



Avances en la Transformación Digital hacia la industria 4.0



EDITORES:

- M. en C. Ma. de Lourdes Sánchez Guerrero.
- Dra. Alma Rosa García Gaona.
- Dr. Francisco Javier Álvarez Rodríguez.

EDITORIAL:

ALFAOMEGA GRUPO EDITOR S.A. DE C.V.

ISBN:

978-607-538-551-8

LUGAR:

Ciudad de México

FECHA DE PUBLICACIÓN:

DICIEMBRE 2019

Índice

Prólogo	6
Introducción	7
Semblanza de los Editores	8
AGRADECIMIENTOS	9
Comité Revisor	10
I. Analítica	11
Battery Discharge Prevention for Vehicles Stored based on Time Series Forecasting from IoT approach	12
II. Ciberseguridad	19
CAN's MAC Security Service Survey	20
III. Ciudades Inteligentes	27
Diseño de arquitectura TUI para la implementación de Transporte Inteligente y validación mediante series de tiempo	28
IV. Competencias en TIC	35
Aplicación móvil para el manejo de recursos digitales e información para los laboratorios de aprendizaje por competencias en educación media superior	36
Recursos educativos abiertos en Tecnologías de Información: RUA-ANIEI	44
Uso de la nube: CULTASOFT software para la Gestión Web de Talleres de un Centro Cultural	49
ESTUDIO DE VENTAS EN LÍNEA A TRAVÉS DE "FACEBOOK" EN LA EMPRESA GRECA FASHION	57
Tipos de Redes Sociales	64
V. Contenidos Abiertos	73
Impacto Educativo de los Cursos de Capacitación al Docente: Un Enfoque desde el Profesor	74
VI. Educación en TI	80
B-learning para Apoyo del Aprendizaje de la Asignatura de Administración	81
Análisis del Contexto de Riesgos en las Actividades Realizadas por los Usuarios de las Redes Sociales: Estudio de Caso del Municipio de Atlatlahucan, Morelos.	86
Propuesta para optimizar el aprendizaje matemático por medio de la tecnología, basado en la creación de un videojuego con la implementación de ejercicios de pensamiento lógico-matemático para nivel básico educativo de Telesecundarias en Hidalgo	93
Mejora de la Calidad Educativa basada en Tests de Ritmo y Estilo de Aprendizaje mediante un Portal Web	98
VII. E-educación	104
Intérprete de Pseudocódigo para Aprender a Programar con Arreglos	106
La Computación Afectiva en la educación: una revisión	112
Diseño de un Objeto de Aprendizaje para estudiantes visuales: introducción a la librería Three.js	120
VIII. E-learning	128
Uso de la gamificación en grupos de autonomía curricular de educación básica para el área de matemáticas	129
Aplicación y análisis de Bartle.	133
Laboratorio Virtual Web de Cálculo Integral para Educación 4.0	136

