

Tipo de artículo: Artículo original

Integrando minería de reglas de asociación en PostgreSQL

Integration association rules mining in PostgreSQL

Alfredo Yunior Montero Oconor^{1*} , <https://orcid.org/0000-0001-8964-8636>

Jose Miguel Reyes Pérez² , <https://orcid.org/0000-0003-3751-0189>

Julio Cesar Diaz Vera³ , <https://orcid.org/0000-0002-1525-8288>

¹ Ingeniero en Ciencias Informáticas (Dirección de Tecnologías y Sistemas). alfredo98@gmail.com

² Ingeniero en Ciencias Informáticas, Profesor Instructor (Dirección de Tecnologías y Sistemas). josemiguel92rp@gmail.com

³ Ingeniero en Telecomunicaciones y electrónica, MsC en Gestión de proyectos Informáticos. Profesor Auxiliar (Departamento de Informática Facultad 3 Universidad de las Ciencias Informáticas). jcdiaz@uci.cu

* Autor para correspondencia: josemiguel92rp@gmail.com

Resumen

El desarrollo de las tecnologías y la informatización de las empresas ha incrementado el cúmulo de información almacenada en las bases de datos dificultando el proceso de análisis de estas manualmente, por lo cual es necesario utilizar técnicas como la minería de datos que faciliten obtener conocimientos a partir de los datos recopilados. En la presente investigación se analizó la técnica de minería de reglas de asociación para integrar un algoritmo al sistema gestor de bases de datos (SGBD) PostgreSQL, debido a las deficiencias de las herramientas libres existentes para realizar el análisis de la información. En ella se desarrollan mecanismos para optimizar el rendimiento del algoritmo implementado con el objetivo de aprovechar las ventajas de PostgreSQL. Además, se comprobó la solución de la investigación mediante la aplicación de las técnicas a una base de datos ficticia y se realizó un experimento para comprobar que el algoritmo integrado al gestor permite aprovechar las potencialidades que brindan otros algoritmos del minado de reglas.

Palabras clave: Minería de Datos, informatización, Reglas de Asociación, PostgreSQL, Gestor de base de datos.

Abstract

The development of technologies and the computerization of companies has increased the accumulation of information stored in databases, making it difficult to analyze them manually, which is why it is necessary to use techniques such as data mining that facilitate obtaining knowledge from the collected data. In the present investigation, the association rules mining technique was analyzed to integrate an algorithm to the PostgreSQL database management system (DBMS), due to the deficiencies of the existing free tools to perform the information analysis. In it, mechanisms are developed to optimize the performance of the implemented algorithm in order to take advantage of PostgreSQL. In addition, the research solution was verified by applying the techniques to a fictitious database and an experiment was carried out to verify that the algorithm integrated into the manager makes it possible to take advantage of the potential offered by other rule mining algorithms.

Keywords: Data Mining, computerization, Association Rules, PostgreSQL, Database Manager system

Recibido: 22/08/2022

Aceptado: 29/10/2022

En línea: 01/11/2022



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional** (CC BY 4.0)

Introducción

La minería de datos es el conjunto de técnicas y tecnologías que permiten explorar grandes bases de datos, de manera automática o semiautomática, con el objetivo de encontrar patrones repetitivos, tendencias o reglas que expliquen el comportamiento de los datos en un determinado contexto. Básicamente, surge para intentar ayudar a comprender el contenido de un repositorio de datos. Con este fin, hace uso de prácticas estadísticas y, en algunos casos, de algoritmos de búsqueda próximos a la Inteligencia Artificial y a las redes neuronales (Rodríguez González, Martínez Trinidad, Carrasco Ochoa, & Ruiz Shulcloper, 2018).

