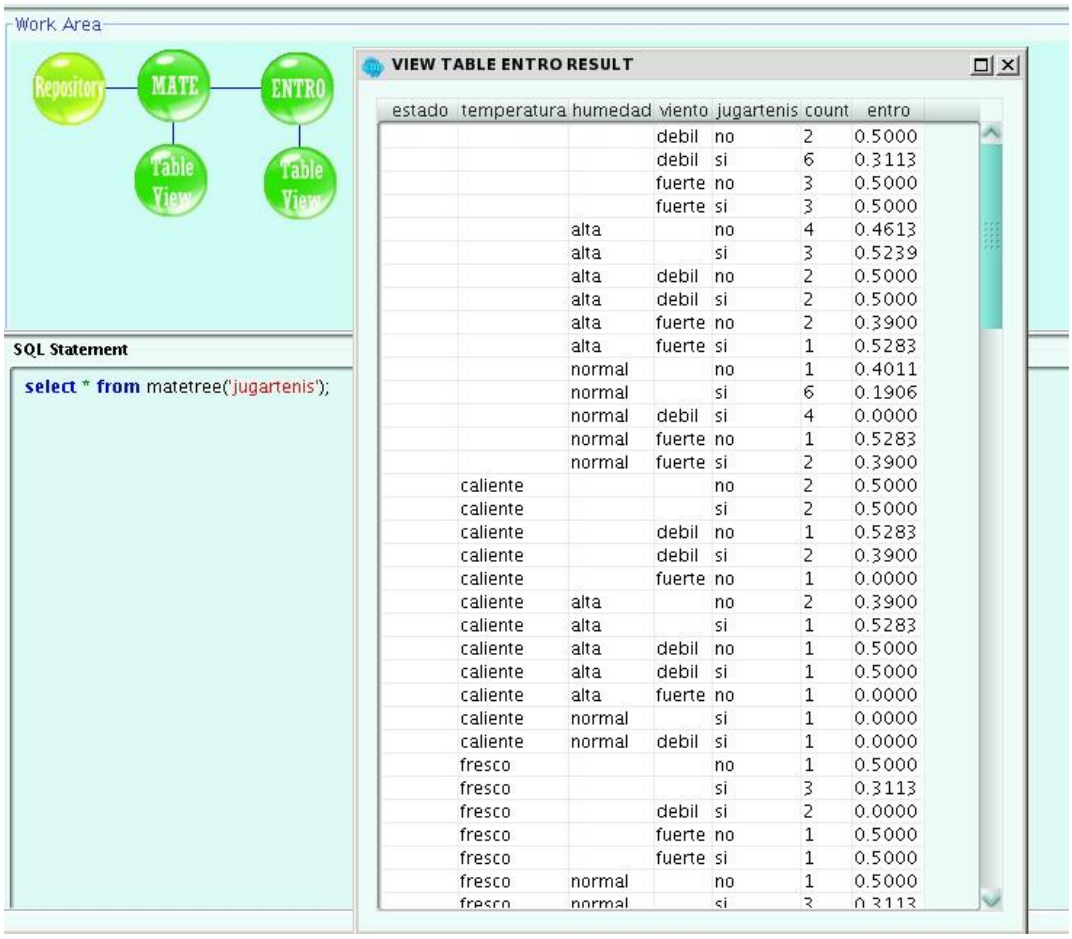

estado	temperatura	humedad	viento	jugartenis	count	entro
			debil	no	2	0.5000
			debil	si	6	0.3113
			fuerte	no	3	0.5000
			fuerte	si	3	0.5000
		alta		no	4	0.4613
		alta		si	3	0.5239
		alta	debil	no	2	0.5000
		alta	debil	si	2	0.5000
		alta	fuerte	no	2	0.3900
		alta	fuerte	si	1	0.5283
		normal		no	1	0.4011
		normal		si	6	0.1906
		normal	debil	si	4	0.0000
		normal	fuerte	no	1	0.5283
		normal	fuerte	si	2	0.3900
	caliente			no	2	0.5000
	caliente			si	2	0.5000
	caliente		debil	no	1	0.5283
	caliente		debil	si	2	0.3900
	caliente		fuerte	no	1	0.0000
	caliente	alta		no	2	0.3900
	caliente	alta		si	1	0.5283
	caliente	alta	debil	no	1	0.5000
	caliente	alta	debil	si	1	0.5000
	caliente	alta	fuerte	no	1	0.0000
	caliente	normal		si	1	0.0000
	caliente	normal	debil	si	1	0.0000
	fresco			no	1	0.5000
	fresco			si	3	0.3113
	fresco		debil	si	2	0.0000
	fresco		fuerte	no	1	0.5000
	fresco		fuerte	si	1	0.5000
	fresco	normal		no	1	0.5000
	fresco	normal		si	3	0.3113

Fuente. Esta investigación.

Paso 3.

