



UNIVERSIDAD DE CÓRDOBA  
ESPAÑA

Congreso Internacional y Multidisciplinar de  
**INVESTIGADORES**  
EN FORMACIÓN

18 al 21 Febrero de 2019 | Manta - Ecuador



Inserte  
foto

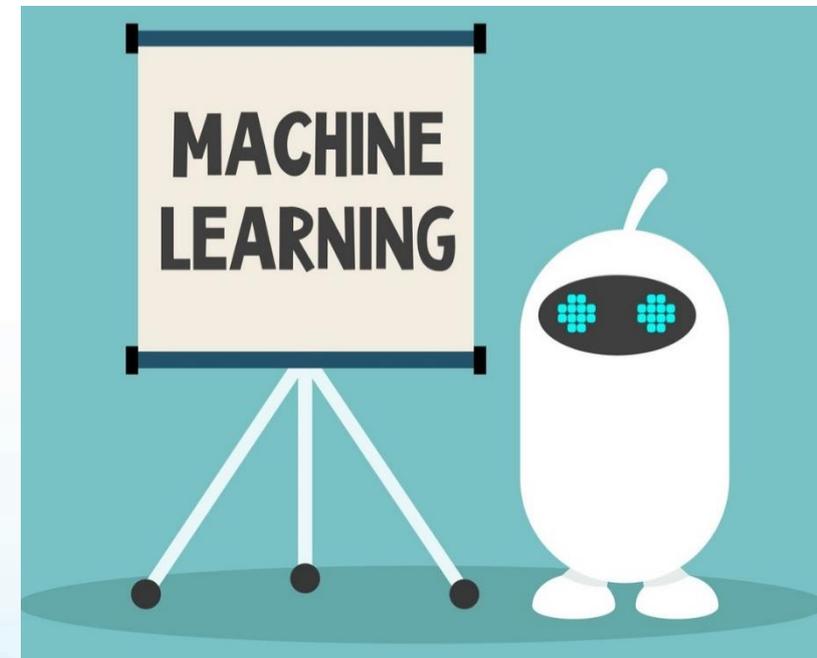
**“Aplicación de Técnicas de Machine Learning a la  
Identificación del Perfil Cognitivo en Población  
Clínica Infantil con Trastornos”**

Emanuel Guillermo Muñoz Muñoz  
Docente de la Universidad Técnica de Manabí  
Formación:  
Magister en Estadística Aplicada.  
Ing. En sistemas

e-mail: [emunoz@utm.edu.ec](mailto:emunoz@utm.edu.ec)

## Introducción

En la actualidad, la identificación del perfil cognitivo en población clínica infantil con trastornos es un tema que ha despertado el interés y motivación para investigar, ya que a través de varias técnicas y terapias se ha mejorado la calidad de vida de las personas con trastornos. En este documento se presenta una revisión teórica de las técnicas clásicas utilizadas por los expertos en trastornos de neurodesarrollo, aplicando diversas técnicas machine learning para la comparación de resultado.