Una parte de la información relevante para la toma de decisiones empresariales se encuentra almacenada en bases de datos relacionales. La minería de datos permite investigar esta información y alcanzar mejor entendimiento de la misma a partir de la determinación de las tendencias y características de los datos. Sin embargo, la mayoría de los gestores de bases de datos (ejemplos son Oracle y PostgreSQL) no consideran a las bases de datos relacionales como fuentes para obtener los datos a los que se les aplicarán los respectivos algoritmos. Se requiere de procesos de transformación de los datos desde su estado original hacia vistas minables que sean manejables por parte de las aplicaciones de minería. El proceso de transformación de los datos puede ser muy complejo y además genera un problema de seguridad al generar una copia de los datos que permanecerá fuera del gestor de bases de datos y por ende escapa a la política de privilegios definida por la institución e instanciada dentro del gestor de bases de datos (Sáenz López, Cortés Martínez, & Betancourt Chávez, 2017).

Gestores de bases de datos como Oracle y SQLServer han incorporado módulos orientados a realizar diferentes tareas de minería solventando las dificultades anteriores. Pero la utilización de estos sistemas es cada vez menos frecuente por parte de las medianas y pequeñas empresas que prefieren optar por alternativas libres para escapar de los altos precios de licencias asociados a los gestores antes mencionados.

PostgreSQL es a día de hoy la más robusta de las alternativas libres. Está considerado el gestor abierto más avanzado del mundo y soporta la mayoría de las especificaciones del estándar SQL1. Pero de momento no integra funcionalidades para aplicar técnicas de minería de datos. De tal forma que cuando se requiere minar información almacenada en el mismo es necesario desencadenar antes un proceso de transformación de los datos para obtener una vista minable que

¹ SQL es un lenguaje de dominio específico utilizado en programación



se ajuste al software de minería correspondiente. Una situación que sin duda coloca en desventaja a las empresas que lo utilizan y que genera una carga de trabajo adicional para los ingenieros de datos responsables de estas tareas.

La minería de las reglas de asociación es un área muy importante dentro de la minería de datos. Es un proceso no supervisado que tiene la finalidad de encontrar implicaciones de la forma $x \Rightarrow y$, que se encuentran en las instancias de base de datos, su principal desarrollo ha sido en el área de los negocios, pero recientes estudios avalan su actualidad e importancia y su aplicación en áreas como bioinformática, medicina y seguridad de redes entre otras (Sáenz López, Cortés Martínez, & Betancourt Chávez, 2017).

Materiales y métodos

Minería de reglas de asociación

La minería de datos es una de las etapas del proceso de Descubrimiento de Conocimiento en Bases de Datos -DCBD que permite descubrir información oculta y útil para la toma de decisiones entre grandes volúmenes de datos. La tarea de Reglas de Asociación ha sido siempre un centro de gran atención, importancia e investigación en el área de minería de datos (TIMARÁN PEREIRA, 2016).

La Minería de Reglas de Asociación es una técnica importante en la Minería de Datos y consiste en encontrar las asociaciones interesantes en forma de relaciones de implicación entre los valores de los atributos de los objetos de un conjunto de datos. Esta técnica emergió en la década de los 90 con una aplicación práctica, el análisis de información de ventas para el mercadeo. (Rodríguez González, Martínez Trinidad, Carrasco Ochoa, Ruiz Shulcloper, 2018).

Un ejemplo de este tipo de colecciones se muestra en la Tabla 1.

Tabla 1. Ejemplo de colección de transacciones

Transacciones	
No.	Productos comprados
1	Leche, Pan
2	Pan, Mantequilla
3	Cerveza
4	Pan, Mantequilla, Leche
5	Pan
6	Pan, Mantequilla, Leche



En este contexto una regla de asociación podría ser "Si un cliente compra pan y leche, entonces también compra mantequilla", formalmente.

$$(pan \wedge leche) \Rightarrow (mantequilla)$$

El interés de una regla de asociación está dado por su soporte y su confianza, entendiéndose por soporte la frecuencia de aparición en la colección de la combinación de productos involucrados en la regla. Ejemplo, para la colección mostrada en la Tabla 1 se tiene que:

$$soporte((pan \wedge leche) \Rightarrow (mantequilla)) = soporte(pan \wedge leche \wedge mantequilla) = \frac{2}{6}$$

Por confianza de una regla entendemos cuánto representa el soporte de la regla, del soporte del antecedente de la regla. Ejemplo, para la colección mostrada en la Tabla 1 se tiene que:

$$confianza((pan \wedge leche) \Rightarrow (mantequilla)) = \frac{soporte(pan \wedge leche \wedge mantequilla)}{soporte(pan \wedge leche)} = \frac{2}{3}$$

Se considera que una regla es interesante si su soporte y su confianza son mayores o iguales que ciertos umbrales de mínimo soporte y mínima confianza especificados (Rodríguez González, Martínez Trinidad, Carrasco Ochoa, Ruiz Shulcloper, 2018).