Ahora para determinar el nodo raíz y crear el árbol de decisión, se agrega un nodo *gain()* conectado al nodo *entro(),* también se agrega un *Table view,* se ejecuta estos nodos y se visualiza el resultado de la operación de este nodo, el cual genera dos tablas, una indica el calculo de las entropías para determinar el nodo raíz, y otra con las reglas de decisión finales aunque con valores discretizados para los nodos (Figura 79). En esta última tabla se puede observar la lógica de la estructura del árbol.

Figura 79: Ganancias y Tabla con el árbol de decisión.

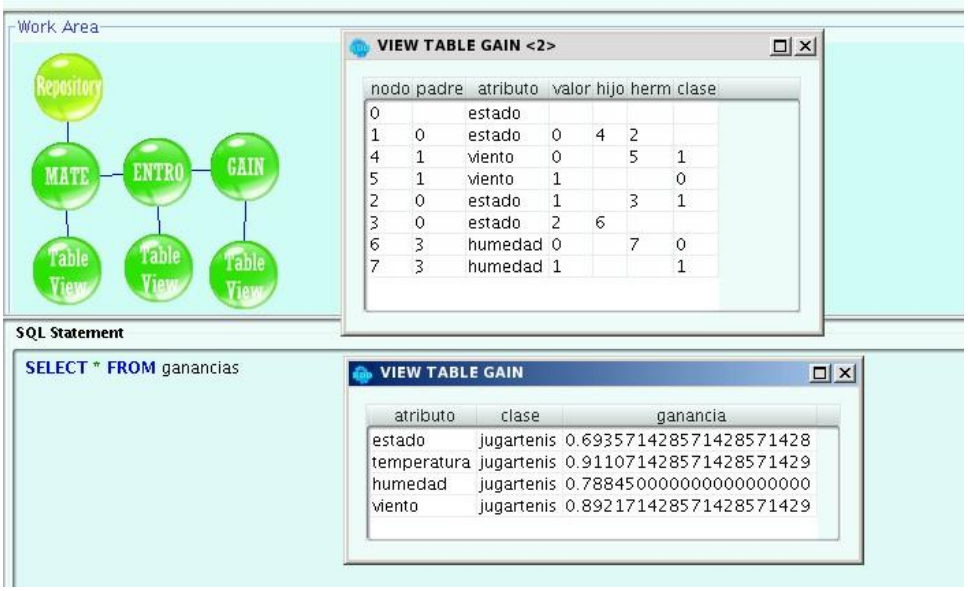

Fuente. Esta investigación.

Paso 4.

Finalmente se agrega un nodo *classification rules* conectado al nodo *gain,* y un nodo *rules view.* Se ejecutan estos nodos y se visualiza las reglas ya generadas (Figura 80). En este paso se utilizan las funciones agregadas test_rules(), translate_rules() y arm_rules() que verifican las reglas generadas, transformar a su estado inicial los valores de las tablas y arman cada una de las reglas y devuelve reglas del tipo "*condicion1 AND condicion2.. --> Decisión"* respectivamente.

