

# El uso del aprendizaje automático para predecir elecciones en el estado de Quintana Roo, México

**Roger Ismael Noh Balam**

Instituto Tecnológico de Chetumal

*ismael\_balam@hotmail.com*

## Resumen

Este artículo presenta un análisis y una comparación de tres algoritmos diferentes: método de agrupamiento (K-means), Algoritmo expectación-maximización Kohonen (EM) y metodología de clasificación (LAMDA), usando dos paquetes (WEKA y SALSA) de clasificación como ayuda para la predicción de futuras elecciones en el estado de Quintana Roo. Al trabajar con datos electorales éstos son clasificados de forma cualitativa y cuantitativa y por tal virtud al final de ésta artículo se tendrán los elementos necesarios para decir que software tiene mejor desempeño para dicho aprendizaje de clasificación.

**Palabras clave.** Aprendizaje automático, lógica difusa, agrupamiento, WEKA, SALSA, LAMDA, elecciones estatales, predicción.

## 1. Introducción

La fascinación por predecir el futuro es uno de los intentos y deseos que el hombre sigue insistiendo en conseguir. Mucho esfuerzo han puesto las personas y empresas en conocer el clima y precios de productos en el mercado [8,9,12]. Algunos de estos trabajos [9] calculan rendimientos logarítmicos, métodos de trazado, promedio de valores en series de tiempo para generar escenarios probabilísticos.

Muchos trabajos de predicción con Minería de datos se han hecho como la predicción y tratamiento de enfermedades [4], consumo de alcohol en adolescentes [5], etc. Otros estudios acerca de predicción de elecciones se han hecho en países como: España [1], Holanda [2], Alemania [3,4], Canadá [13].

El descubrimiento de conocimiento en bases de datos (KDD) ha hecho que los procedimientos computacionales en aprendizaje automático sea cada vez más avanzados. La minería de datos tiene como objetivo descubrir patrones y relaciones para hacer predicciones.

Primeramente la clasificación de los datos por un proceso de aprendizaje no supervisado como el clustering, trae consigo el encontrar grupos que sean diferentes pero los individuos sean iguales entre sí [6].

Se elige la utilización del software de minería de datos llamado WEKA por ser una herramienta fácil, más utilizada y donde distintos trabajos eligieron [13,15] y compararon [5] los diferentes productos de software de minería de datos.

También se elige un modelo híbrido (ver tabla 1) como técnicas de clustering por mejores resultados en algunos trabajos relacionados [10,11].

**Tabla 1.** Descripción de modelos de predicción [11]

<b>Técnica</b>	<b>Tipo de modelo</b>
Regresión múltiple	Lineal
Redes neuronales (Radial Basis Function, RBF y Backpropagation)	No Lineal
Métodos de K-nearest neighbor	No lineal
Red neuronal probabilística (PNN)	No lineal
Algoritmo genético	No lineal
Redes neuro-difusas	No lineal e Híbrido
Redes neuronales MPL	No lineal
SVM support vector machines	No lineal

Con propósitos comparativos, en éste artículo se muestran los resultados de la clasificación en dos aplicaciones: WEKA y SALSA en diferentes técnicas de clustering. También se muestra y detallan los experimentos sobre la preparación de los datos como parte de un tutorial. En la primer parte se explica nuestra intención por predecir elecciones estatales así como describir tres técnicas de clustering y describir a brevemente la metodología de clasificación LAMDA.

Se hace una comparación de las técnicas y el software basándose en los resultados obtenidos, finalmente se muestra el desempeño de cada herramienta.

## **2. Predicción de elecciones estatales**

La predicción de elecciones en Alemania 2009 [4] se hace tomando en cuenta la frecuente de menciones y se obtienen los totales de menciones, replicación de menciones y porcentajes de menciones. La muestra es de menos de un mes y se toman días representativos. También se toman en cuenta la progresión de los seguidores. El análisis de los resultados es cuantitativo.

En cambio la clasificación que se hace en [13] a través de aprendizaje automático muestra las posibles clasificaciones de clases y SVM como el mejor clasificador manejando 3390 registros como el mejor conjunto de datos (data set) de entrenamiento. En éste caso, se toman las elecciones en el estado de Quintana Roo de los años 1998, 2004 y 2010.