Evaluación de materiales didácticos en plataformas digitales _____	145
IX. Ingeniería de Software _____	152
Reingeniería de Sistema de Control Interno de Suministro en Almacenes de Seguridad Industrial _____	153
Hacia la Evaluación de Usabilidad de Aplicaciones Colaborativas _____	163
Evaluando la Usabilidad de Aplicaciones en Computadoras Portátiles y Pizarras Digitales Interactivas _____	171
X. Innovación en TIC _____	179
Infraestructura tecnológica y su impacto en los servicios hospitalarios _____	180
Habilidades del Líder Tecnológico _____	190
Diseño y operación de tarjeta AZ-11-SSS para el control de variables de un SITE a través de IoT y ESP1 _____	196
Marco Comparativo de Evaluación de Herramientas Tecnológicas para la Educación _____	205
XI. Inteligencia Artificial _____	213
edge2art: Edges to Artworks Translation with Conditional Generative Adversarial Networks _____	214
Perfilado de autor para el español mediante la implementación de características estilométricas _____	223
XII. Inteligencia de Negocios _____	232
A General Methodology to Structure Business Intelligence Solutions _____	233
Uso de la Inteligencia Empresarial para Pymes. Estudio de Caso _____	241
Methodological Variations in the Development of Business Intelligence Solutions _____	249
Diseño modular de un laboratorio virtual de inteligencia empresarial _____	258
XIII. Internet de las Cosas _____	265
Implementación de Webhooks para plataformas IoT a través de servicios de google _____	266
Sistema de Control para la Visualización y Activación en la Domótica: Un Caso de Uso _____	274
XIV. Matemáticas Computacionales _____	281
Metodología para la evolución temporal de la caminata utilizando información incompleta _____	282
XV. Mejores prácticas y estándares _____	287
ITIL como Herramienta de Diseño de Sistemas de Gestión Administrativa _____	288
Principios Básicos en la Construcción de Software _____	295
XVI. Minería de Datos _____	303
Análisis de datos para generar esfuerzos coordinados ante el robo de identidad en el sector financiero de México _____	304
La Minería de Datos a través de la Metodología CRISP- DM. Un Estudio de Caso. _____	312
Análisis de Encuestas sobre la Disminución de Autopsias en un Hospital Mexicano usando Minería de Patrones Emergentes _____	327
XVII. Realidad Virtual _____	334
ARVI, Asistente Virtual para Tratamiento de Estrabismo _____	335
XVIII. Responsabilidad Social _____	347
XIX. Seguridad Informática _____	348
Desarrollo de un Módulo de Hashing para un Sistema Criptográfico _____	350
XX. Sistemas de Información _____	359
Sistema Web para el conteo de conjuntos independientes sobre Árboles _____	360
Sincronización automática de la respuesta cámara proyector para un sistema de proyección digital de patrones _____	368
XXI. TIC y responsabilidad social _____	377

TEXTIL DYE TOXICITY CONCENTRATION IDENTITY USING LEGO MINDSTORM SYSTEM _____	378
Fases de diseño del modelo de Gobierno de Tecnologías de la Información para una universidad pública mexicana basado en la Norma ISO/IEC 38500 _____	386
Propuesta innovadora de atención a la discapacidad auditiva: aplicación para reconocimiento de gestos de frases más utilizadas en el aula de clases _____	394
Reciclaje de material tecnológico en la creación de nuevos productos para evitar un mayor impacto ambiental (Caso de estudio Impresora 3D). _____	402
Desarrollo de una APP para medir la adicción a internet de acuerdo al método de Kimberly Young _____	399
<hr/>	
XXII. Vida 2.0 _____	406
El impacto del CyberBullying en Estudiantes Universitarios de Ciencias Computacionales en México: Un Estudio Descriptivo. _____	407
Estudio descriptivo sobre el nivel de Adicción a los videojuegos en Estudiantes de Licenciatura en la Universidad Autónoma de Aguascalientes _____	413

Análisis de Encuestas sobre la Disminución de Autopsias en un Hospital Mexicano usando Minería de Patrones Emergentes

Ingrid Aylin Ríos Méndez¹, Lisbeth Rodríguez Mazahua¹,
José Antonio Palet Guzmán², María Antonieta Abud Figueroa¹,
Giner Alor Hernández¹

¹Tecnológico Nacional de México, Instituto Tecnológico de Orizaba
Orizaba, Veracruz, México
²Hospital Regional de Río Blanco (HRRB)
Río Blanco, Veracruz, México

Resumen. La Minería de Patrones Emergentes (EPM) es una tarea de Minería de Datos que permite encontrar diferencias entre distintas clases o conjuntos de datos. En este trabajo, se utilizaron tres algoritmos de EPM para encontrar patrones emergentes en un conjunto de datos que contiene las respuestas de una encuesta aplicada al personal médico sobre la disminución de autopsias en un hospital mexicano.

Abstract. Emerging Pattern Mining (EPM) is a Data Mining task that allows finding differences among classes or data sets. In this work, three EPM algorithms were used to find emerging patterns in a data set which contains the answers of a survey applied to the medical staff about the decrease of autopsies in a Mexican hospital.