Figura 80: Reglas generadas

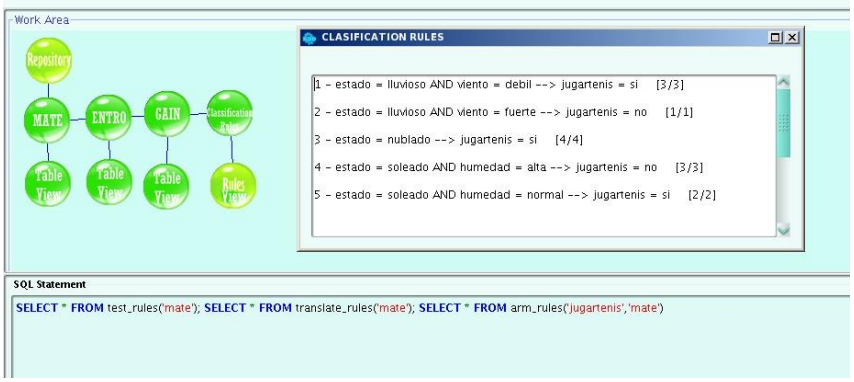

Fuente. Esta investigación.

Del proceso anterior se verifica que las reglas que se generan corresponden a las encontradas anteriormente, como lo indica la

.Figura 81: Comparación de resultados

Proceso Manual	Pg_KDD
1. Estado=Soleado ^ Humedad=alta -->JugarTenis = No	1 – estado = soleado AND humedad = alta --> jugartenis = no [3/3]
2. Estado=Soleado ^ Humedad=Normal -->JugarTenis = Si	2 - estado = soleado AND humedad = normal --> jugartenis = si [2/2]
3. Estado=Nublado -->JugarTenis = Si	3 - estado = nublado --> jugartenis = si [4/4]
4. Estado=Lluvioso ^ Viento=Debil -->JugarTenis = Si	4 - estado = lluvioso AND viento = debil --> jugartenis = si [3/3]
5. Estado=Lluvioso ^ Viento=Fuerte -->JugarTenis = No	5 - estado = lluvioso AND viento = fuerte --> jugartenis = no [1/1]

Fuente. Esta investigación.

Observando los resultados obtenidos del proceso manual y del proceso con Pg_KDD, para la tarea de clasificacion el árbol construido y las reglas coinciden en su totalidad, por lo que se puede inferir que la herramienta funciona para esta tarea.

REFERENCIAS

1. Agrawal R., Mannila H., Srikant R., Toivonen H., Verkamo A.I., Fast Discovery of Association Rules, in Advances in Knowledge Discovery and Data Mining, AAAI Press / The MIT Press, 1996.

2. Chaudhuri S., Data Mining and Database Systems: Where is the Intersection?, Bulletin of the Technical Committee on Data Engineering, Vol.21 No. 1, Marzo, 1998.

3. Chen M., Han J., Yu P., Data Mining: An Overview from Database Perspective, IEEE Transactions on Knowledge and Data Engineering, 1996.

4. Clear, J., Dunn, D., Harvey, B., Heytens, M., Lohman, P., Mehta, A., Melton, M., Rohrberg, L., Savasere, A., Wehrmeister, R., Xu, M., NonStop SQL/MX Primitives for Knowledge Discovery, KDD-99, San Diego, USA, 1999.

5. Fayyad, U., Piatetsky-Shapiro, G., Smyth, P., From Data Mining to Knowledge Discovery: An Overview, in Advances in Knowledge Discovery and Data Mining, AAAI Pres/ The MIT Press, 1996.

6. Fayyad, U., Piatetsky-Shapiro, G., Smyth, P., The KDD Process for Extracting Useful Knowledge from Volumes of Data, Comunications of the ACM, Vol 39, No. 11, November, 1996.

7. Fayyad U., Piatetsky-Shapiro G., Smyth P., Knowledge Discovery and Data Mining: Towards a Unifying Framework, The Second International Conference on Knowledge Discovery and Data Mining, Portland, Oregon, 1996.

8. Fayyad U., Mining Databases: Towards Algorithms for Knowledge Discovery, Bulletin of the IEEE Computer Society, Vol.21, No. 1, March, 1998.