## **3. Aprendizaje automático**

Aprendizaje automático es la adquisición de nuevo conocimiento, el desarrollo de un motor y habilidades cognitivas a través de instrucciones o prácticas, la organización de nuevo conocimiento, representación efectiva y descubrimiento de nuevos hechos y teorías a través de la observación y experimentación.

Los tipos de conocimiento adquirido son parámetros en expresiones algebraicas, árboles de decisión, gramática formal, producción de reglas, lógica formal basada en expresiones, grafos y redes, marcos y esquemas y otras codificaciones procedimentales y programas de cómputo.

Este aprendizaje es aplicado a muchas áreas como la química, educación, programación computacional, sistemas expertos, videojuegos, matemáticas, música, procesamiento del lenguaje natural, robótica, reconocimiento del habla e imagen, y secuencias de predicción [17] entre otras.

### 3.1 Técnicas de Clustering

Las técnicas de clustering, son procedimientos que sirven para agrupar una serie de ítems. Clustering es usado en estadística y ciencia. Los métodos a ocupar son el método jerárquico, debido a que es una herramienta exploratoria diseñada para revelar las agrupaciones naturales dentro de un conjunto de datos que no sería de otra manera evidente. Es útil cuando desea agrupar un número pequeño de objetos, pueden ser casos o variables, dependiendo, si se desea clasificar casos o examinar relaciones entre las variables.

**Tabla 2.** Clasificación de algoritmos de clustering [16].

Métodos	Categoría
Método jerárquico	Agglomerative algorithms y divisive algorithms
Método de partición y de reubicación	Clustering probabilístico, K-mediods y K-means.
Método de particionado basado en densidad	Clustering con conectividad basado en densidad y clustering de funciones de densidad.
Método basado en red	
Método basado en co-ocurrencia de datos categóricos	
Otras técnicas de clustering	Clustering basado en restricciones, particionamiento en grafos, algoritmos de agrupamiento con aprendizaje supervisado y algoritmos de agrupamiento con aprendizaje automático
Algoritmos de clustering escalables	
Algoritmos para datos dimensionales altos	Clustering de subespacio y técnicas de co-clustering

El método jerárquico es construido por un clúster jerárquico o árboles de clusters. Cada nodo contiene clusters hijos. Categorizados en aglomerative y divisive. El primero empieza con un cluster y después dos o más clusters similares.

El segundo empieza con un cluster conteniendo todos los puntos de datos y recursivamente divide el grupo más apropiado. El proceso continúa y se detiene hasta que el criterio es mejorado.

#### **a. K-Means**

Es un algoritmo clasificado como método de particionado y de reubicación. Cada uno de sus clusters representa la media de sus puntos (centroide). La ventaja de usarlo es por la rápida vista gráfica y estadística. La función objetivo es la suma de los errores entre el centroide y sus puntos, es decir la varianza total dentro del cluster.

#### **b. Algoritmo expectación-maximización Kohonen (EM)**

El algoritmo EM pertenece a la familia de modelos Finite Mixture Models utilizados para segmentar datos. Es un algoritmo de clustering probabilístico, donde se intenta conocer la función objetivo de probabilidad desconocida a la que pertenece el conjunto de datos. Cada clúster está definido por una distribución normal.

### **3.2 Lógica difusa**

La lógica difusa se ocupa cuando se manejan términos imprecisos o subjetivos, donde un elemento puede pertenecer a varios conjuntos de forma parcial. La lógica difusa fue definida en éste trabajo por funciones de pertenencia de campana por las funciones media y desviación estándar.

#### **a. Metodología de clasificación LAMDA**

LAMDA (*Learning Algorithm for Multivariable Data Analysis*) traducido al español como un algoritmo de aprendizaje para el análisis de datos multivariable. LAMDA es un método de clasificación desarrollado por N. Piera y J. Aguilar [19, 20, 21]. Es concebido

por principio para clasificar datos dónde pueden existir muchas variables, sin embargo clasifica tanto numéricos como simbólicos, datos cuantitativos y cualitativos.

LAMDA entra dentro de la teoría de redes de función de base radial la cual es un método para mejorar la generalización de nuevos datos. El aprendizaje de base radial se puede dar de forma supervisada o no supervisada. Supervisada cuando se busca minimizar el error entre el valor de salida de la red y el valor de salida deseada (utilizando mínimos cuadrados). No supervisada donde permita dividir el espacio en patrones de entrada en clases. El número de clases es el número de neuronas ocultas en una red de base radial.