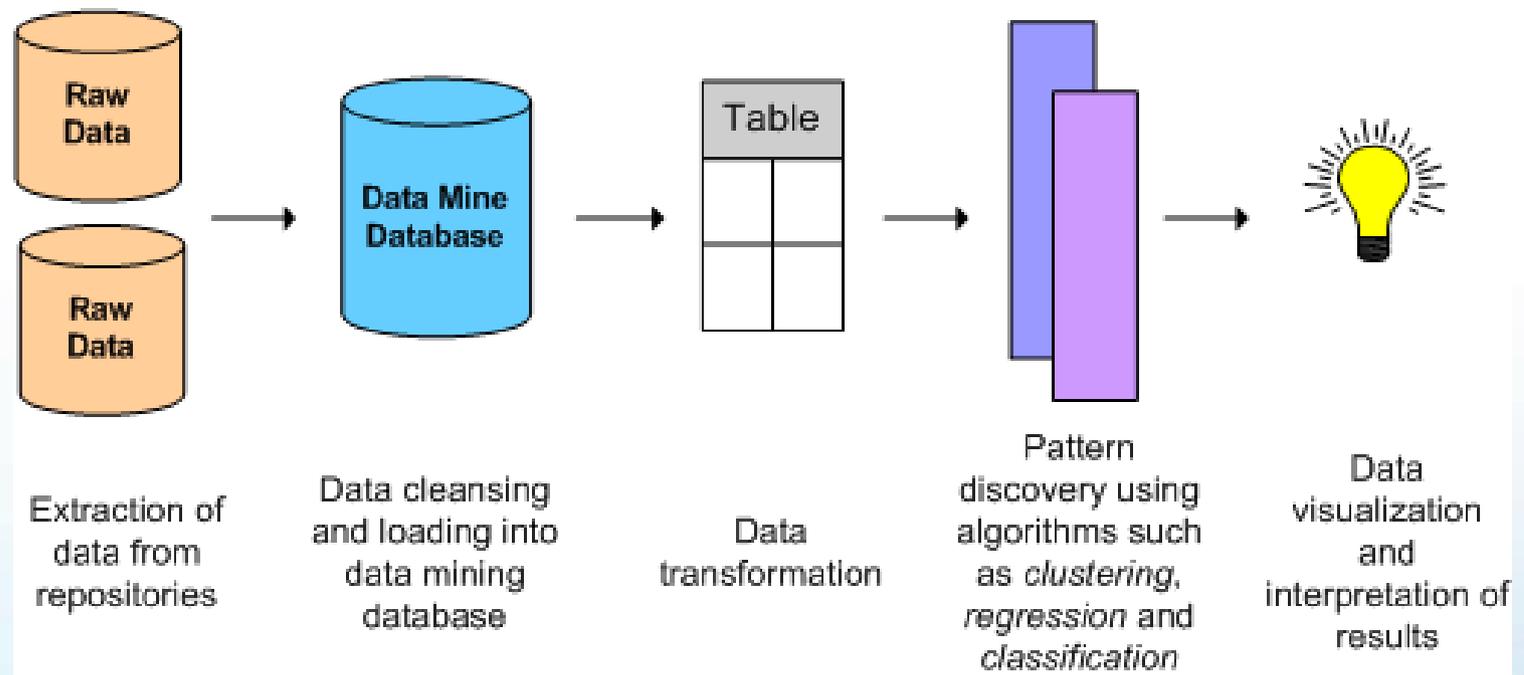
## OBJETIVO DE ESTUDIO

El presente estudio tuvo como objetivo general, identificar el Perfil Cognitivo en Población Clínica Infantil con Trastornos mediante la aplicación de Técnicas de Machine Learning.