Keywords: Minería de Patrones Emergentes, Autopsias, Minería de Datos.

1 Introduction

La Minería de Patrones Emergentes (EPM) es una tarea de Minería de Datos que construye un modelo de datos descriptivo con respecto a una propiedad de interés. En años recientes, la descripción de conjuntos de datos se convirtió en un campo interesante debido a la fácil adquisición de conocimiento por parte de los expertos [1]. La disminución de autopsias realizadas en los hospitales es un problema mundial [2]. En el Hospital Regional de Río Blanco se aplicó una encuesta al personal médico para saber los motivos por los que cada vez se realizan menos autopsias en el hospital y así tomar medidas que permitan incrementar dicha práctica, las encuestas se analizaron utilizando técnicas de Minería de Datos, como Minería de Reglas de Asociación y Redes Bayesianas [3]. En este artículo, se presentan los resultados encontrados al aplicar tres algoritmos de EPM al conjunto de datos de las encuestas utilizando el marco de trabajo *EPM-Framework*.

2 Estado del Arte

Li et al. [4] utilizaron EPM para identificar las preferencias de hospedaje de los viajeros; mientras que en [5] se abordó el tema de minería de patrones emergentes disyuntivos en conjuntos de datos biomédicos de alta dimensionalidad; de igual forma, un nuevo enfoque de EPM de saltos fuertes basado en el árbol de compresión de cadenas de bits (*BSC-Tree*) a partir de conjuntos de datos de alta dimensionalidad se propuso en [6]. García-Vico et al. [1] presentaron un estudio completo de EPM. Por otro lado, en [7], los autores propusieron un método para descubrir patrones emergentes de saltos usando el algoritmo genético; en contraste, se aplicó la EPM para descubrir conocimiento toxicológico de los compuestos químicos en [8], para identificar tendencias de ventas de productos en [9] y como una técnica de Minería Web en [10].

3 Metodología usada

En esta sección, se describe el conjunto de datos, así como el marco de trabajo y los algoritmos de EPM utilizados.

3.1 Conjunto de datos

El conjunto de datos está formado por 17 atributos categóricos y 7859 instancias. En la Tabla 1 se describe cada uno de los atributos.

3.2 EPM-Framework

EPM-Framework [11] es un marco de trabajo públicamente disponible y escrito en Java que permite ejecutar algoritmos de EPM en varios conjuntos de datos. Algunos algoritmos de EPM implementados en este marco de trabajo son BCEP (*Bayesian Classification based on Emerging Patterns*, Clasificación Bayesiana basada en Patrones Emergentes) [12], DeEPS (*Decision-making by Emerging Patterns*, Toma de Decisiones por medio de Patrones Emergentes) [13], iEPMiner (*Interesting Emerging Pattern Miner*, Minero de Patrones Emergentes Interesantes) [14], Tree-based JEP-C (*Tree-based Jumping Emerging Pattern Classifier*, Clasificador de Patrones Emergentes de Saltos basado en Árbol) [15], Top-k minimal SJEPs (*Strong Jumping Emerging Patterns*, Patrones Emergentes de Saltos Fuertes) [16], SJEP-C (*Strong Jumping Emerging Pattern Classifier*, Clasificador de Patrones Emergentes de Saltos Fuertes) [17], DGCP-Tree (*Dynamically Growing Contrast Pattern Tree*, Árbol de Patrones de Contraste que Crecen Dinámicamente) [6], EvAEP (*Evolutionary Algorithm for Extracting Emerging Patterns*, Algoritmo Evolutivo para Extraer Patrones Emergentes) [18], CEPMine (*Crisp Emerging Pattern Mining*, Minería de Patrones Emergentes Definidos) [19], LCMine (*Logical Complex Miner*, Minero de Lógica Compleja) [20] y EP-Random Forest [21].

Nombre	Descripción
Area	Área a la que pertenece el médico (Interno, Residente o Adscrito).
Categoría	Categoría correspondiente.
Ult_grado	Último grado de estudios.
Esc_med_gral	Escuela de medicina general.