Un objeto  $X$  es representado por un vector que contiene un conjunto de características, en éste caso puede ser las votaciones del partido 1, partido 2 o partido 3, llamados descriptores. En la clasificación cada objeto  $X$  es asignado a una clase. Una clase es definida como el universo de descriptores que se caracteriza como un conjunto de objetos.

LAMDA realiza la clasificación de acuerdo a criterios de similitud en dos fases, primero se mide el criterio de similitud de cada descriptor de objeto al descriptor correspondiente de una clase dada, a esto se le conoce como la obtención o cálculo del grado de adecuación marginal (MAD), segundo es cuando las similitudes del descriptor de un objeto se agregan para obtener la similitud del objeto de una clase dada, a esto se le conoce como la obtención o cálculo del grado de adecuación global (GAD). Por último el máximo de similitud global de un objeto a una clase permite la definición de una clase que mejor describe al objeto.

En otras palabras MAD es un término relacionado de cómo es similar un descriptor objeto al mismo descriptor de una clase dada y GAD es definida como el grado de pertinencia de un objeto a una clase dada, como una función de pertinencia difusa.

$$MAD \left( \frac{di \cdot xj}{\rho \left( \frac{i}{k} \right)} \right) = \rho \left( \frac{i}{k} \right) \left( 1 - \rho \left( \frac{i}{k} \right) \right) (1 - di \cdot xj) \text{ Fórmula MAD. (1)}$$

La implementación de LAMDA incluye una función de probabilidad para estimar la distribución de descriptores basados en fuzzificación.

Las características principales y que hace diferencia de LAMDA son la NIC (not information classified), la cual permite realizar clasificaciones supervisadas y no supervisadas, las funciones de aprendizaje son basadas en medias aritméticas, se puede modificar los parámetros representativos de cada clase. NIC acepta todos los objetos contenidos en el universo de descripción con el mismo grado de apreciación (GAD).

## **4. Antecedentes**

### **4.1 Referencias**

Para analizar la toma de decisión de los ciudadanos, es necesario contar con instrumentos de medición respecto a su comportamiento electoral, como son encuestas y proyecciones. En México respecto a las primeras hay algo escrito, pero sobre las segundas existe muy poco. La literatura referente a proyecciones electorales es anémica porque los estudios que deberían nutrirlos como los análisis estadísticos estos son escasos (22).

La falta de bibliografía especializada se debe a que desde 1993 se difunden, por parte del Instituto Federal Electoral (IFE), y los órganos electorales estatales, los resultados globales y con algunos niveles de desagregación; lo que ha implicado que no existan series históricas de votación, ni criterios para construir unidades de comparación.

Con la práctica de presentar la estadística básica desagregada hasta el nivel de sección electoral e inclusive por casilla, se han subsanado algunas de las carencias descritas, sin embargo, todavía subsiste la necesidad de analizar e interpretar los datos; fijar criterios para la construcción y utilización de agregados estadísticos; y finalmente, realizar predicciones tentativas.

La literatura sobre comportamiento electoral individual ha subrayado la existencia de predisposiciones estables de voto, afirmadas en el largo plazo, sobre la base de las cuales se concretará la decisión, salvo que actúen sobre el individuo circunstancias particulares de una elección: candidatos, temas, etcétera, todas fuerzas de corto plazo.

## **4.2 Metodología**

Es importante estudiar la relación entre la tendencia histórica de la votación y los resultados electorales de un proceso específico; es trascendente porque nos permite efectuar predicciones, las cuales pueden, en buena medida, sensibilizar a los actores políticos y a los ciudadanos acerca de los posibles resultados del proceso electoral.

Es pertinente señalar que la investigación se realizó ordenando los resultados de los procesos locales de gobernador 1998, 2004 y 2010 del estado de Quintana Roo, para elaborar series históricas de votación, las cuales eran necesarias para efectuar las proyecciones, los resultados electorales no son eventos totalmente fortuitos, desligados por completo de acontecimientos anteriores, y que mucho de lo que ocurre en los procesos locales nos permite prever los posibles escenarios del proceso local.

Así, para el caso del ejecutivo local se incorporan los datos de los tres últimos comicios para gobernador 1998, 2004 y 2010, se analizaron datos de presidentes municipales y diputados locales “los anteriores son cada 3 años”, debido a las dificultades para normalizar los datos y la falta de los datos mismos, se determinó a usar los datos para la gubernatura.