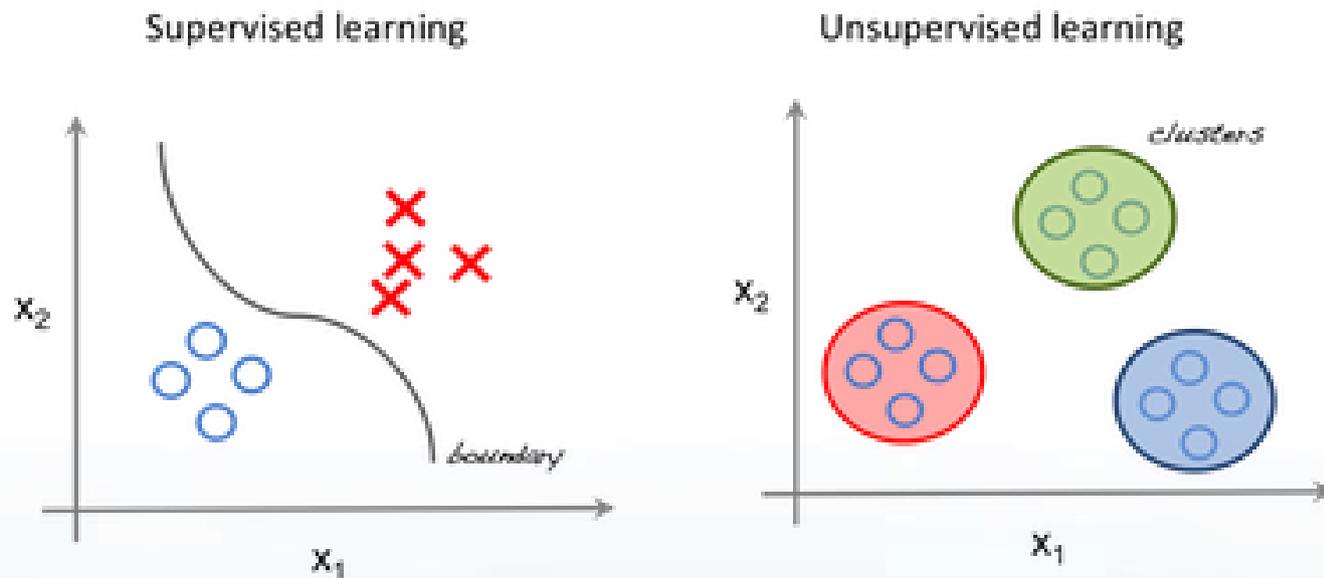
## Materiales y métodos

Los materiales utilizados para el análisis del objeto de estudio fueron la base de datos de obtenida de WISC-IV (escala de inteligencia para niños de Weschler, versión 4) y los programas Jupiter, R Studio y Excel.

