

Minería de datos espacial en la agricultura en Latinoamérica - Una aproximación conceptual

Andrés-Felipe Gil-Torres¹

Aura-Liliana Monroy-García²

Juan-Sebastián González-Sanabria³

Fecha de recepción: 3 de marzo de 2020

Fecha de aprobación: 19 de abril de 2020

Resumen

Debido al aumento en el uso de SIG, es necesario conocer técnicas complementarias como la minería de datos espaciales. Este documento es una revisión de algunas de las técnicas existentes y cuáles proporcionan mayores beneficios, revelando tendencias en su aplicación en el área de la agricultura. Además, con base en el hecho de que dentro de esta área se manipulan variables, se presentan las herramientas que facilitan el proceso de toma de decisiones en el área en mención, proporcionando el resultado de la evaluación de los datos disponibles.

Palabras clave: agricultura; minería de datos espaciales; sistemas de información geográfica.

¹ Universidad Pedagógica y Tecnológica de Colombia (Tunja-Boyacá, Colombia). andres.gil01@uptc.edu.co.

² Universidad Pedagógica y Tecnológica de Colombia (Tunja-Boyacá, Colombia). aura.monroy@uptc.edu.co.

³ M.Sc. Universidad Pedagógica y Tecnológica de Colombia (Tunja-Boyacá, Colombia). juansebastian.gonzalez@uptc.edu.co. ORCID: [0000-0002-1024-6077](https://orcid.org/0000-0002-1024-6077)

Spatial Data Mining in Agriculture in Latin America - A Conceptual Approach

Abstract

Due to the increase in the use of GIS, it is necessary to know complementary techniques such as spatial data mining. This paper is a review of some of the existing techniques, as well as which of these provide greater benefits, revealing trends in their application in agriculture. Additionally, because in this area several variables are manipulated, tools are presented to facilitate the making decision process, by providing the result of evaluating the available data.

Keywords: agriculture; geographical information systems; spatial data mining.

Para citar este artículo:

Gil-Torres, A.-F., Monroy-García, A.-L., & González-Sanabria, J.-S. (2020). Minería de datos espacial en la agricultura en Latinoamérica - Una aproximación conceptual. *Pensamiento y Acción*, 28, 19-33.

Esta obra está bajo licencia internacional Creative Commons Reconocimiento 4.0



Introducción

El desarrollo de nuevas tecnologías de comunicación ha llevado al aumento en la generación de datos, en especial de tipo geográfico, debido al auge en la implementación de sistemas de georreferenciación (Gonzalez & Pérez, 2013). Esto, aunado a que dentro del entorno empresarial se ha incrementado el interés por el conocimiento obtenido a partir de la información geográfica, dado el valor agregado que brinda con respecto al análisis de clientes y obtención de conocimiento (Dueñas-Reyes, 2009), ha convertido a las bases de datos geográficos en una fuente importante para la toma de decisiones y la planeación estratégica dentro de las organizaciones.

Con el fin de obtener mayores beneficios en el análisis de datos geográficos, surge la minería de datos espacial, la cual permite caracterizar las dimensiones de espacio y tiempo con el propósito de realizar descubrimiento de conocimiento más acertado (Dueñas-Reyes, 2009). El objetivo de la minería de datos espacial es permitir el hallazgo automatizado de patrones inesperados y modelos ocultos (Herrera-Parra, 2006) que, al cumplirse, permiten el análisis automático mediante la implementación de algoritmos. Esto brinda la posibilidad de buscar correlaciones no evidentes y potencialmente útiles entre objetos geográficos (Aljure & Agudelo, 2011), lo que resulta bastante útil en diferentes campos empresariales.

La minería de datos es un área que posee numerosas técnicas para realizar el conjunto de actividades que la comprenden, éstas se clasifican en dos grandes categorías: predictivas y descriptivas. Las técnicas predictivas especifican el modelo para los datos con base en un conocimiento teórico previo, en el cual se busca realizar predicciones del valor de un atributo partiendo de las relaciones de datos conocidos. Las técnicas descriptivas no requieren de variables ni modelos previos de datos, intentan describir el comportamiento de los datos y las relaciones encontradas, los modelos se crean automáticamente partiendo del reconocimiento de patrones (Herrera-Parra, 2006).

En la Tabla 1 se presenta una breve descripción de las principales técnicas que se aplican.

Tabla 1. Descripción de las técnicas de Minería de Datos.

