



## XXI Congreso Internacional sobre Innovaciones en Docencia e Investigación en Ciencias Económico Administrativas



FACULTAD DE  
CONTADURÍA Y  
ADMINISTRACIÓN

### Modelo predictivo de trayectoria escolar utilizando redes neuronales

Víctor Alonso Domínguez Ríos<sup>1</sup>, José René Arroyo Ávila<sup>2</sup>, María del Rosario de Fátima Alvídrez Díaz<sup>3</sup>

Universidad Autónoma de Chihuahua, México

Área temática:

**Formación Integral de los alumnos**

#### Resumen

Una red neuronal es una herramienta de inteligencia artificial que mediante modelos matemáticos puede ser utilizada como mecanismo predictivo de la trayectoria escolar de un estudiante. El objetivo de la investigación fue diseñar un modelo que permita predecir la trayectoria escolar de los estudiantes del área Económico-Administrativa de la Universidad Autónoma de Chihuahua, tomando como base el Test Psicométrico Multidimensional y los datos académicos de ingreso. El diseño de la investigación fue longitudinal de evolución de grupos-correlacional; la variable dependiente fue la trayectoria escolar de los estudiantes; las variables independientes fueron los resultados del Test Psicométrico Multidimensional y los datos académicos de ingreso; la unidad de análisis fueron 922 estudiantes que ingresaron en 2014 y 2015. A través del método k-medias se determinaron las dimensiones apropiadas del Test Psicométrico Multidimensional que, junto con los datos académicos de ingreso, fueron las entradas a una red neuronal de retropropagación entrenada con el algoritmo Levenberg-Marquardt, que pudo categorizar la trayectoria escolar que al compararla con la trayectoria real de esos mismos estudiantes para 2016, se tuvo una efectividad del 89.2%, mayor al 85% que se estableció como meta en la investigación.

**Palabras clave:** *redes neuronales, trayectoria escolar, computación aplicada en el comportamiento humano*

---

<sup>1</sup> Doctor en Administración, docente-investigador, (614) 142 0092, [vdomingu@uach.mx](mailto:vdomingu@uach.mx)

<sup>2</sup> Doctor en Administración, docente-investigador, (614) 427 4488, [rarroyo@uach.mx](mailto:rarroyo@uach.mx)

<sup>3</sup> Candidata a Doctor en Administración, docente-investigador, (614) 184 4587, [malvidre@uach.mx](mailto:malvidre@uach.mx)

# Modelo predictivo de trayectoria escolar utilizando redes neuronales

## Índice

INTRODUCCIÓN .....	1
1. Antecedentes .....	2
2. Planteamiento del problema .....	3
3. Justificación .....	4
4. Hipótesis .....	4
I. MARCO TEÓRICO .....	5
1. Test Psicométrico Multidimensional .....	5
2. Inteligencia artificial .....	5
II. METODOLOGÍA .....	9
1. Objetivos .....	9
2. Enfoque .....	10
3. Diseño y tipo .....	10
4. Variables e indicadores .....	10
5. Población y muestra .....	11
III. RESULTADOS .....	11
1. Análisis de las dimensiones del Test Psicométrico Multidimensional ..	11
2. Análisis de la situación de ingreso de los estudiantes .....	18
3. Determinación de los datos de entrada de la red neuronal .....	18
4. Análisis de la trayectoria escolar de los estudiantes .....	19
5. Construcción y entrenamiento de la red neuronal .....	20
6. Pruebas de la red neuronal .....	21
IV. CONCLUSIONES .....	24
Recomendaciones .....	25
BIBLIOGRAFÍA .....	26

## INTRODUCCIÓN

Una red neuronal que apoya a determinar la relación entre la trayectoria escolar de un estudiante y los resultados de su test psicométrico multidimensional, establece una categorización de alumnos que permite la toma de decisiones pertinentes respecto de su seguimiento y apoyo que un estudiante debe recibir durante sus estudios, tanto académicos como extra-académicos.

La Universidad Autónoma de Chihuahua cuenta con una base de datos de los “resultados del Test Psicométrico Multidimensional”, de “los resultados de su evaluación de ingreso” a la institución y del “promedio del nivel educativo previo (preparatoria)” de una amplia muestra de estudiantes; con esa información, se decidió entrenar una red neuronal para determinar cómo estos factores impactaron en el desempeño escolar de los estudiantes y poder compararlos con los “resultados académicos reales” de esos mismos estudiantes, una vez que trascurrieron algunos semestres de estudio. Este modelo de predicción pretende apoyar en la detección temprana de patrones de comportamiento que pudieran originar bajo rendimiento académico y tomar acciones preventivas mediante la actividad tutorial en futuras generaciones.