9. Freitas, A.A., Generic, Set-oriented Primitives to Support Data-parallel Knowledge Discovery in Relational Database Systems, Ph.D. diss.,

http://cswww.essex.ac.uk/SystemsArchitecture/DataMining/alex/thesis.html, 1997.

10. Freitas, A.A., Lavington, S.H., Using SQL Primitives and Parallel DBServers to Speed Up Knowledge Discovery in large relational databases, University of Essex, UK, http:// citeseer.nj.nec.com/cs, 1997.

11. Han, J., Fu, Y., Wang, W., Chiang, J., Zaiane, O., Koperski, K., DBMiner: Interactive Mining of Multiple-Level Knowledge in Relational Databases, ACM SIGMOD, Montreal, Canada, 1996.

12. Han, J., Fu Y., Wang, W., Chiang, J., Koperski, K., Li, D., Lu Y., Rajan, A., Stefanovic, N., Xia, B., Zaiane, O., DBMiner: A System for Mining Knowledge in Large Relational Databases, The second International Conference on Knowledge Discovery & Data Mining, Portland, Oregon, 1996.

13. Han, J., Fu Y., Wang, W., Koperski, K., Zaiane, O., DMQL: A Data Mining Query Language for Relational Databases, SIGMOD 96 Workshop, On research issues on Data Mining and Knowledge Discovery DMKD 96, Montreal, Canada, 1996.

14. Han , J., Chiang, J., Chee, S., Chen, J., Chen, Q., Cheng, S., Gong, W., Kamber , M., Koperski, K., Liu , G., Lu, Y., Stefanovic, N., Winstone, L., Xia, B., Zaiane, O., Zhang, S., Zhu, H., DBMiner: A System for Data Mining in Relational Databases and Data Warehouses, CASCON: Meeting of Minds, Toronto, Canada, 1997.

15. Han, J., Kamber, M., Data Mining Concepts and Techniques, Morgan Kaufmann Publishers, San Francisco, 2001.

16. Han J., Cai Y., Cercone N., Knowledge Discovery in Databases: An Attribute-Oriented Approach, VLDB Conference, Vancouver, Canada, 1992.

17. Han J., Data mining, in J. Urban and P. Dasgupta (eds) Encyclopedia of Distributed Computing, Kluwer Academic Publishers, 1999.

18. Han J., Pei J., Yin Y., Mining Frequent Patterns without Cndidate Generation, ACM SIGMOD, Dallas, Texas, USA, 2000.

19. Imielinski, T., Mannila, H., A Database Perspective on Knowledge Discovery, Communications of the ACM, Vol. 39, No 11, November 1996.

20. Imielinski, T., Virmani, A., Abdulghani, A., Data Mine: Application Programming Interface and Query Language for database Mining, 2º Conference KDD y Data Mining, Portland, Oregon, 1996.

21. Imielinski, T., Virmani, A., MSQL: A Query Language for Database Mining, Data Mining and Knowledge Discovery, Kluwer Academic Publishers, Vol 3, Number 4, pp .373-408, 1999.

22. Klosgen W., Some implementation aspects of a Discovery System, Knowledge Discovery in Databases Workshop, 1993.

23. Meo R., Psaila G., Ceri S., A New SQL-like Operator for Mining Association Rules, VLDB Conference, Bombay, India, 1996.

24. Meo R., Psaila G., Ceri S., An Extension to SQL for Mining Association Rules, Data Mining and Knowledge Discovery, Kluwer Academic Publishers, Vol 2, pp . 195-224, Boston, 1998.

25. Meo R., Psaila G., Ceri S., A Tightly-Coupled Architecture for Data Mining, 14th. International Conference on Data Engineering ICDE98, 1998.

26. Rajamani, K., Cox, A., Iyer, B., Chadha, A., Efficient Mining for Association Rules with Relational Database Systems, International Database Engineering and Aplication Symposium, p. 148-155, 1999.