Técnica	Nombre	Descripción
Predictivas	Series temporales	Se parte de una serie de comportamientos históricos y se modelan series, tendencias, ciclos y estaciones para realizar predicciones.
	Redes bayesianas	Representan posibles sucesos o consecuencias mediante un grafo de probabilidades condicionales, el cual permite establecer relaciones causales y efectuar predicciones.
	Árboles de decisión	Presentan de forma visual las reglas de decisión, partiendo de datos históricos, su gran ventaja es la facilidad de interpretación.
	Redes neuronales	Imitan la estructura cerebral en relación con las neuronas y sus conexiones, buscando crear modelos artificiales para la solución de problemas mediante técnicas algorítmicas tradicionales (Aluja, 2001).
	Algoritmos genéticos	Métodos adaptativos que pueden usarse para resolver problemas de búsqueda y optimización. Son funciones matemáticas o rutinas de software que toman como entrada los ejemplares y retornan como salida cuáles de ellos deben producir descendencia para la nueva generación (Alfaro, 2015a).
	Regresión	Técnica estadística que permite cuantificar la relación entre variables.
	Análisis de la varianza y covarianza	Medidas estadísticas, la primera mide la dispersión de los valores respecto a un valor central (media), la segunda es un indicador de la relación entre variables.
Descriptivas	Clustering	Técnica de agrupamiento de acuerdo con un criterio. Busca relación entre variables descriptivas y permite una descripción clara de un grupo de datos complejos.
	Segmentación	Clasificación de los datos en grupos específicos, incluye un aprendizaje no supervisado.
	Asociación y dependencia	También conocido como análisis exploratorio. La asociación se refiere a una alta frecuencia en la aparición de dos valores relacionados y la dependencia a que el valor de un atributo varía en relación con otros atributos (Alfaro, 2015b).
	Escalamiento multidimensional	Es muy importante en el reconocimiento de patrones, debido a que permite identificar la estructura de los datos y la extracción de información relevante del objeto de estudio (Aguirre, 2010).

Al finalizar el proceso de descubrimiento del conocimiento (KDD, por las siglas en inglés de Knowledge Discovery in Databases), se espera que los resultados cumplan con ciertas propiedades deseables para el conocimiento extraído, las cuales, de acuerdo con Osorio (2009), son:

- Válido: que los patrones generados posean coherencia y aplicabilidad entre los datos históricos y los nuevos, su resultado es preciso en ambos casos.
- Novedoso: que su aporte sea algo desconocido e información diferente a la que ya se conocía, tanto para el sistema como para el usuario.

- Potencialmente útil: que la información resultante sea verdaderamente beneficiosa para el usuario.
- Comprensible: que los patrones obtenidos del proceso de KDD, sean fáciles de interpretar, revisar y validar.

Por lo anterior, es importante conocer las técnicas existentes para la minería de datos espaciales y cuáles de éstas proveen mayores beneficios. El desarrollo de esta investigación permite dar a conocer las tendencias en la aplicación de minería de datos espacial, así como identificar los campos empresariales en los que ésta ha tenido éxito, con especial interés en el área de la agricultura. Dentro de esta área se manipulan diferentes variables que, al ser analizadas, facilitarán el proceso de toma de decisiones, por el resultado que se obtiene de la evaluación de los datos disponibles.

Minería de Datos Espacial (MDE)

Los datos espaciales han sufrido un aumento en cuanto a volumen de almacenamiento, complejidad y dimensión, por lo que se ha hecho necesaria la aplicación de métodos eficaces para la extracción de información. Como respuesta, la MDE ha proporcionado herramientas para mejorar los métodos de análisis espacial tradicional (Aljure & Agudelo, 2011; Mennis & Guo, 2009).

La MDE es la aplicación de algoritmos que buscan información existente en una base de datos espacial que no es evidenciable, pero provee información válida, novedosa y útil. La consecución de dicha información se realiza por medio de diferentes técnicas de minería de datos como lo son: agrupamiento, caracterización espacial, co-localización y detección de tendencias espaciales (Mennis & Guo, 2009).

Dentro de la MDE se encuentran cuatro tareas importantes (Aljure & Agudelo, 2011), provenientes de diferentes áreas de la computación, cada una abarca múltiples métodos para el alcance de estas tareas:

1) Clasificación espacial y predicción. Esta tarea busca la agrupación de datos en clases determinadas por patrones identificados en su contenido. La clasificación se configura de acuerdo con un conjunto de datos de entrenamiento

que se encarga de diseñar el modelo de clasificación y los datos de validación para optimizar la configuración. Se utiliza también un conjunto de datos que provee la aplicación de pruebas para medir el desempeño del modelo; esta clasificación es llamada “Clasificación supervisada”.