La ARM es una de las tareas de minería de datos más estudiadas y aplicadas varios estudios se han realizado en diferentes áreas de conocimiento. A continuación, se presentan algunos casos de uso real de las reglas de asociación:

- Medicina
- Ventas al por menor
- Diseño de las experiencia del usuario (UX)
- Entretenimiento

Definiciones asociadas a la MRA

Dentro de las MRA hay términos que son necesarios para su entendimiento como el de soporte y confianza, junto a estos existen otras definiciones que tiene gran relevancia conocer su significado, ejemplos son:



El levantamiento(lev): se define como el grado en el que la confianza es mayor (o menor) a lo esperado(umbral). Esto se refiere a que, para valores mayores a uno, un conjunto aparece una cantidad de veces superior a lo esperado, mientras que, para valores menores a uno, indica que aparece una cantidad de veces menor a lo esperado (Levano Chiroque, 2019). La elevación de $X \rightarrow Y$ es:

$$lev(X \rightarrow Y) = \frac{confianza(X \rightarrow Y)}{soporte}$$

Soporte mínimo: Es el umbral mínimo de soporte, este umbral se fija por el usuario o investigador. Es la mínima probabilidad que una transacción contenga al antecedente X. Se denota por la expresión MinSupp. Esto quiere decir, que se tomará en cuenta los subconjuntos cuyos soportes son al menos mayores que el soporte mínimo. A estos subconjuntos se les denomina itemset frecuentes (Levano Chiroque, 2019).

$$Supp(X \rightarrow Y) \geq MinSupp$$

Algoritmos para el minado de reglas de asociación

Los algoritmos de reglas de asociación tienen como objetivo encontrar relaciones dentro de un conjunto de transacciones, en concreto, ítems o atributos que tienden a ocurrir de forma conjunta

A cada uno de los eventos o elementos que forman parte de una transacción se le conoce como ítem y a un conjunto de ellos itemset. Una transacción puede estar formada por uno o varios ítems, en el caso de ser varios, cada posible subconjunto de ellos es un itemset distinto. Por ejemplo, la transacción $T = \{A, B, C\}$ está formada por 3 ítems (A, B y C) y sus posibles itemsets son: $\{A, B, C\}$, $\{A, B\}$, $\{B, C\}$, $\{A, C\}$, $\{A\}$, $\{B\}$ y $\{C\}$ (Harol Vacca, 2016).

Una regla de asociación se define como una implicación del tipo “si X entonces Y” ($X \Rightarrow Y$), donde X e Y son itemsets o ítems individuales. El lado izquierdo de la regla recibe el nombre de antecedente o left-hand-side (LHS) y el lado derecho el nombre de consecuente o right-hand-side (RHS). Por ejemplo, la regla $\{A, B\} \Rightarrow \{C\}$ significa que, cuando ocurren A y B, también ocurre C.



Existen varios algoritmos diseñados para identificar itemsets frecuentes y reglas de asociación.

- A Priori
- FP-Growth
- Eclat
- EquipAsso

Resultados y discusión

Se han diseñado diferentes algoritmos para obtener los conjuntos de ítems frecuentes en la tarea de Asociación, dentro de los cuales están: A Priori, Eclat y FP-Growth. Sin embargo, todos ellos se han implementado aisladamente y por fuera de los motores de bases de datos.

EquipAsso es un algoritmo que se basa en los operadores del álgebra relacional Associator y EquipKeep para el cálculo de conjuntos de ítems frecuentes. Este hecho facilita su integración al interior de cualquier SGBD, acoplado la tarea de Asociación de una manera fuerte y favorece la aplicación de técnicas de optimización de consultas para mejorar su rendimiento.