Esc_esp	Escuela en la que estudió su especialidad.
Años_prac	Años de práctica
Casos	Número de casos de autopsia en los que ha participado.
Hall_disc	Los hallazgos encontrados en las autopsias pueden ser discrepantes con los diagnósticos clínicos.
Hall_arb	Los hallazgos encontrados en las autopsias dan origen a casos de arbitraje.
Hall_dem	Los hallazgos encontrados en las autopsias dan origen a casos de demanda.
Mcc_aut	Motivos, causas y circunstancias para que solicite una autopsia.
Mcc_no_aut	Motivos, causas y circunstancias para que no solicite una autopsia.
Rechazo_fa m	Principal causa de rechazo por parte del familiar para realizar una autopsia.
No_hosp	Causas por las que no se realizan suficientes autopsias en su hospital.
Per_sol_aut	Persona que debe solicitar la autopsia.
Med_aut	Causas por parte del médico para solicitar una autopsia.
Fmr_sol_aut	Forma, método o recurso que pudiera funcionar en forma eficiente para la solicitud de un estudio de autopsia.

Tabla 8. Atributos del conjunto de datos.

3.3 Algoritmos de EPM

Se aplicaron todos los algoritmos al conjunto de datos de las encuestas considerando como clase al atributo *Fmr_sol_aut*, los algoritmos mejor evaluados fueron iEPMiner, Top-k minimal SJEPs y LCMine.

3.3.1 iEPMiner

iEPMiner [14] es un algoritmo eficiente para la minería de patrones emergentes interesantes basados en una estructura de datos de árbol, donde la prueba de *chi-squared* se utiliza como heurística para podar el espacio de búsqueda, esto hace que iEPMiner sean más rápido. La heurística siempre descubre el 90% de EPs más interesantes, que son suficientes para construir clasificadores de alta precisión en muchas aplicaciones de la vida real.

3.4.2 Top-k minimal SJEPs

Los patrones emergentes de saltos (EPs que cubren ejemplos para una sola clase), como otros patrones discriminativos, ayudan a comprender las diferencias entre las clases y a construir clasificadores precisos. Dado que su descubrimiento suele llevar mucho tiempo y la poda con un soporte mínimo puede requerir varios ajustes, en [16] se consideró el problema de extraer los patrones emergentes de saltos (JEPs) mínimos *top-k*, es decir, los *k* JEPs mínimos (un EP es mínimo cuando sus sub-patrones no son EPs, los EPs mínimos son interesantes para la descripción porque, en general, contienen un pequeño número de variables [1]) más admitidos en cada clase de decisión, por lo que se propuso el algoritmo Top-k minimal SJEPs que sigue un enfoque basado en un árbol de patrones de contraste (*CP-Tree*) para encontrar JEPs fuertes (los EPs son fuertes cuando son EPs de saltos y mínimos, los EPs fuertes son fáciles de entender y tienen un alto poder predictivo [1]). Se poda el espacio de búsqueda con un soporte mínimo, cuyo valor se aumenta gradualmente a medida que se descubren nuevos JEPs mínimos. Para

permitir esto, se verifica que cada nuevo JEP sea mínimo en el momento en que se encuentra en lugar de al final del proceso. Este algoritmo logra ahorros significativos tanto en tiempo como en el número de patrones examinados, cuando se solicita un pequeño número de JEPs altamente compatibles.

3.4.3 LCMine

LCMine [20] es un algoritmo eficiente para encontrar regularidades discriminatorias en una muestra de entrenamiento con datos mixtos e incompletos para la clasificación supervisada. Este algoritmo se basa en una inducción de árbol de decisión diversa y una etapa de filtrado posterior al procesamiento, que permite encontrar un conjunto reducido de propiedades discriminatorias de alta calidad para cada clase.

LCMine tiene tres características distintivas: 1) No aplica una discretización *a priori* en las características numéricas, a diferencia de la mayoría de los algoritmos para extraer regularidades discriminatorias; 2) Utiliza una representación extendida para las regularidades, y 3) Utiliza una nueva estrategia de filtrado para eliminar las regularidades redundantes.