## METODOLOGÍA DE LA INVESTIGACIÓN

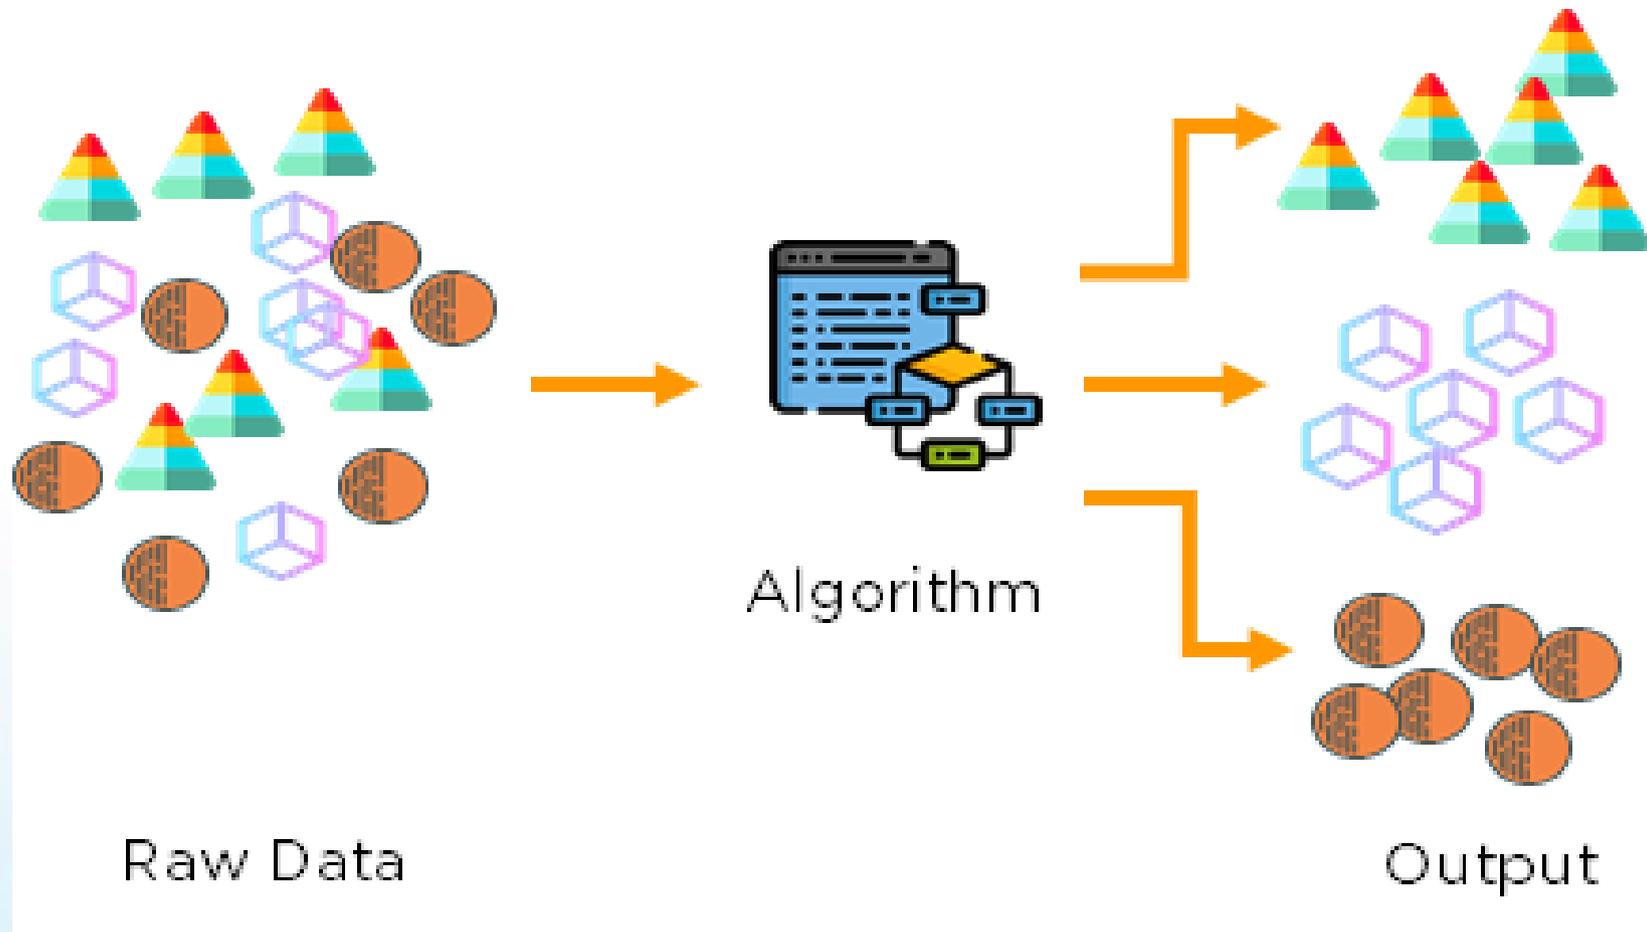


## METODOLOGÍA DE LA INVESTIGACIÓN



El aprendizaje automático es una idea para aprender de ejemplos y experiencias, sin ser programado explícitamente. En lugar de escribir código, alimenta datos al algoritmo genérico, y construye la lógica en función de los datos proporcionados.