Descripción e Implementación del Algoritmo EquipAsso

En el primer paso del algoritmo se cuenta el número de ocurrencias de cada ítem para determinar los 1-conjuntos de ítems frecuentes L_1 . En el subsiguiente paso, se aplica el operador EquipKeep 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 generar todos los conjuntos de ítems tamaño 2 ($I_s = 2$) 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 en la relación R' (Andrés O. Calderón Romero*, 2019).

Tabla 2. Algoritmo EquipAsso.

Entradas: transacciones de una base de datos ; min sop

Salidas: L , conjuntos de elementos frecuentes de la base de datos D .

$L_1 = (1 - \text{conjunto de ítems frecuentes})$

Foral transacciones $T \in D$ do begin

//se aplica el operador EquipKeep

$R = x_{L_1}$



```
K = 2
//genera todos los conjuntos de ítems posibles
R1 =  $\alpha_{k1q}(R) = \{U_{all} X1 \mid Xi \subseteq Ti\}$ 
End
// conjuntos de ítems frecuentes.
L = {count (R1) | count  $\leq$  minsup}
```

La ventaja de esta implementación es que facilita su integración al interior de cualquier SGBD, acoplando la tarea de Asociación de una manera fuerte. Debido a que el algoritmo es ejecutado conjuntamente con los datos en el SGBD, la ventaja potencial de este enfoque es que resuelve los problemas de escalabilidad y facilita la aplicación de técnicas de optimización de consultas (Andrés O. Calderón Romero*, 2019).

Utilizando las primitivas SQL para minar reglas de Asociación, el algoritmo EquipAsso de la tabla 18, se implementa con la cláusula SELECT de la siguiente manera:

```
SELECT <ListaAtributosTablaDatos>, count(*) AS soporte INTO R'
FROM D
EQUIPKEEP ON L1
ASSOCIATOR RANGE k UNTIL g
GROUP BY <ListaAtrivutosTablaDatos> HAVING count(*) >= minsup
```

Aplicación del Algoritmo EquipAsso

Sea la tabla booleana Transacción (Tid, Item_1, Item_2, Item_3, Item_4), la cual se indica en la tabla 1.

Tabla 3. Relación de Transacción.

Tid	Item_1	Item_2	Item_3	Item_4
100	1	1	0	0
200	0	1	1	1
300	1	1	1	0
400	0	1	1	1
500	0	0	1	1



Suponiendo que ya se han calculado los conjuntos de ítems frecuentes de tamaño 1 con un soporte igual a 3, los cuales son {Item_2}, {Item_3}, {Item_4}. Encontrar los conjuntos de ítems frecuentes de tamaño 2 y 3 formados por los atributos Item_1, Item_2, Item_3, Item_4 y almacenar los resultados en la tabla Frecuentes, utilizando el algoritmo EquipAsso:

Tabla 4. Resultado del algoritmo SQL-EquipAsso.

Item_1	Item_2	Item_3	Item_4	Soporte
null	1	1	null	3
null	null	1	1	3

Integración del algoritmo al SGBD PostgreSQL

A partir de la versión 9.1 PostgreSQL brinda facilidades para que los usuarios puedan crear, cargar, actualizar y administrar extensiones utilizando el objeto de base de datos EXTENSION. Entre las ventajas de esta funcionalidad se encuentra, que en lugar de ejecutar un script SQL para cargar objetos que estén “separados” en su base de datos, se tendrá la extensión como un paquete que contendrá todos los objetos definidos en ella, lo cual trae gran beneficio al actualizarla o eliminarla ya que por ejemplo se pueden eliminar todos los objetos utilizando DROP EXTENSION sin necesidad de especificar cada uno de los objetos definidos dentro de la extensión. Se cuenta con un repositorio para obtener extensiones y contribuir con estas (Anthony R Sotolongo, 2016).

La integración del algoritmo se va a realizar mediante la creación de una extensión por las ventajas que PostgreSQL brinda para su creación.

Validación del algoritmo EquipAsso como generador de reglas de asociación

El conjunto de datos utilizado para las pruebas son datos ficticios de un supermercado durante un periodo determinado. El conjunto de datos contiene 10.757 diferentes productos. Para cada conjunto de datos se realizó pre-procesamiento y transformación de datos con el fin de eliminar los productos repetidos en cada transacción y transformar las tablas a un modelo simple.