2) Reglas de asociación espacial. Permiten la identificación de las reglas de asociación de un conjunto de datos con los predicados, principalmente están orientadas a la identificación de patrones entre los objetos involucrados en las BDE. Estas reglas expresan diferentes relaciones topológicas como la disyunción, intersección, adyacencia, sobreposición, vecindad e igualdad.

3) Agrupamiento espacial. El agrupamiento o clustering es ampliamente utilizado en el análisis de datos que reúnen características similares entre grupos y difieren de otros. Existen dos formas de realizar esta agrupación: por separación y por jerarquía; la primera divide un conjunto de datos en una serie de grupos que no se solapan, los elementos son asignados al grupo basado en una medida de semejanza o proximidad; mientras que la segunda organiza los datos en una secuencia de particiones o agrupaciones, haciendo uso del método de Ward.

4) Geovisualización. Se refiere al desarrollo de la teoría y los métodos para facilitar la construcción del conocimiento a través de la exploración visual y el análisis de datos geoespaciales, así como la implementación de herramientas visuales para la recuperación posterior, síntesis, comunicación y uso de conocimiento. Esta tarea se diferencia de la cartografía porque se centra en el desarrollo de mapas altamente interactivos y herramientas para la explotación de datos, generación de hipótesis y construcción de conocimiento.

A continuación, se describen las diferentes técnicas de minería de datos espacial que serán objeto de investigación.

1) Caracterización espacial. Se conoce como clasificación supervisada porque necesita configurar, optimizar y evaluar el modelo de clasificación partiendo de un conjunto de datos de prueba. La caracterización espacial busca la agrupación de objetos en clases o categorías de acuerdo con sus propiedades. Algunos de los métodos son los árboles de decisiones que se utilizan para el análisis y predicción

de comportamientos espaciales, redes neuronales artificiales, funciones lineares discriminantes y métodos de vecindad cercana (Mennis & Guo, 2009).

En este proceso, adicional a las propiedades de los objetos geográficos, también se tienen en cuenta las propiedades de sus vecinos, pertenezcan o no a la misma clase. La función que realiza el algoritmo de clasificación es extraer los atributos relevantes de un objeto para compararlos con las propiedades de las diferentes clases a las que puede pertenecer el objeto (Sivakumar & Prakaash, 2019).

2) Co-localización. Es usada en la representación de conjuntos de características booleanas que ocurren regularmente con gran proximidad geográfica. Un ejemplo serían las estaciones de gasolina junto a las vías principales, detectar servicios con alta frecuencia de requerimiento por los usuarios.

La aplicación de esta técnica presenta dificultades en la búsqueda de patrones de co-localización al implementar algoritmos de minería de reglas de asociación tradicional, debido a que éstas no utilizan el término transacción (Wang et al., 2009). La transacción se define en torno a una instancia de función espacial.

Por lo general, una mejor solución en la búsqueda de patrones de co-localización es mediante el uso de joins espaciales y de términos como vecindad (Sundaram et al., 2012).

3) Clustering espacial. Es la asociación de objetos espaciales en grupos con un alto grado de similitud denominados “clusters”, que difieren bastante de las características de los objetos pertenecientes a otros clusters (Shekhar et al., 2008). Esta técnica se conoce como aprendizaje no supervisado porque no necesita de conjuntos de datos para entrenamiento ni prueba, además, es reconocida dentro del campo de la estadística. En pocas palabras, lo que busca es determinar grupos de alta densidad partiendo de un conjunto de puntos distribuidos de forma no uniforme (Shekhar & Chawla, 2003).

Se trabajan diferentes métodos dentro de esta técnica, los cuales se pueden clasificar en 4 grupos:

- De partición: los puntos son redistribuidos por diferentes clústeres hasta encontrar un criterio definido para detenerse; se utilizan para formas esféricas.

Ejemplo: el algoritmo K-Means, PAM (por las siglas en inglés de Partitioning Around Medoid), Agrupamiento para aplicaciones de gran tamaño (CLARA) y Agrupamiento para aplicaciones de gran tamaño basado en búsquedas aleatorias (CLARANS).