La evolución histórica que han tenido los partidos políticos en el Estado de Quintana Roo muestra claramente como han aparecido diversidad de estos actores políticos, pero con el paso del tiempo han fenecido. Los partidos políticos que con el paso del tiempo han subsistido solos o coaligados son el PAN, PRI y el PRD, para el caso de estudio.

Para obtener los datos ya normalizados, se tuvo que realizar un análisis histórico de la evolución que han tenido los partidos políticos y sus coaliciones; se llegó a la conclusión, para el caso del estado de Quintana Roo, en todas las elecciones de gobernador se encontraban presentes los tres partidos políticos grandes de México o estaban coaligados.

Primeramente y para no tener sesgo o tendencia, se tomó en el orden que aparecen registrados en el órgano electoral estatal, de tal manera que aparecen la siguiente manera: PAN, PRI Y PRD o sus respectivas coaliciones. En ese sentido se empezaron a tomar como datos el año de la elección (1998, 2004 y 2010), siendo los datos que se



obtuvieron del Órgano Electoral Estatal y tomando en cuenta que la elección mayor se realiza cada 6 años.

Posteriormente los datos se clasificaron por distrito electoral (1998, 2004 y 2010 para estos años han existido 15 distritos), de tal manera que se realizó la división por distrito electoral y para cada distrito electoral se desagregó por casilla (para las casillas existió la necesidad de normalizar la información); para cada casilla electoral se dividió por tipo de casilla, de tal manera que se llegó el desagregado al dato más elemental.

Quedando el registro de la siguiente manera (año de la elección, distrito electoral, casilla, partido 1, partido 2 y partido 3). Quedando 2 tipos de datos cualitativos y los otros cuantitativos.

## 5. Experimentos

### 5.1 Salsa

Al archivo generado de los datos, se le debe agregar el encabezado (a) de acuerdo al formato que maneja la herramienta para este caso Salsa, posteriormente ya normalizados dichos datos, se guarda el archivo (b). Se procede a realizar la carga de los datos por medio del archivo realizado en formato texto (c).

Una vez que se ha procedido a cargar los datos en Salsa, se procede a procesarlos (d).

#### a. Encabezado del archivo

<b>&amp;ANIO</b>	<b>DIST</b>	<b>PAN</b>	<b>PRI</b>	<b>PRD</b>
<b>CAS</b>				

El formato del encabezado del archivo que servirá para procesar los datos en la herramienta es el que se muestra en la imagen, la herramienta pide que al inicio del archivo exista & y las demás columnas deberán estar separadas por un (Tabulador)

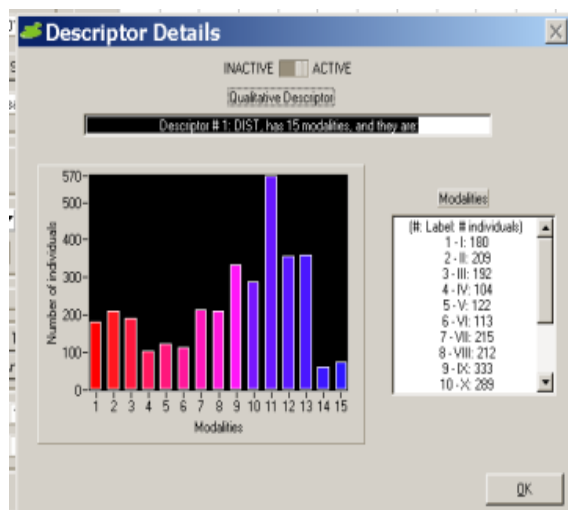
#### b. Datos normalizados año 1998- 2010

<b>&amp;ANIO</b>	<b>DIST</b>	<b>PAN</b>	<b>PRI</b>	<b>PRD</b>
<b>CAS</b>				

1998	I	300B	83	149	45
1998	XV	297B	11	235	236
2004	I	300B	206	161	20
2004	XV	297B	3	35	127
2010	I	300B	47	153	58
2010	XV	297B	73	137	79

Los datos fueron agrupados por años (1998, 2004 y 2010), el distrito electoral al que corresponde (I..XV), el número y tipo de casilla (**B**ásica, **C**ontigua, **E**special o **eX**traordinaria) y por último la votación correspondiente al partido.