Tabla 5. Descripción de los conjuntos de datos minados.

Nomenclatura	Número de registros	Número de transacciones	Promedio ítems por Transacción
BD1	555.123	85.692	7
BD2	194.337	40.256	5



BD3	97.824	10.731	10
-----	--------	--------	----

Se evaluó el rendimiento de los algoritmos Apriori, FP-Growth y EquipAsso, comparando la cantidad de reglas generadas y los tiempos de respuesta, para diferentes soportes mínimos. Los resultados de la evaluación del tiempo de ejecución de estos algoritmos, aplicados a los conjuntos de datos BD1, BD2 y BD3, se pueden observar en las tablas 25,26 y 27 respectivamente.

Tabla 6. Resultados obtenidos para BD1.

BD1.						
Soporte %	Tiempo(ms)			Número de Reglas		
	A Priori	FP-Growth	EquipAsso	A Priori	FP-Growth	EquipAsso
4.15	750	166	85	5684	5980	5910
4.75	362	162	82	4890	5820	5780
5.35	365	164	83	5047	6102	5864
5.95	120	159	80	5218	5423	5325

Tabla 7. Resultados obtenidos para BD2.

BD2.						
Soporte %	Tiempo(ms)			Número de Reglas		
	A Priori	FP-Growth	EquipAsso	A Priori	FP-Growth	EquipAsso
1.90	268	66	29	2570	2806	2918
2.00	265	64	29	2481	2697	2706
2.10	132	63	27	2081	2574	2505
2.30	45	61	27	1800	2290	2394

Tabla 8. Resultados obtenidos para BD3.

BD3.						
Soporte %	Tiempo(ms)			Número de Reglas		
	A Priori	FP-Growth	EquipAsso	A Priori	FP-Growth	EquipAsso
3.00	525	28	15	957	1665	1405
4.00	182	26	14	846	1456	1395
5.00	105	25	13	625	1390	1360
6.00	53	24	13	600	1302	1356

Analizando el tiempo de ejecución y la cantidad de reglas generadas para los conjuntos de datos BD1, BD2 y BD3; en el caso de los algoritmos FP-Growth y EquipAsso (tablas 25 y 26) con soportes más bajos, el comportamiento de estos algoritmos sigue siendo similar lo que reafirma al algoritmo EquipAsso como solución generadora de reglas de



asociación, en el caso particular de A priori se ve afectado significativamente a medida que disminuye el soporte lo que expone su desventaja en cuanto a eficiencia con la comunidad de las ARM.(tablas 25,26 y 27)

Conclusiones

Actualmente se cuenta con un algoritmo que permite calcular los conjuntos de ítems frecuentes en la tarea de Asociación sin generar conjuntos candidatos. Este algoritmo denominado EquipAsso genera el conjunto de ítems frecuentes directamente en cada tupla de una relación ya que se basa para su cálculo en dos operadores del álgebra relacional para minería de datos: Associator y EquipKeep. Esto facilita la integración fuerte de la tarea de Asociación con un Sistema de Gestión de Bases de Datos, al extender el lenguaje SQL con las primitivas Associator Range y EquipKeep On que implementan estos operadores y favorece la aplicación de técnicas de optimización de consultas para mejorar su rendimiento.

Como resultado de las pruebas realizadas, se puede observar que los algoritmos EquipAsso y FP-Growth tienen tiempos de ejecución y resultados semejantes. Con respecto a A Priori se puede apreciar que a medida que se disminuye el soporte sus tiempos de ejecución se incrementan hasta llegar a límites incomparables con respecto a EquipAsso y FP-Growth.

Para soportes bajos, donde la cantidad de itemsets frecuentes aumenta y lo mismo su tamaño, EquipAsso tuvo un mejor desempeño que FP-Growth. En soportes altos, no existe una diferencia representativa entre el rendimiento de los algoritmos FP-Growth y EquipAsso.

Conflictos de intereses

Los autores no poseen conflictos de intereses.