- De jerarquía: partiendo de un clúster simple, el conjunto de datos es descompuesto jerárquicamente hasta encontrar un criterio para detenerse. Se obtiene como resultado un árbol de clústeres denominado “dendograms”. Algunos algoritmos pertenecientes a esta categoría son: Reducción iterativa balanceada, Clustering usando jerarquías (BIRCH), Clustering usando representantes (CURE) y Clustering robusto usando enlaces (ROCK).
- Basados en densidad: consideran los clústeres como regiones densas de objetos que luego son separadas en regiones menos densas (realiza filtros por ruido y valores atípicos). Los algoritmos más importantes son: Agrupación espacial basada en densidad de aplicaciones con ruido (DBSCAN) y Agrupamiento basado en densidad (DENCLUE).
- Basados en red o cuadrícula: representan el espacio en un número finito de celdas y la que posee mayor número de puntos es considerada como densa. Ejemplos de algoritmos para esta categoría: métodos basados en cuadrículas de información estadística (STING), STING+, WaveCluster, BANG-clustering y Clustering in quest (CLIQUE) (Shekhar & Chawla, 2003; Sumathi & Geetha, 2008).

4) Detección de Tendencias Espaciales. Herrera-Parra (2006) señala que:

Una tendencia espacial ha sido definida como un cambio regular de uno o más atributos espaciales cuando se aleja de un objeto inicial dado. Se utilizan los caminos de vecindad iniciando desde un objeto o para modelar el movimiento y se realiza un análisis de regresión en los valores del atributo respectivo para los objetos de un camino de vecindad para describir la regularidad del cambio.

Minería de Datos Espacial en la agricultura

En el presente apartado se exponen los casos más relevantes de aplicación de la Minería de Datos Espacial en la Agricultura, con el fin de evaluar los usos y posibles beneficios de su aplicación.

Caso 1 - China

China es uno de los países que más se ha preocupado por la utilización de técnicas de minería de datos espacial para la optimización de cultivos como el maíz, en los cuales se han aplicado algoritmos de series de tiempo para la predicción de su rendimiento.

La predicción es desarrollada con base en los datos obtenidos en experimentos de un campo durante seis años, apoyados en datos GPS para la elección de las muestras que se evaluarían posteriormente (Cao et al., 2013). Por otro lado, el rendimiento de maíz es relativamente estable, lo que permite tener mayor precisión y completitud en la investigación. El uso de series espacio-temporales es especialmente útil por los cambios en la tierra y los factores que influyen en el rendimiento del maíz, además, los métodos tradicionales no tienen en cuenta la influencia de la fertilidad del suelo respecto a su ubicación geográfica, por lo que se hace necesaria la aplicación de técnicas de minería de datos espacial.

Teniendo en cuenta los datos del periodo 2004-2009 sobre campos de maíz, se hizo una evaluación por medio de series de tiempo, redes neuronales y SIG, con el fin de obtener la distribución espacial de los diferentes factores que influyen en el rendimiento de los cultivos. Los resultados que se obtuvieron permiten afirmar que el valor estimado de la minería de datos con el método espacio-temporal y el valor real del rendimiento de maíz eran muy similares (Fig. 1), y demuestran un error del 5% al comparar las predicciones de la producción de maíz entre 2004 y 2009 y los datos reales.




Fig. 1. Comparación entre valor predicho (en negro) y el real (en rojo). Fuente: Cao et al. (2013)

Tabla 2. Resultados Caso de estudio Cultivos de Maíz. Fuente: Cao et al. (2013).

Año	Valor real	Valor predicho	Error
2004	4813	5011	0,041
2005	5120	5214	0,016
2006	5287	5162	-0.023
2007	5394	5506	0,021
2008	5034	5143	0,021
2009	4989	5032	0,008

Caso 2 - India

En India, un país donde más de dos terceras partes de la población habitan en la zona rural, existe una búsqueda constante por aumentar la eficiencia en la producción de cultivos. Una de las tareas que realizan los agricultores dentro de este proceso es el uso de plaguicidas, pero se conoce que un uso excesivo de éstos es perjudicial para el equilibrio de la naturaleza y de los cultivos. Con el fin de realizar un buen control de plagas y disminuir el uso de pesticidas, se realizó un modelo y un entorno de prueba de minería de datos espacial, implementando los algoritmos de clustering jerárquico y de reglas de asociación. Esto para obtener la correlación y el patrón oculto entre los cultivos, el suelo, los fertilizantes, el clima, las plagas, los insectos y los plaguicidas aplicados en cultivos de arroz, algodón y semillas oleaginosas.