**METODOLOGÍA DE LA INVESTIGACIÓN**

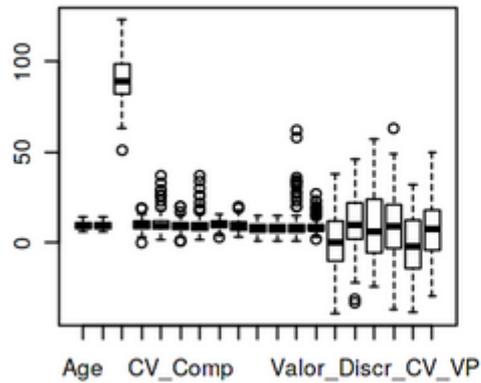




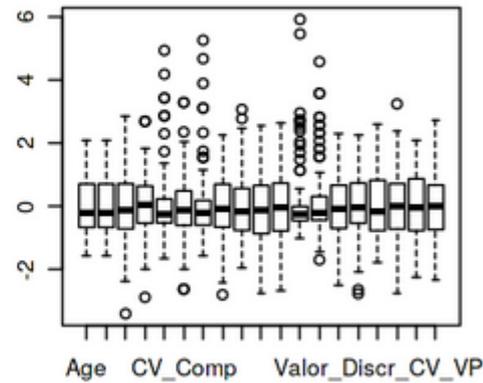


**RESULTADOS**

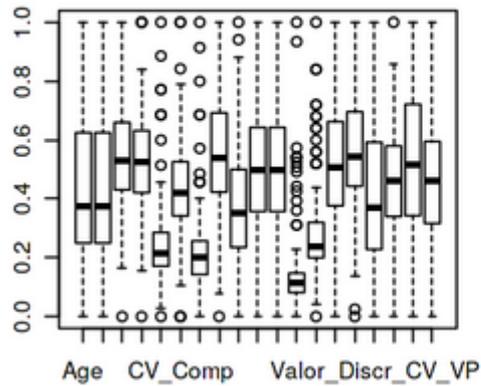
**bupa**



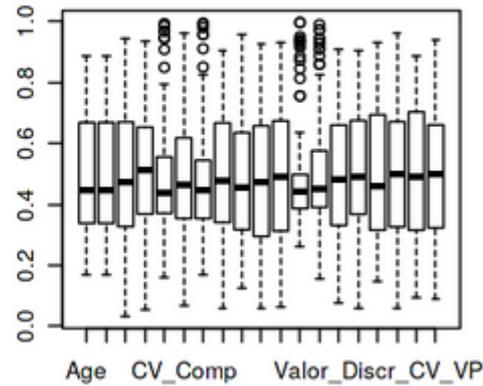
**znorm datos**



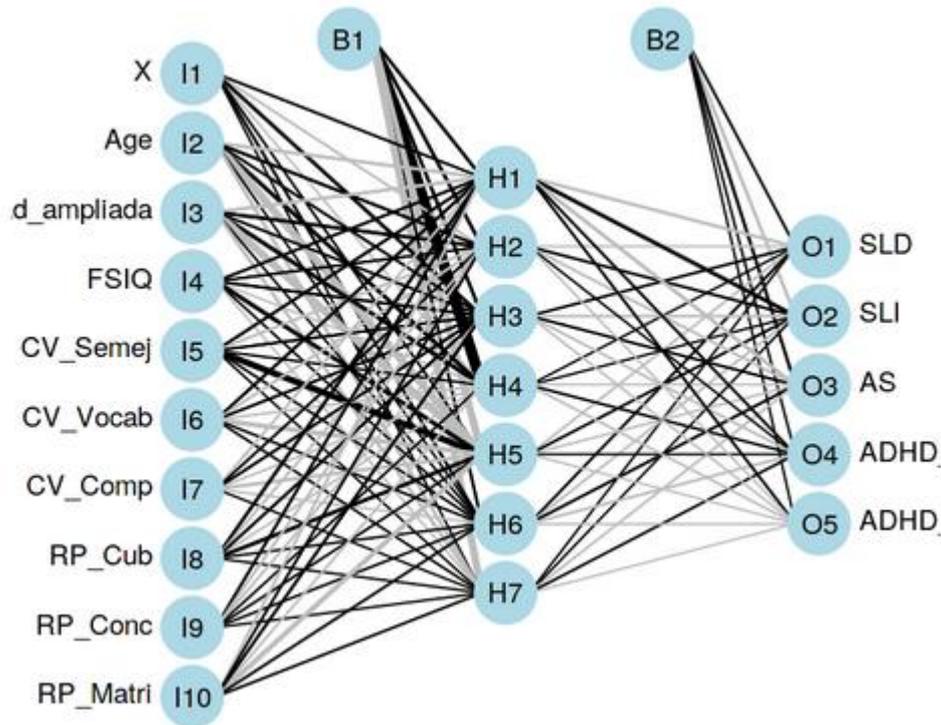
**min-max datos**



**softmax**



**RESULTADOS**



[1] "MATRIZ DE CONFUSIÓN"

```

tcd
cd  1  2  3  4  5
  1  4  0  0  0  0
  2  0  2  0  0  0
  3  0  0  7  0  0
  4  0  0  0  7  0
  5  0  0  0  0 11
  
```

```

Diagnostic
prediccion ADHD-C ADHD-PI AS SLD SLI
ADHD-C      2      1  0  0  0
ADHD-PI     8      3  1  0  2
AS          5      4  6  4  2
SLD         0      0  0  2  4
SLI         0      0  0  1  2
  
```

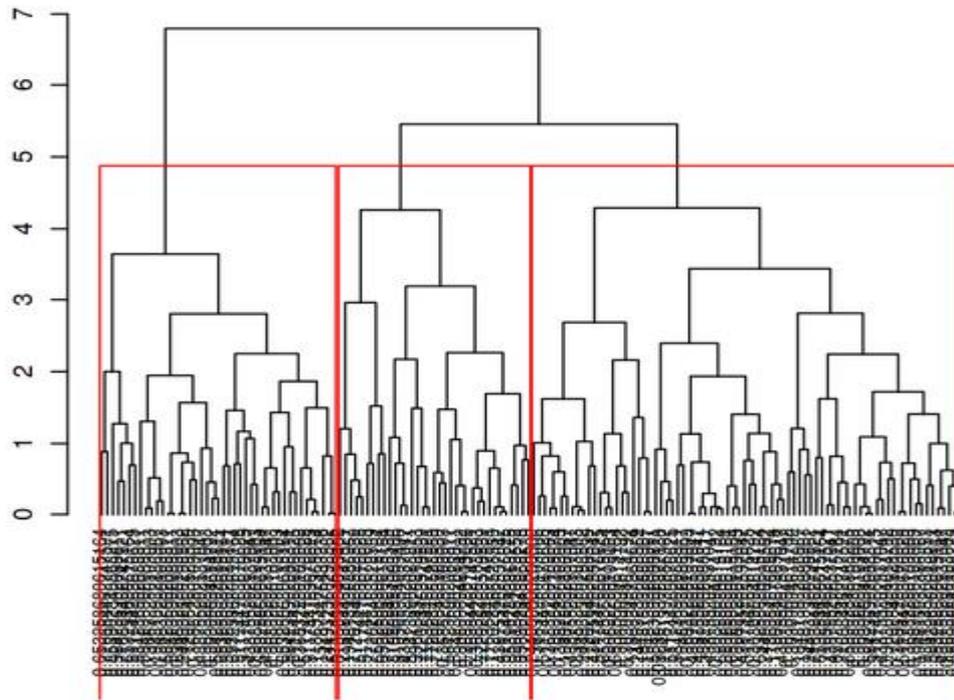
```

: # % correctamente clasificados
(correctos <- sum(diag(mc)) / nrow(datos.test) *100)
  