Contribución de los autores

1. Conceptualización: Alfredo Yunior Montero Oconor, Jose Miguel Reyes Pérez, Julio Cesar Diaz Vera.
2. Curación de datos: Alfredo Yunior Montero Oconor.
3. Análisis formal: Alfredo Yunior Montero Oconor.
4. Adquisición de fondos: Alfredo Yunior Montero Oconor.



5. Investigación: Alfredo Yunior Montero Oconor, Jose Miguel Reyes Pérez
6. Metodología: Alfredo Yunior Montero Oconor, Jose Miguel Reyes Pérez
7. Recursos: José Miguel Reyes Pérez, Julio Cesar Diaz Vera.
8. Software: Alfredo Yunior Montero Oconor.
9. Supervisión: Alfredo Yunior Montero Oconor.
10. Validación: Jose Miguel Reyes Pérez, Julio Cesar Diaz Vera.
11. Visualización: Jose Miguel Reyes Pérez, Julio Cesar Diaz Vera.
12. Redacción – borrador original: Alfredo Yunior Montero Oconor, Jose Miguel Reyes Pérez, Julio Cesar Diaz Vera.
13. Redacción – revisión y edición: Alfredo Yunior Montero Oconor, Jose Miguel Reyes Pérez, Julio Cesar Diaz Vera.

Financiamiento

La investigación no requirió fuente de financiamiento externa.

Referencias

- A. Reyes-Naval, 3. A.-F.-L. (2017). Minería de datos aplicada para la identificación de factores de riesgo en alumno. México: ISSN.
- AL-Zawaidah, F. H., Jbara, Y. H., & Abu-Zanona, M. A.-A. (2011). An Improved Algorithm for Mining Association Rules in Large Databases. Jordan - Saudi Arabia: ISSN.
- AMARIS, M. E. (2003). LA CONTRIBUCIÓN DE LAS REGLAS DE ASOCIACIÓN A LA MINERÍA DE DATOS. Colombia: TECNURA.
- Andrés O. Calderón Romero.*, I. R. (2019). Análisis de desempeño de EquipAsso: Un algoritmo para el cálculo de Itemsets frecuentes basado en operadores algebraicos relacionales. San Juan de Pasto, Colombia: *Universidad de Nariño.
- Ansel Yoan Rodríguez González, J. F. (2009). Minería de Reglas de Asociación sobre Datos Mezclados . Puebla, México.: Coordinación de Ciencias Computacionales INAOE .
- Anthony R Sotolongo, .. A. (2016). INTEGRACIÓN DE LOS ALGORITMOS DE MINERÍA DE DATOS 1R, PRISM E ID3 A POSTGRESQL. Ciudad de la Habana, Cuba: Universidad de las Ciencias Informáticas.
- Bohórquez, M. O. (2017). MÉTODO DE REGLAS DE ASOCIACIÓN PARA EL ANÁLISIS DE AFINIDAD . Barranquilla – Colombia: Universidad de la Costa CU.