4 Resultados Experimentales

En esta sección se presentan los resultados obtenidos al aplicar los algoritmos iEPMiner, Top-k minimal SJEP-C y LCMine al conjunto de datos de las encuestas.

Cada algoritmo se evaluó utilizando las métricas descritas a continuación:

Velocidad. Se refiere al tiempo en segundos que tardó la ejecución de cada algoritmo.
#Patrones con confianza > 0.6. EPM-Framework permite obtener un archivo con los patrones que superan un valor de 0.6 en confianza en los datos de prueba, la confianza se define como la precisión de la capacidad predictiva de un patrón para la clase positiva.

#Patrones. Número de patrones.

FPR. Tasa de Falsos Positivos, mide el porcentaje de ejemplos incorrectamente cubiertos con respecto a la cantidad total de ejemplos negativos, este valor debe ser minimizado.

GR. Tasa de crecimiento, esta es la medida que define un patron emergente, calcula la proporción entre el soporte del patrón en la clase positiva y el soporte en la negativa. Se interpreta como el poder discriminativo de un patrón.

WRACC. *Weighted Relative Accuracy*, Precisión Relativa Pesada, mide el intercambio entre la ganancia de generalidad y de precision. Un valor alto puede interpretarse como un alto balance entre la generalidad del patrón y su confianza.

TPR. Tasa de Verdaderos Positivos, mide el porcentaje de ejemplos correctamente cubiertos con respecto al número total de ejemplos positivos [1].

La Tabla 2 compara el desempeño de cada algoritmo considerando los primeros tres criterios:

Algoritmo	Velocidad (segundos)	#Patrones con confianza>0.6	#Patrones
iEPMiner	4	27	27
Top-k minimal SJEP-	19	41	55

C			
LCMine	6	17	76

Tabla 2. Primera comparación entre algoritmos.

iEPMiner es el algoritmo más veloz de los tres de acuerdo a la Tabla 2. Además, es el que solo obtuvo patrones con confianza mayor a 0.6. Top-k minimal SJEP-C encontró más EPs que cumplieran con esta característica, pero fue el más lento.

La Tabla 3 muestra los resultados obtenidos con cada uno de los algoritmos para los últimos criterios, considerando como número de patrones solo aquellos que superan el valor de 0.6 en confianza.

Algoritmo	WRAC C	CONF	G R	TPR	FPR	#Patrones
iEPMiner	0.2313	0.7683	1	0.0655	0.0047	27
Top-k minimal SJEP-C	0.0289	0.9188	1	0.0289	0.0012	41
LCMiner	0.1961	0.9765	1	0.0031	0.0000	17

Tabla 3. Segunda comparación entre algoritmos.

Como se observa en la Tabla 3, el algoritmo mejor evaluado fue iEPMiner, ya que obtuvo patrones con mayor precisión relativa pesada y tasa de verdaderos positivos que los otros dos algoritmos, LCMine encontró patrones con mayor confianza que iEPMiner y menor tasa de falsos positivos, sin embargo, el número de patrones obtenidos por iEPMiner fue mayor que el de LCMine. El algoritmo peor evaluado fue Top-k minimal SJEP-C, puesto que solo encontró más patrones que los otros dos algoritmos.

Por cuestiones de espacio, en la Tabla 4 solo se muestran tres de los 27 EPs obtenidos con el algoritmo iEPMiner, uno para cada valor de la clase, que en este caso es el atributo *Fmr_sol_aut*.