27. Sarawagi S., Thomas S., Agrawal R., Integrating Association Rule Mining with Relational Database Systems: Alternatives and Implications, ACM SIGMOD, 1998.

28. Sarawagi S., Thomas S., Agrawal R., Integrating Association Rule Mining with Relational Database Systems: Alternatives and

Implications, Data Mining and Knowledge Discovery, Kluwer Academic Publishers, Vol 4, 2000.

29. Sarawagi S., Thomas S., Agrawal R., Integrating Association Rule Mining with Relational Database Systems: Alternatives and Implications, ACM SIGMOD, 1998.

30. Timarán,R., Arquitecturas de Integración del Proceso de Descubrimiento de Conocimiento con Sistemas de Gestión de bases de datos: UN ESTADO DEL ARTE, Ingeniería y Competitividad, Universidad del Valle, Volumen 3, No. 2, Cali, diciembre de 2001.

31. Timarán, R., Nuevos operadores algebraicos y Primitivas SQL para el Descubrimiento de Conocimiento en Bases de Datos, INFORME AVANCE TESIS DOCTORAL, Universidad del Valle, diciembre 2002.

32. Timarán, R., Millán, M., Machuca, F., New Algebraic Operators and SQL Primitives for Mining Association Rules, in proceedings of the IASTED International Conference on Neural Networks and Computational Intelligence (NCI 2003), International Association of Science and Technology for Development, Cancun, Mexico, mayo 2003.

33. Schmuller, Joseph. Aprendiendo UML en 24 horas. Prentice-Hall, 2001

34. Internet - Wikipedia, La Enciclopedia libre- Paradigma Orientado a Objetos, http://es.wikipedia.org/wiki/Java_(lenguaje_de_programaci%C3%B3n). Visitado agosto de 2011.

35. Internet - Look & Feel - Nilo J. González, Madrid, http://personales.ya.com/nimrod/index.html. Visitado agosto de 2011.

36. Internet – InfoNode – Doking Windows – Tabbed Panel, NNL Technology AB. 2009, http://www.infonode.net/. Visitado agosto de 2011.

37. Castro C, Cabrera M,. MATE-KDD: Una Herramienta Genérica Para El Descubrimiento De Reglas De Clasificación Medianamente Acoplada Al SGBD PostgreSQL, SAN JUAN DE PASTO, 2007. Tesis de Pregrado,

Universidad de Nariño. http://biblioteca.udenar.edu.co:8085/bibliotecavirtual/viewer.aspx?&var=70974. Visitado Abril 2012.

38. Booch, Grady; Rumbaugh, James; Jacobson, Ivar. El Lenguaje Unificado de Modelado. Madrid, 1999, Addison Wesley.

39. Booch, Grady; Rumbaugh, James; Jacobson, ivar. El Proceso Unificado de Desarrollo. Madrid, 2000, Addison Wesley.

40. Quinlan, J. Ross. Induction of Decision Trees, Machine Learning, Kluwer Academic Publishers Hingham, MA, USA 1986.

41. Quinlan, J. Ross: C4-5: Programs for Machine Learning, Kluwer Academic Publishers Hingham, MA, USA, 1992.

42. Mehta, M., Agrawal, R., Rissanen. SLIQ: A Fast Scalable Classifier for Data Mining, 1996.

43. Cerquera C., Armero S., Diaz M., Guerrero M.: Implantación De Primitivas Sql Para El Descubrimiento De Reglas De Asociación Y Clasificación Al Interior Del Motor Del Sistema Gestor De Base De Datos PostgreSQL, 2005, Tesis de Pregrado, Universidad de Nariño. http://biblioteca.udenar.edu.co:8085/bibliotecavirtual/viewer.aspx?&var=67436

44. Internet – Wikipedia, La Enciclopedia libre, NetBeans - http://es.wikipedia.org/wiki/NetBeans. Visitado Agosto 2011

45. Internet – Wikipedia, La Enciclopedia libre, JDBC - http://es.wikipedia.org/wiki/JDBC. Visitado Agosto 2011

46. Internet – scribd, El ABC de Jdbc, Otero. Abraham, 2003 . http://es.scribd.com/doc/84530902/El-ABC-Jdbc2. Visitado Agosto 2012

47. Internet - Wikipedia, La Enciclopedia libre, Swing (biblioteca gráfica) http://es.wikipedia.org/wiki/Swing_%28biblioteca_gr%C3%A1fica%29. Visitado agosto 2011.