Al finalizar, se obtuvo un framework que es útil para la optimización del uso de pesticidas en el que se incluyen tres factores importantes: la exploración de plagas, uso de plaguicidas y datos meteorológicos. A futuro, se piensa mostrar estos resultados gráficamente, para que puedan ser fácilmente utilizados por un usuario final (Tripathy, Adinarayana & Sudharsan, 2009).

Caso 3 - Peeters

Por otro lado, Peeters (2015) se ha preocupado por la utilización de información espacial para obtener estadísticas en la clasificación de árboles de huerto, tarea que realizó con base en la minería de datos espacial, específicamente por clustering e implementando el algoritmo k-means. El desarrollo de su trabajo está orientado a la optimización en el manejo de los cultivos, analizando la variabilidad espacial presente en éstos y en su entorno por medio de un método de agrupación espacial (clustering) multivariable que permita conocer las condiciones ideales para dicho manejo, así como las características y sus relaciones espaciales (Peeters et al., 2015).

Caso 4 - Clasificación del Suelo

La agricultura es la columna vertebral de la economía en cualquier país. Para lograr una buena cosecha se requiere realizar inversiones en recursos hídricos y obtener el capital para comprar semillas, fertilizantes y pesticidas; además, factores como el tipo de suelo, tipo de cultivo y el clima influyen en el rendimiento de los cultivos.

Mediante este proyecto, se diseña un modelo para la clasificación del suelo con el cual se contribuye a la evaluación de la producción de alimentos en relación con la degradación de tierras y la estimación de indicadores de agotamiento de los nutrientes del suelo.

El aporte que se realizó fue un modelo híbrido eficiente que implementa un clasificador bayesiano ingenuo, un clasificador Random forest y clustering k-means. Primero, se realiza la agrupación de datos y, posteriormente, son clasificados usando la información conceptual espacial extraída de variables medioambientales.

Se demostró que el clasificador tiene un mejor rendimiento y precisión de clasificación si la agrupación se realiza antes de la clasificación. Al realizar una comparación de los resultados obtenidos con el modelo propuesto y la herramienta

Landsat MSS imagery, se comprueba una mejor precisión de valores con el modelo (Peeters et al., 2015).

Aplicaciones de la minería de datos espacial

Diferentes técnicas de minería de datos espacial han sido vagamente aplicadas para el aprovechamiento de la información espacial relacionada con la agricultura, evidenciando que su implementación trae grandes beneficios para el desarrollo y optimización de los diferentes procesos.

Una de las principales ventajas que ofrece la MDE, es la posibilidad de evaluar la relación existente entre los factores que intervienen en el desarrollo de las actividades agrícolas, como lo son las condiciones climáticas, el tipo de suelo y la geografía. Esto con el fin de proveer a los agricultores de un mecanismo con el cual puedan: realizar un aprovechamiento de los recursos, desarrollar planes de contingencia, facilitar la toma de decisiones y contribuir en el incremento de la producción de los cultivos.

La agrupación espacial (clustering) tiene mayor acogida dentro de las aplicaciones basadas en MDE en la agricultura, siendo implementada como única técnica o como complemento de un proceso más amplio. Esta técnica permite realizar un mejor proceso de análisis, simple y categorizado según los criterios definidos por el interesado.

De acuerdo con la revisión del estado del arte, se identifica que la MDE aplicada a la agricultura no ha sido estudiada a profundidad en Latinoamérica en comparación con los trabajos encontrados de países asiáticos, lo cual ubica a este continente en desventaja al momento de obtener un mayor potencial de sus suelos e influir en el progreso de aquellos dedicados a la agricultura.

Los estudios realizados en Asia se han desarrollado debido a la necesidad de optimizar el uso de los recursos por la escasez de estos; en Latinoamérica se requiere implementar estas técnicas con el fin de aprovechar de forma eficiente los recursos que se poseen actualmente y evitar su agotamiento antes que sea demasiado tarde.

El uso de la información espacial puede ser un método para combatir el bajo rendimiento en las actividades agrícolas, proveyendo información crucial para el mejoramiento y optimización en este sector.

Los países africanos muestran poco interés por el uso de técnicas de minería de datos para combatir los problemas relacionados con el clima y la geografía del país. En Latinoamérica, la minería de datos espacial es poco explorada en el ámbito de la agricultura, pese a ser una potente herramienta que brinda a los países oportunidades en el desarrollo de sus actividades agrícolas.