EP	Interpretación
IF Hall_arb = 8b AND Hall_dem = 11a THEN 21a	Si los médicos están de acuerdo en que los hallazgos encontrados en las autopsias dan origen a casos de arbitraje y están totalmente de acuerdo en que los hallazgos encontrados en las autopsias dan origen a casos de demandas, entonces ellos consideran que la forma, método o recurso que pudiera funcionar en forma eficiente para la solicitud de un estudio de autopsia es pedir el consentimiento al familiar del paciente, desde que ingrese al hospital.
IF Anios_prac = 3a AND Hall_dem = 11b AND Med_aut = 20e THEN 21b	Si los médicos tienen menos de 5 años de práctica y están de acuerdo en que los hallazgos encontrados en las autopsias dan origen a casos de demandas y creen que una de las causas por parte del médico para solicitar una autopsia es diagnóstico erróneo, entonces ellos consideran que la forma, método o recurso que pudiera funcionar en forma eficiente para la solicitud de un estudio de autopsia es solicitar el consentimiento de autopsia a los familiares inmediatamente después de la defunción.

IF Anios_prac = 3c AND Hall_dem = 11b THEN 21c	Si los médicos tienen de 11 a 15 años de práctica y están de acuerdo en que los hallazgos encontrados en las autopsias dan origen a casos de demandas, entonces ellos consideran que la forma, método o recurso que pudiera funcionar en forma eficiente para la solicitud de un estudio de autopsia es que la institución a nivel regional o estatal reglamente la práctica de autopsias de forma obligatoria a los pacientes hospitalizados que fallezcan.
--	--

Tabla 4. EPs obtenidos con iEPMiner.

Como se observa en la Tabla 4, cada patrón muestra características discriminatorias entre las clases. Estos patrones además de tener un alto valor de confianza (0.7165, 0.6948 y 0.7248, respectivamente), son mínimos, por lo tanto, tienen un pequeño número de variables, lo cual los hace interesantes para la descripción. También son máximos, es decir, sus super-patrones no son EPs, por lo que son muy precisos.

5 Conclusiones y Trabajo Futuro

En este artículo se aplicaron algoritmos de EPM a un conjunto de datos sobre encuestas aplicadas al personal médico del Hospital Regional de Río Blanco, con el objetivo de encontrar diferencias entre clases. Los algoritmos aplicados fueron iEPMiner, Top-k minimal SJEP-C y LCMine, el primero fue el mejor considerando velocidad, tasa de verdaderos positivos y balance entre la generalidad del patrón y su confianza. En el futuro se aplicará la encuesta en otro hospital y se compararán los resultados obtenidos en los dos hospitales.

Agradecimientos. Los autores agradecen al Consejo Nacional de Ciencia y Tecnología (Conacyt), así como al Tecnológico Nacional de México (TecNM) por el apoyo otorgado para la realización de esta investigación.

Referencias

- [1] A. M. García-Vico, C. J. Carmona, D. Martín, M. García-Borroto y M. J. del Jesus, An overview of emerging pattern mining in supervised descriptive rule Discovery: taxonomy, empirical study, trends, and prospects. *WIREs Data Mining and Knowledge Discovery*. Vol. 8, 2018.
- [2] D. E. Suleiman, Reviving hospital autopsy in Nigeria: An urgent call to action. *Annals of Nigerian Medicine*, Vol. 9, No. 2, pp. 39-40, 2015.
- [3] E. Rubio-Delgado, L. Rodríguez-Mazahua, J. A. Palet Guzman, J. Cervantes, J. L. Sánchez-Cervantes, S. G. Peláez-Camarena y A. López-Chau, Analysis of Medical Opinions about the Nonrealization of Autopsies in a Mexican Hospital Using Association Rules and Bayesian Networks. *Scientific Programming*, Vol. 2018, pp. 1-21, 2018.
- [4] G. Li, R. Law, H. Q. Vu, J. Rong y X. Zhao, identifying emerging hotel preferences using Emergent Pattern Mining technique, *Tourism Management*. Vol. 46, pp. 311-321, 2015.
- [5] R. Vimieiro y P. Moscato, A new method for mining disjunctive emerging patterns in high-dimensional datasets using hypergraphs, *Information Systems*. Vol. 40, pp. 1-10, 2014.
- [6] Q. Liu, P. Shi, Z. Hu y Y. Zhang, A novel approach of mining strong jumping emerging patterns based on BSC-tree, *International Journal of Systems Science*. Vol. 45, No. 3, pp. 598-65, 2014.
- [7] S. Q. ul Ain y S. ur Rehman, Discovery of Jumping Emerging Patterns Using Genetic Algorithm. *International Journal of Computer Science and Information Security*. Vol. 16, No. 4, pp. 331-336, 2018.