### c. Datos cargados

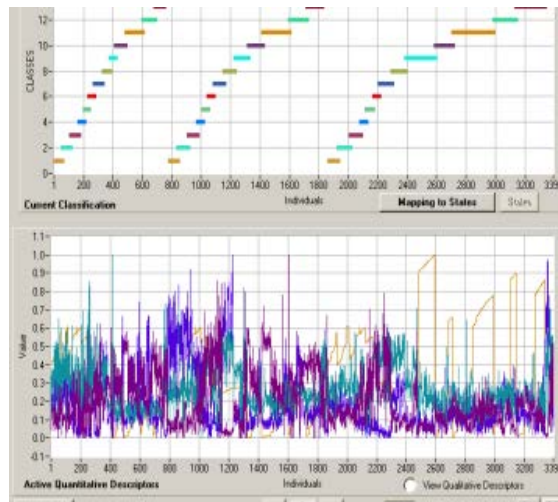


En esta figura, se observa como la herramienta ya ha agrupado y ordenado los datos, de una manera cuantitativa y cualitativa, si se observa el punto anterior, el archivo es un conjunto de datos sin ordenar y sin clasificar, donde existen números y alfanuméricos.

### d. datos procesados

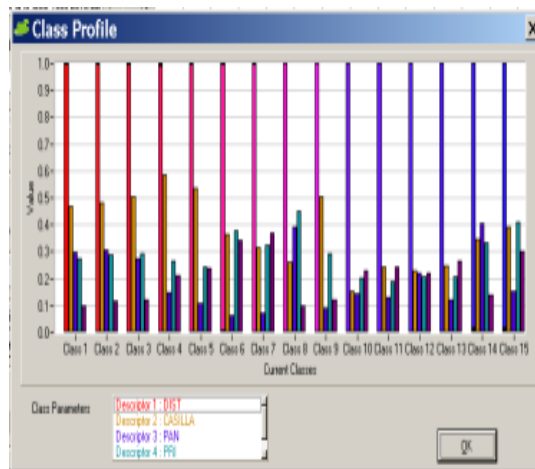
Los datos históricos procesados contienen 3390 muestras y 15 descriptores o variables físicas obtenidas por la normalización realizada a los datos de las elecciones. A través de una normalización de los datos, se muestra la representación del comportamiento de

las variables. Los valores máximos y mínimos que se utilizan en cada descriptor ayuda a homogenizar la influencia de sus dimensiones.



### e. perfil de la clase.

Se ilustra las clasificaciones encontradas para cada método de Agrupamiento. Particiones obtenidas con: a) *LAMDA*, b) *K-Means*.



## 5.2 WEKA

Se realiza un procedimiento similar al que se realizó con Salsa. Como primer paso se genera un archivo de datos, al archivo generado de los datos, se le debe agregar el

encabezado (a) de acuerdo al formato que maneja la herramienta para éste caso WEKA, posteriormente ya normalizados dichos datos, se guarda el archivo. Se procede a realizar la carga de los datos por medio del archivo realizado en formato texto (b).


### a. Encabezado del archivo

Para el caso de WEKA, se le tuvo que quitar el atributo año, cuando se le dejaba este atributo generaba un error de datos cualitativos y cuantitativos.

```
@relation 'datos'
@attribute distrito {I, II, III, IV, V, VI, VII, VIII, IX, X, XI, XII, XIII, XIV, XV}
@attribute pan numeric
@attribute pri numeric
@attribute prd numeric
```

### b. Datos cargados

Se observa como hace la clasificación WEKA (en forma de tabla y en forma de barras), para el caso de la tabla se hace una clasificación por distrito y el resultado de la agrupación de los datos para cada distrito. Para las gráficas solo muestra su concentración y uno tendría que deducir que cada barra es un distrito electoral.