Para ello fue necesario establecer algunas premisas:

- La Universidad Autónoma de Chihuahua cuenta con una gran cantidad de programas educativos cuya naturaleza varía de una Unidad Académica a otra, por lo tanto, fue necesario acotar la investigación a una parte del alumnado, cuyas características fueran similares y determinar cuál información era pertinente considerar como datos de entrada a la red neuronal.
- Una vez que fueron claramente definidos los datos de entrada, fue necesario construir y entrenar la red, requiriéndose seleccionar una muestra adecuada de datos (80% de los datos con los que se contaban) de forma que la red considerara la mayor cantidad de particularidades posibles.
- Para concluir, y de acuerdo a la literatura revisada, la red neuronal fue sometida a una fase de pruebas donde se aseguró que tuviera un mínimo del 85% de efectividad.

## 1. Antecedentes

La Universidad cuenta actualmente con 15 Facultades y una oferta de 56 programas de Licenciatura, sumando 27,323 alumnos inscritos para el ciclo escolar agosto – diciembre 2017 distribuidos como se señala en la tabla 1, que a su vez muestra un comparativo con los estudiantes de los ciclos escolares agosto – diciembre 2014 y enero – junio 2015, durante los cuales se aplicó el Test Psicométrico Multidimensional. Se puede corroborar que la Facultad de Contaduría y Administración es la Unidad Académica con mayor alumnado, y si se conjunta con la Facultad de Economía Internacional, población sobre la cual se desarrolla la presente investigación, representan el 18.44% del total de la matrícula de la Universidad para el ciclo escolar agosto – diciembre 2017.

**Tabla 1.** Alumnos de nivel licenciatura en las áreas Económico-Administrativas de la Universidad Autónoma de Chihuahua

Unidad Académica	alumnos inscritos		
	ago – dic 2014	ene – jun 2015	ago – dic 2017
Contaduría y Administración	4,453	4,248	4,454
Economía Internacional	585	303	585
Total de la Universidad	27,346	26,051	27,323

*Fuente:* (Universidad Autónoma de Chihuahua, 2017).

Uno de los problemas en la Universidad, es que a pesar de que cuenta con una amplia matrícula, el número de alumnos que desertan de sus planes de estudios es alto, principalmente debido a alumnos que caen en baja definitiva por reprobación o simplemente ya no se inscriben al siguiente ciclo escolar; los datos se comportan como se observa en la tabla 2, con lo que se puede determinar que el 11.81% de los estudiantes no se inscribieron al próximo ciclo escolar en el área Económico-Administrativa, valor mayor al 10.11% para la Universidad, por lo que se detecta un problema en estas Unidades Académicas.

**Tabla 2.** Alumnos con situación de baja definitiva o reingreso no inscrito al inicia los ciclos escolares por Unidad Académica

Unidad Académica	enero – junio 2015			agosto – diciembre 2015			enero – junio 2017		
	baja definitiva	no inscritos	total	baja definitiva	no inscritos	total	baja definitiva	no inscritos	total
Contaduría y Administración	295	260	555	269	228	497	220	317	537
Economía Internacional	15	2	17	21	7	28	12	46	53
Total de la Universidad	1,643	984	2,627	1,741	960	2,701	1,260	1,502	2,762

*Fuente:* (Universidad Autónoma de Chihuahua, 2017)

## 2. Planteamiento del problema

En la Universidad Autónoma de Chihuahua, los alumnos de nuevo ingreso son asignados a un tutor académico utilizando criterios establecidos en el Programa Institucional de Tutorías, sin que los parámetros seleccionados tengan relación con la mejoría en el desempeño académico de los estudiantes. Muchos de los datos considerados para asignar un tutor provienen del registro de su ficha de admisión, que en muchas ocasiones son proporcionados con la ayuda de un tercero, lo que conlleva a que la información no sea fiable.

Si bien es cierto que es información valiosa y que puede utilizarse para muchos estudios estadísticos, es pertinente contar con un análisis más concienzudo de la situación de ingreso de cada alumno; es preciso contar información más elaborada que una simple encuesta, procesándola con nuevos mecanismos de explotación de la información que permitan formar un criterio más amplio y exacto del contexto académico, psicológico y familiar en el cual los estudiantes ingresan a la Universidad Autónoma de Chihuahua.

Las redes neuronales, representan una alternativa para la solución de problemas en los que se requiere que el aprendizaje sea orientado al desarrollo de habilidades predictivas en relación a sus datos de entrada; de esta manera, resultó interesante la idea de entrenar una red neuronal con datos previamente definidos con base en un análisis estadístico y que ésta adquiriera la capacidad de determinar la trayectoria escolar de un estudiante. De lo anterior, resulta la siguiente pregunta de investigación: *¿Cómo predecir la trayectoria escolar utilizando la información del Test Psicométrico Multidimensional y los datos académicos de ingreso de los alumnos del área Económico-Administrativa de la Universidad Autónoma de Chihuahua?*

En consecuencia, surge una serie de preguntas adicionales por responder:

- ¿Cómo seleccionar las dimensiones apropiadas del Test Psicométrico Multidimensional para construir, mediante una red neuronal, un modelo predictivo de trayectoria escolar?
- ¿Cuál es la red neuronal recomendable para diseñar el modelo predictivo de trayectoria escolar de los estudiantes?
- ¿Cómo asegurar que la red neuronal pueda utilizarse como mecanismo predictivo de la trayectoria escolar?