- [8] R. Sherhod, P. N. Judson, T. Hanser, J. D. Vessey, S. J. Webb y V. J. Gillet, Emerging Pattern Mining To Aid Toxicological Knowledge Discovery, *Journal of Chemical Information and Modeling*, Vol. 54, pp. 1864-1979, 2014.
- [9] C.-H. Weng y T. C.-K. Huang, Observation of sales trends by mining emerging patterns in dynamic markets, *Applied Intelligence*, Vol. 48, No. 11, pp. 4515-4529, 2018.
- [10] X. Yu, M. Li, K. A. Kim, J. Chung and K. H. Ryu, Emerging Pattern-Based Clustering of Web Users Utilizing a Simple Page-Linked Graph, *Sustainability*, Vol. 8, No. 3, pp. 1-18, 2016.
- [11] SIMIDAT/epm-framework, <http://github.com/SIMIDAT/epm-framework>.
- [12] H. Fan y K. Ramamohanarao, A Bayesian Approach to Use Emerging Pattern for Classification, En: Proc. of the 14th Australasian database conference, Vol. 17, pp. 39-48, 2003.
- [13] J. Li, G. Dong, K. Ramamohanarao y L. Wong, DeEPS: A New Instance-Based Lazy Discovery and Classification System, *Machine Learning*, Vol. 54, pp. 99-124, 2004.
- [14] H. Fan y K. Ramamohanarao, Efficiently Mining Interesting Emerging Patterns, En: Dong et al. (Eds.), WAIM 2003, LNCS 2762, pp. 189-201, Springer-Verlag, 2003.
- [15] J. Bailey, T. Manoukian y K. Ramamohanarao, Fast Algorithms for Mining Emerging Patterns, En: T. Elomaa (Eds.), PKDD, LNAI 2431, pp. 39-50, Springer-Verlag, 2002.
- [16] P. Terlecki y K. Walczak, Efficient Discovery of Top-K Minimal Jumping Emerging Patterns, En: C.-C. Chan et al. (Eds.), RSCTC 2008, LNAI 5306, pp. 438-447, Springer-Verlag 2008.
- [17] H. Fan y K. Ramamohanarao, Fast Discovery and the Generalization of Strong Jumping Emerging Patterns for Building Compact and Accurate Classifiers, *IEE Transactions on Knowledge and Data Engineering*, Vol. 18, No. 6, 2006.
- [18] A. M. García-Vico, J. Montes, J. Aguilera, C. J. Carmona y M. J. del Jesus, Analysing Concentrating Photovoltaics Technology Through the Use of Emerging Pattern Mining, En: M. Graña et al. (Eds.), International Joint Conference SOCO'16-CISIS'16-ICEUTE'16, Advances in Intelligent Systems and Computing 527, Springer International Publishing AG 2017.
- [19] M. García-Borroto, J. F. Martínez-Trinidad y J. A. Carrasco-Ochoa, A New Emerging Pattern Mining Algorithm and Its Application in Supervised Classification, En: M. J. Zaki et al. (Eds.) PAKDD 2010, Part I, LNAI 6118, pp. 150-157, Springer-Verlag, 2010.
- [20] M. García-Borroto, J. F. Martínez-Trinidad, J. A. Carrasco-Ochoa, M. A. Medina-Pérez y J. Ruiz-Shulcloper, LCMine: An efficient algorithm for mining discriminative regularities and its application in supervised classification, *Pattern Recognition*, Vol. 43, pp. 3025-3034, 2010.
- [21] L. Wang, Y. Wang y D. Zhao, Building Emerging Pattern (EP) Random Forest For Recognition, En: 2010 IEE International Conference on Image Processing, 2010.