### c. Datos procesados mediante K-means

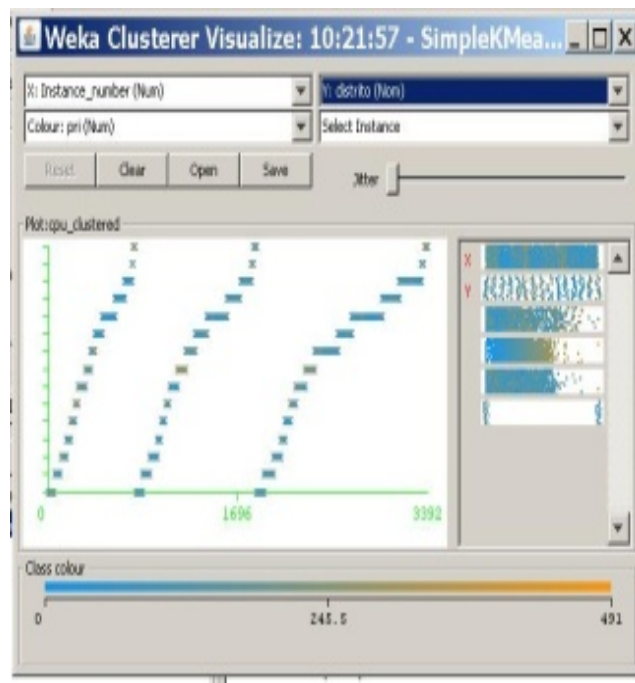
Como se puede observar en los círculos de la imagen anterior la herramienta WEKA genera dos Cluster Centroids (XI y XIII) y los maneja como si fueran los más lejanos y a partir de esa primicia se hace al ajuste.

```
Clusterer output
Clusterer Model
kMeans
-----
Number of iterations: 22
Within cluster sum of squared errors: 2635.438902787142
Missing values globally replaced with mean/mode
Cluster centroids:
Attribute  Full Data  Cluster#
(3392)    (1442)    (1951)
-----
distrito  XI      XIII    XI
pan      51.9318  81.5393  29.1205
pri      129.104  148.432  114.8186
prd      88.0899  65.9341  104.4654

Time taken to build model (full training data) : 0.36 seconds

--- Model and evaluation on training set ---

Clustered Instances
0      1442 ( 42%)
1      1951 ( 58%)
```



### **5.3 Resultados y trabajos futuros**

Aunque WEKA es un software que permite hacer clasificaciones automatizadas por diferentes métodos y formas, en este análisis sólo se usaron los métodos propuestos al inicio del artículo, de tal manera que se muestran los resultados (imágenes) que más se ajustaban o acercan a las clasificaciones esperadas por él experto. Lo anterior debido a que existen datos cualitativos, que no todas las herramientas tienen la capacidad de clasificar adecuadamente y por otro lado no se puede explicar bajo algún método estadístico el comportamiento de los datos y en ese sentido no se puede hacer una correlación bajo los métodos que trabaja WEKA.

El que mejor realizó las clasificaciones fue Salsa, ver el apartado 5.1 apartado c y d, debido a que incluyó de manera adecuada los datos cualitativos junto con los cuantitativos, con las bases mostradas en éste trabajo, se puede realizar en un futuro el pronóstico por alguna metodología matemática y terminar de hacer los análisis correspondientes, así como las correlaciones entre los datos de los distritos y de las casillas, para los trabajo o los fines que se vayan a utilizar.

Con los datos ya procesados tanto en WEKA y en SALSA, se realizó un análisis y una comparación de los mismos, el análisis realizado fue con respecto a su desempeño al agrupamiento de los datos cuantitativos y cualitativos, la otra vertiente realizada es con respecto a la eficiencia al realizar dichos datos.

### **Conclusiones**

En éste artículo se averiguó sobre el estado actual de investigación relacionado con la predicción de elecciones usando aprendizaje automático.

Para trabajo futuro se realizará un análisis y almacenará una colección de opiniones para comparar con los registros de votos anteriores, Nosotros creemos que se puede con las herramientas mostradas, predecir con mucha antelación la tendencia de las elecciones en base a datos históricos y comparados con futuras elecciones y opiniones hechas por ciudadanos.