Referencias

- Aguirre Valencia, J., Daza Santacoloma, G., Acosta, C. D., & Castellanos Domínguez, G. (2010). Comparación de métodos de reducción de dimensión basados en análisis por localidades. *Revista Tecnológicas*, (25), 131-150. <https://doi.org/10.22430/22565337.127>
- Alfaro, E. (2015a). Algoritmos genéticos. Disponible en <http://eddyalfaro.galeon.com/geneticos.html>
- Alfaro, E. (2015b). El proceso de KDD-Técnicas de minería de datos y principales algoritmos. Disponible en http://exa.unne.edu.ar/depar/areas/informatica/dad/DAD/Presentaciones/Mineria_de_Datos.pdf
- Aljure, D. C., & Agudelo J. G. (2011). Minería de datos espaciales. *Revista de Avances en Sistemas e Informática*, 8 (3), 71-77
- Aluja, T. (2001). La minería de datos entre la estadística y la inteligencia artificial. *QÜESTIÓ*, 25 (3), 479-498
- Cao, L., San, X., Zhao, Y., & Chen, G. (2013). The Application of the Spatio-temporal Data Mining Algorithm in Maize Yield Prediction. *Math. Comput. Model.*, 58 (3-4), 507-513. <https://doi.org/10.1016/j.mcm.2011.10.073>
- Dueñas-Reyes, M. X. (2009). Searching for True Information with Spatial Data Mining. *Ingeniería y Universidad*, 13 (1), 137-156
- González Polanco, L., & Pérez Betancourt, Y. G. (2013). La minería de datos espaciales y su aplicación en los estudios de salud y epidemiología. *Revista Cubana de Información en Ciencias de la Salud*, 24(4),482-489
- Herrera-Parra, C. A. (2006). Minería de datos espacial. Disponible en <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.130.5194&rep=rep1&type=pdf>
- Mennis, J., & Guo, D. (2009). Spatial Data Mining and Geographic Knowledge Discovery-An Introduction. *Comput. Environ. Urban Syst.*, 33 (6), 403-408. <https://doi.org/10.1016/j.compenvurbsys.2009.11.001>

- Osorio Zuluaga, G. A. (2009). Análisis de características del ambiente creativo en empresas de Manizales con técnicas KDD. Maestría thesis, Universidad Nacional de Colombia - Sede Manizales, Manizales, Colombia.
- Peeters, A., Zude, M., Käthner, J., Ünlü, M., Kanber, R., Hetzroni, A., Gebbers, R., & Ben-Gal, A. (2015). Getis-Ord's hot- and cold-spot statistics as a basis for multivariate spatial clustering of orchard tree data. *Comput. Electron. Agric.*, 111, 140-150. <https://doi.org/10.1016/j.compag.2014.12.011>
- Rojas-Montes, M., Pino-Correa, F., & Martínez, J. (2015). Proceso de pruebas para pequeñas organizaciones desarrolladoras de software. *Revista Facultad de Ingeniería*, 24(39), 55-70. <https://doi.org/10.19053/01211129.3551>
- Shekhar, S., & Chawla, S. (2003). Introduction to spatial data mining. En: *Spatial Databases: A Tour*, Prentice Hall
- Shekhar, S., Zhang, P., Huang, Y., & Vatsavai, R. R. (2008) Trends in Spatial Data Mining. En Kargupta, H. y Joshi, A. (Eds.). *Data mining: next generation challenges and future directions*. AAAI/MIT Press, 357-380
- Sivakumar, K., & Prakaash, A. S. (2019). An Empirical Research on Spatial Data Mining. *International Journal of Innovative Technology and Exploring Engineering*, 8 (12S2), 797-800. <https://doi.org/10.35940/ijitee.I1136.10812s219>
- Sumathi, N., & Geetha, R. (2008). Spatial Data Mining-Techniques Trends and Its Applications. *J. Comput. Appl.*, 1 (4), 28-30
- Sundaram, V. M. Thnagavelu, A., & Paneer, P. (2012). Discovering Co-location Patterns from Spatial Domain using a Delaunay Approach. *Procedia Eng.*, 38, 2832-2845. <https://doi.org/10.1016/j.proeng.2012.06.332>
- Tripathy, A. K., Adinarayana, J., & Sudharsan, D. (2009). Geospatial data mining for Agriculture Pest Management – A Framework. En: *17th International Conference on Geoinformatics*, Virginia, United States of America. <https://doi.org/10.1109/geoinformatics.2009.5293296>
- Wang, L., Zhou, L., Lu, J., & Yip, J. (2009). An order-clique-based approach for mining maximal co-locations. *Inf. Sci.*, 179 (19), 3370-3382. <https://doi.org/10.1016/j.ins.2009.05.023>