48. Internet - Look and Feel http://chuwiki.chuidiang.org/index.php?title=Look_and_Feel. Visitado agosto 2011.

49. Timarán,R. Clasificación: una tarea de descubrimiento de conocimiento en bases de datos, San Juan de Pasto, Nariño, Colombia, 2009.

50. Timarán,R. Asociación: una método de descubrimiento de conocimiento en bases de datos, San Juan de Pasto, Nariño, Colombia, 2009.

51. Calderón A, Ramirez I, Alvarado J., Guevara A., TariyKDD: Una herramienta genérica De Descubrimiento De Conocimiento En Bases de Datos débilmente acoplada con El SGBD PostgreSQL", 2007, Tesis de Pregrado, Universidad de Nariño.

52. Internet - Weka 3 - Data Mining with Open Source Machine Learning Software in Java, http://www.cs.waikato.ac.nz/ml/weka/. Visitado agosto 2012

ANEXO

Nuevas implementaciones en PostgresKDD

Implementación Funcion definida por el usuario *convertir_mate().*

Figura A. 1 Implementación Funcion definida por el usuario convertir_mate().

```
CREATE OR REPLACE FUNCTION convertir_mate() RETURNS SETOF varchar AS '
DECLARE
        sql     text DEFAULT '''';
        sql1    text DEFAULT '''';
        cad     text DEFAULT '''';
        cada    text DEFAULT '''';

        rec1    record;
        rec2    record;
        rec3    record;
BEGIN
        sql1 := ''SELECT attname,relnatts FROM pg_class, pg_attribute'';
        sql1 := sql1 || '' WHERE pg_class.relname = ''''kdd_ent'''''';
        sql1 := sql1 || '' AND pg_attribute.attrelid = pg_class.oid'';
        sql1 := sql1 || '' AND attnum > 0 ORDER BY attnum'';

        sql := ''SELECT atributo, valor, discret FROM kdd_values'';

        FOR rec1 IN EXECUTE ''SELECT relname FROM pg_class WHERE relname = ''''tablemate_aux'''''' LOOP
                EXECUTE ''DROP TABLE tablemate_aux'';
        END LOOP;

        EXECUTE ''CREATE TABLE tablemate_aux AS SELECT * FROM tablemate'';

        FOR rec1 IN EXECUTE sql1 LOOP

                FOR rec2 IN EXECUTE sql LOOP

                        IF cast(rec2.atributo as varchar) = cast(rec1.attname as varchar) THEN

                                cad := ''UPDATE tablemate_aux set ''||cast(rec1.attname as varchar)||'' = ''''''||cast(rec2.discret as varchar)||''''''''';
                                cad := cad ||'' WHERE ''||rec1.attname||'' = ''''''||rec2.valor||''''''''';

                                EXECUTE cad;
                        END IF;
                END LOOP;

        END LOOP;

        EXECUTE ''DELETE FROM kdd_clase'';
        EXECUTE ''INSERT INTO kdd_clase SELECT * FROM tablemate_aux'';
        EXECUTE ''DROP TABLE tablemate_aux'';

        RETURN NEXT ''OK'';
        RETURN;

END;'
LANGUAGE 'plpgsql' WITH (isstrict);
```

Modificación a la función definida por el usuario mate_by()