```

31.9148936170213

**RESULTADOS**

**Cluster sobre BASE DE DATOS**



Importance of components:

	PC1	PC2	PC3	PC4	PC5	PC6	PC7
Standard deviation	26.6676	23.7328	20.1175	13.23862	8.33259	3.68181	2.79301
Proportion of Variance	0.3596	0.2848	0.2046	0.08862	0.03511	0.00685	0.00394
Cumulative Proportion	0.3596	0.6444	0.8490	0.93765	0.97276	0.97961	0.98355
	PC8	PC9	PC10	PC11	PC12	PC13	PC14
Standard deviation	2.74659	2.45844	2.30467	2.0381	1.69614	1.65733	1.18979
Proportion of Variance	0.00381	0.00306	0.00269	0.0021	0.00145	0.00139	0.00072
Cumulative Proportion	0.98737	0.99042	0.99311	0.9952	0.99667	0.99805	0.99877
	PC15	PC16	PC17	PC18	PC19	PC20	PC21
Standard deviation	1.09907	0.81705	0.56379	0.47667	0.05013	0.03752	0.03492
Proportion of Variance	0.00061	0.00034	0.00016	0.00011	0.00000	0.00000	0.00000
Cumulative Proportion	0.99938	0.99972	0.99988	0.99999	1.00000	1.00000	1.00000
	PC22	PC23	PC24	PC25	PC26	PC27	PC28
Standard deviation	0.03324	0.03068	0.02764	0.02617	0.02489	0.0231	0.02101
Proportion of Variance	0.00000	0.00000	0.00000	0.00000	0.00000	0.0000	0.00000
Cumulative Proportion	1.00000	1.00000	1.00000	1.00000	1.00000	1.0000	1.00000
	PC29	PC30	PC31	PC32	PC33	PC34	PC35
Standard deviation	0.02016	0.01843	0.01717	0.01689	0.01615	0.01445	0.01376
Proportion of Variance	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
Cumulative Proportion	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
	PC36	PC37	PC38				
Standard deviation	0.01238	3.903e-15	1.961e-15				
Proportion of Variance	0.00000	0.000e+00	0.000e+00				
Cumulative Proportion	1.00000	1.000e+00	1.000e+00				

## DISCUSIÓN

Realizado el proceso de análisis para determinar el perfil cognitivo que presenta la población clínica infantil a través de técnicas de machine learning, se demostró que el porcentaje de eficiencia en la predicción de este algoritmo fue de 31.91%. (Quisi Peralta, 2015) (Martín Ramos, Ramos Palmer, Grau Ávalos, & García Lorenzo, 2007) indican que por tal motivo el conocimiento a profundidad de estas técnicas permite mejorar los modelos de clasificación o predicción, reducir la dimensionalidad y la selección de variables para la construcción de nuevos modelos de inferencia que mejoren la generación automática de planes específicos de terapia de lenguaje.

## CONCLUSIONES

Los resultados obtenidos en la eficiencia de predicción fueron del 31.91% tal resultado no ha sido relevante, sin poder identificar claramente los índices que afectan a los distintos trastornos.

Para conseguir mejores resultados se pretende aplicar técnicas de reprocesamiento junto con otras técnicas de machine learning como sistemas basados en reglas que nos permitan, junto con la identificación de las variables, la explicación de los resultados.



UNIVERSIDAD DE CÓRDOBA  
ESPAÑA

Congreso Internacional y Multidisciplinar de  
**INVESTIGADORES**  
EN FORMACIÓN  
18 al 21 Febrero de 2019 | Manta - Ecuador