- Casillas, G. C. (2018). USO DE ANÁLISIS ASOCIATIVO EN ALGORITMOS DE APRENDIZAJE. Madrid: UNIVERSIDAD AUTÓNOMA DE MADRID.
- Diana-Lucia Miholca, *. G. (2018). A new incremental relational association rules mining approach. Romania: ScienceDirect.
- Harol Vacca, J. A. (2016). Una investigación entre algoritmos de reglas de asociación. En D. M. Julio Andrea Rocha H.1, *Visión Electrónica* (págs. 210-217). Bogotá Colombia: Visión Electrónica.
- Isam Kareem THAJEEL1, O. N.-S. (2017). IMPROVING IDSs ALERTS TO IMPROVE HIGH QUALITY NETWORK SECURITY BY USING DATA MINING TECHNIQUE. Mustansiriyah, Iraq: . College Of Science-University Of Mustansiriyah.
- Jordan Bianchi, M., & Capaldo Amaral, D. (2020). A systematic review of association rules in project management: opportunities for hybrid models. São Paulo: Escola de Engenharia de São Carlos, Universidade de São Paulo - USP, São Carlos, SP, Brasil.
- Levano Chiroque, F. T. (2019). Identificación de las reglas de asociación utilizando los algoritmos secuenciales SPADE Y CSP. LIMA: PERÚ.
- Lucas, J. P. (2010). MÉTODOS DE CLASIFICACIÓN BASADOS EN ASOCIACIÓN APLICADOS A SISTEMAS DE RECOMENDACIÓN. Salamanca: Universidad de Salamanca.
- Manjit Kaur, U. G. (2015). Advanced Eclat Algorithm for Frequent Itemsets Generation. Phagwara, Punjab, India: Research India Publications.
- MONSALVE, T. E. (2011). DESARROLLO Y ANÁLISIS DE LA UTILIZACIÓN DE ALGORITMOS DE MINERÍA DE DATOS PARA LA BÚSQUEDA DE ANOMALÍAS Y PATRONES SECUENCIALES EN MINERÍA DE PROCESOS. Santiago de Chile: PONTIFICIA UNIVERSIDAD CATÓLICA DE CHILE .
- Orozco Bohórquez, M. (2017). MÉTODO DE REGLAS DE ASOCIACIÓN PARA EL ANÁLISIS DE AFINIDAD . Barranquilla – Colombia : Universidad de la Costa CUC .
- P. Chausa Fernández1, E. G. (2017). Extracción de reglas de asociación en una base de datos clínicos de pacientes con VIH/SIDA. Madrid: , Universidad Politécnica de Madrid.
- Puigmartí, E. L. (2017). Análisis Catálogos Robustos desde perspectivas de la minería de reglas de asociación. Elche: Universidad Miguel Hernández de Elche.
- Rodríguez González, A. Y., Martínez Trinidad, J. F., Carrasco Ochoa, J. A., & Ruiz Shulcloper, J. (2018). Minería de Reglas de Asociación sobre Datos Mezclados. Puebla, México: Coordinación de Ciencias Computacionales INAOE.
- Sáenz López, A., Cortés Martínez, F., & Betancourt Chávez, J. R. (2017). Reglas de asociación en una Base de datos del área médica. *Revista de Arquitectura e Ingeniería*, . 1-8.



- Sanchez, D. A. (2007). Versión paralela dinámica del algoritmo Apriori Implementada en plataformas heterogéneas de ejecución , y su posible generalización para otros contextos. Bogotá: Universidad de los Andes.
- Segura Delgado, L. A. (2021). Estudio y Diseño de técnicas para la Extracción de Reglas de Asociación Temporales. Granada: Universidad de Granada.
- TIMARÁN PEREIRA, R. (2016). EquipAsso: an algorithm for discovery large itemsets without candidate generation. Manizales: Universidad de Manizales.
- VARGAS, L. A., FARFÁN, J. H RODRÍGUEZ, M. E., TAPIA, M. A., PAREDES, J. C., LLAMPA, A. F., . . . MOGRO, N. A. (2018). IMPLEMENTACIÓN DE TÉCNICAS ESPECÍFICAS DE MINERÍA DE DATOS EN APLICACIONES WEB CON MOTORES DE BASE DE DATOS RELACIONALES. Jujuy: Facultad de Ciencias Agrarias, Universidad Nacional de Jujuy (U.N.Ju.) .
- VARGAS, L. A., FARFÁN, J. H RODRÍGUEZ, M. E., TAPIA, M. A., PAREDES, J. C., LLAMPA, A. F., . . . MOGRO, N. A. (2018). IMPLEMENTACIÓN DE TÉCNICAS ESPECÍFICAS DE MINERÍA DE DATOS EN APLICACIONES WEB CON MOTORES DE BASE DE DATOS RELACIONALES . Jujuy: Universidad Nacional de Jujuy (U.N.Ju.) .
- Wang, H., & Zaniolo, C. (2021). ATLaS: A Native Extension of SQL for Data Mining. japan: IBM.
- Xiaomei Yu, H. W. (2016). Improvement of the Eclat Algorithm Based on Support in Frequent Itemset Mining . China: JOURNAL OF COMPUTERS.
- Yadira Robles Aranda. (2016). Algoritmos de minería de datos: Árboles de decisión y reglas de inducción integrados a PostgreSQL. La Habana: Universidad de las Ciencias Informáticas.