Figura A. 2: Modificación a la Función definida por el usuario mate_by().

```
CREATE OR REPLACE FUNCTION mateby(varchar) RETURNS SETOF varchar AS '
DECLARE
        sql         text DEFAULT '''';
        sql1        text DEFAULT '''';
        cad         text DEFAULT NULL;
        cada        text DEFAULT '''';

        rec1        record;
        rec2        record;
        rec3        record;

        flag_val    integer;
        localset    integer;
        attr        integer;
        active      integer;
        control1    integer;
        control2    integer;
        control3    integer;
        flag        integer;
        i           integer;
        num         integer;
        machete     integer;
BEGIN
        FOR rec1 IN EXECUTE ''SELECT relname AS flag_val FROM pg_class WHERE relname ='''''pg_columna''''''' LOOP
        END LOOP;
        IF rec1.flag_val IS NOT NULL THEN
                EXECUTE ''DROP TABLE pg_columna'';
        END IF;
        EXECUTE ''CREATE TABLE pg_columna(num int2,att bpchar)'';

        ...
        ...
        ...

        EXECUTE ''DROP TABLE pg_columna'';
        EXECUTE ''DROP TABLE pg_pos'';
        EXECUTE ''DROP TABLE pg_att'';
        EXECUTE ''DROP TABLE pg_mate'';

        --Llamado a la función convertir_mate(), que convierte la información de la tabla Tablemate
        --generada por el operador Mate en la fuente de datos de la función entro().
        EXECUTE ''select * from convertir_mate()'';

        RETURN NEXT ''CREADA kdd_clase'';
        RETURN;
END;'
LANGUAGE 'plpgsql' WITH (isstrict);
```

Creación tabla ganancias en función definida por el usuario matetree().

Figura A. 3: Creación tabla ganancias en función definida por el usuario matetree().

```
CREATE OR REPLACE FUNCTION matetree(varchar) RETURNS SETOF varchar AS'
DECLARE
        i               integer;
        numatt  integer;
        nodo            integer;
        ban             integer;
        cp              integer;
        Ent             numeric;
        Ent_clase       numeric;
        Gan             numeric;
        G_min           numeric :=999;

        sql             text DEFAULT '''';
        sql_g           text DEFAULT '''';
        txt             text DEFAULT '''';
        rta             text DEFAULT NULL;

        rec1            record;
        rec2            record;
BEGIN
        EXECUTE ''SELECT * FROM mateby(''''''||$1||'''''')'';
        FOR rec1 IN EXECUTE ''SELECT * FROM entro(''''''||$1||'''''')'' LOOP
                Ent_clase := CAST(rec1.entro as numeric);
        END LOOP;

        ...
        ...
        ...

        sql := ''SELECT attname,attnum FROM pg_class,pg_attribute WHERE ''
                        ||''pg_class.relname=''''kdd_ent'''''
                        || '' AND pg_attribute.attrelid =  pg_class.oid AND attname !=''''''
                        || $1 || '''''' AND attnum >0 ORDER BY attnum'';

                --Creación tabla Ganancias
                FOR rec1 IN EXECUTE ''SELECT relname FROM pg_class WHERE relname = ''''ganancias'''''' LOOP
                        EXECUTE ''DROP TABLE ganancias'';
                END LOOP;

                EXECUTE ''CREATE TABLE ganancias(atributo varchar, clase varchar, ganancia numeric)'';

                FOR rec1 IN EXECUTE sql LOOP

                        EXECUTE ''INSERT INTO pg_pila VALUES(1,0,'''''' || rec1.attname || '''''',-1)'';

                        sql_g := ''SELECT * FROM mate_gain(0,''''''||$1||'''''')'';

                        FOR rec2 IN EXECUTE sql_g LOOP
                                Gan := rec2.mate_gain;
                                --insert a la tabla ganancias
                                EXECUTE ''INSERT INTO ganancias VALUES(''''''' || rec1.attname || ''''''',''''''|| $1 || ''''''',''''''|| Gan ||''''''')'';
                        END LOOP;

                        IF Gan < G_min THEN
                                G_min := Gan;
                                txt := rec1.attname;
                                numatt := rec1.attnum;
                        END IF;

                        EXECUTE ''DELETE FROM pg_pila WHERE num=1'';
                END LOOP;

        ...
        ...
        ...
END;'
LANGUAGE 'plpgsql' WITH (isstrict);
```