## Bibliografía

- [1] Dellte, L., Osteso, J., M., & Claes, F (2013). Predicción de tendencia política por Twitter: elecciones Andaluzas 2012. *Ámbitos. Revista Internacional de Comunicación*, 22(1).
- [2] Tumasjan, A., Sprenger, T. O., Sandner, P. G., & Welpe, I. M. (2010). Predicting Elections with Twitter. What 140 Characters Reveal about Political Sentiment. *ICWSM*, 10, 178-185.
- [3] Sang, E. T. K., & Bos, J. (2012, April). Predicting the 2011 dutch senate election results with twitter. In *Proceedings of the Workshop on Semantic Analysis in Social Media*, 53-60.
- [4] Jungherr, A., Jürgens, P., & Schoen, H. (2012). Why the pirate party won the german election of 2009 or the trouble with predictions: A response to tumasjan, a., sprenger, to, sander, pg, & welpe, im "predicting elections with twitter: What 140 characters reveal about political sentiment". *Social Science Computer Review*, 30(2), 229-234.
- [5] Vega, C. A., Rosano, G., López, J. M., Cendejas, J. L., & Ferreira, H. Data Mining Aplicado a la Predicción y Tratamiento de Enfermedades.
- [6] García, E. G., López, R. J., Moreno, J. J. M., Abad, A. S., Blasco, B. C., & Pol, A. P. (2009). La metodología del Data Mining. Una aplicación al consumo de alcohol en adolescentes. *Adicciones*, 21(1), 65-80.
- [7] Garre, M., Cuadrado, J. J., Sicilia, M. A., Rodríguez, D., & Rejas, R. (2007). Comparación de diferentes algoritmos de clustering en la estimación de coste en el desarrollo de software. *Revista Española de Innovación, Calidad e Ingeniería del Software*, 3(1), 6-22.
- [8] Toro Ocampo, E. M., Molina Cabrera, A., & Garcés Ruiz, A. (2006). Pronóstico de bolsa de valores empleando técnicas inteligentes. *Revista Tecnura*, 9(18), 57-66.
- [9] Matamoros, O. M., Balankin, A., & Simón, L. M. H. (2005). Metodología de predicción de precios del petróleo basada en dinámica fractal. *Científica*, 9(1), 3-11.

- [10] Arango, A., Velásquez, J. D., & Franco, C. J. (2013). Técnicas de Lógica Difusa en la predicción de índices de mercados de valores: una revisión de literatura. *Revista Ingenierías Universidad de Medellín*, 12(22), 117-126.
- [11] García, M. C., Jalal, A. M., Garzón, L. A., & López, J. M. (2013). Métodos para predecir índices bursátiles. *Ecos de Economía*, 17(37).
- [12] Weron, R. (2007). Modeling and forecasting electricity loads and prices: A statistical approach (Vol. 403). John Wiley & Sons.
- [13] Sidorov, G., Miranda-Jiménez, S., Viveros-Jiménez, F., Gelbukh, A., Castro-Sánchez, N., Velásquez, F., & Gordon, J. (2013). Empirical study of machine learning based approach for opinion mining in tweets. In *Advances in Artificial Intelligence* (pp. 1-14). Springer Berlin Heidelberg.
- [14] Makazhanov, A., & Rafiei, D. (2013, August). Predicting political preference of Twitter users. In *Proceedings of the 2013 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining* (pp. 298-305). ACM
- [15] Bin Othman, M. F., & Yau, T. M. S. (2007, January). Comparison of different classification techniques using WEKA for breast cancer. In *3rd Kuala Lumpur International Conference on Biomedical Engineering 2006* (pp. 520-523). Springer Berlin Heidelberg.
- [16] Berkhin, P. (2006). A survey of clustering data mining techniques. In *Grouping multidimensional data* (pp. 25-71). Springer Berlin Heidelberg.
- [17] Carbonell, J. G., Michalski, R. S., & Mitchell, T. M. (1983). An overview of machine learning. In *Machine learning* (pp. 3-23). Springer Berlin Heidelberg.
- [18] De Ariza, M. G., & Aguilar-Martín, J. (2004). Clasificación de la personalidad y sus trastornos, con la herramienta LAMDA de Inteligencia Artificial en una muestra de personas de origen hispano que viven en Toulouse-Francia. *Revista de Estudios Sociales*, (18), 99-110.
- [19] Aguilar-Martín, J., and López De Mantaras (1982), R. The process of classification and learning the meaning of linguistic descriptors of concepts. *Approximate reasoning in decision analysis*, pp. 165–175, North Holland.



- [20] Desroches, P. Syclare (1987): *France de Classification avec Apprentissage et Reconnaissance de Formes*. Manuel d'utilisation. Rapport de recherche, entre d'estudis avançats de lanes, France, Novembre.
- [21] Piera, N., Deroches, P. and Aguilar-Martin (1989), J. LAMDA: An Incremental Conceptual Clustering Method. LAAS-CNRS, report (89420), Toulouse, France.
- [22] Medina T., Luis Eduardo (2000), *Proyecciones electorales*.