### 3. Justificación

Considerando el valor de la información de los alumnos del Área Económico-Administrativa, aunado a los nuevos modelos matemáticos-computacionales, existe la posibilidad de desarrollar una herramienta que conjugue de manera óptima las nuevas tecnologías para, con base en los resultados obtenidos, se puedan tomar acciones pertinentes que coadyuven al desarrollo académico de los estudiantes, elevando su desempeño escolar y reduciendo la deserción que ha venido afectando a los indicadores institucionales.

Una adecuada selección de los datos del Test Psicométrico Multidimensional en conjunto con los datos académicos de ingreso genera un ambiente propicio para detectar, de manera temprana, a los alumnos de nuevo ingreso cuyo desempeño escolar pudiera estar en situación de riesgo y dotar al **Programa Institucional de Tutorías** de herramientas confiables para asignar tutores académicos de manera anticipada, con información que le permita identificar claramente los aspectos en los cuales debe poner especial atención para lograr que el alumno realice de manera exitosa sus estudios.

Los principales beneficiados con esta investigación serán los alumnos de nuevo ingreso, quienes al momento de su incorporación a la Universidad tendrán la posibilidad de ser canalizados de manera oportuna y eficiente con expertos que, mediante un trabajo colaborativo, ayuden al estudiante a elevar su calidad educativa, del mismo modo se verán favorecidos los tutores académicos, ya que propicia la asignación de estudiantes de una manera más precisa para que pueda realizar acciones encaminadas a la mejoría de la situación escolar de los estudiantes. No menos importante, es el beneficio que obtiene la Institución al detectar de manera temprana estudiantes en posible situación de riesgo, ya que podrá implementar otras tantas acciones que le permitan elevar los índices de egreso y titulación al mismo tiempo que disminuye la deserción escolar, situación deseable en cualquier institución educativa.

### 4. Hipótesis

Hipótesis Central

Una red neuronal entrenada y probada con una efectividad mínima del 85%, puede ser utilizada como modelo predictivo de la trayectoria escolar de los estudiantes del área Económico-

Administrativa de la Universidad Autónoma de Chihuahua, recibiendo como datos de entrada el Test Psicométrico Multidimensional y datos académicos de ingreso.

#### Hipótesis Específicas

- Mediante un análisis estadístico del Test Psicométrico Multidimensional, es posible determinar las dimensiones que conforman, junto con los datos académicos de ingreso, las entradas de la red neuronal para la generación de un modelo predictivo.
- La red neuronal recomendable para diseñar el modelo predictivo de trayectoria escolar es el de retropropagación.
- La red neuronal logrará una efectividad mínima del 85% en la fase de pruebas, lo cual indica que es confiable para utilizarse como mecanismo predictivo.

### **I.- MARCO TEÓRICO**

#### **1. Test Psicométrico Multidimensional**

El Test Psicométrico Multidimensional (TPM), es un instrumento que evalúa de manera integral, práctica y confiable un perfil de 160 competencias y factores de inteligencia, personalidad y valores inter-dimensionales para sustentar la orientación psicopedagógica y los programas institucionales de tutoría. Tiene el valor agregado de haberse diseñado, validado y estandarizado especialmente para el contexto mexicano con excelentes índices de confiabilidad (Turborienta, 2014).

#### **2. Inteligencia Artificial**

La expresión Inteligencia Artificial, suele referirse a la simulación computacional de procesos cognitivos; en particular, los trabajos que se han desarrollado en inteligencia artificial abarcan diversas áreas de investigación, tales como la simulación de capacidades perceptuales y habilidades psicomotoras, la comprensión del lenguaje natural y la construcción de sistemas informáticos capaces de emular la pericia de un experto humano en un ámbito de conocimiento determinado (Negrete, 1992). Tiene por objeto el estudio del comportamiento inteligente en las máquinas; que supone percibir, razonar, aprender, comunicarse y actuar en entornos complejos. Una de las metas a largo plazo de esta área es el desarrollo de máquinas que puedan hacer todas estas cosas igual, o quizá incluso mejor, que los humanos (Nilsson, 2001). Una técnica de inteligencia artificial es un método que explora el conocimiento que debe ser representado de tal

manera que el conocimiento capture generalizaciones, puede ser comprendido por personas que deben proporcionarlo, puede ser fácilmente modificado para corregir errores y para reflejar los cambios en el mundo y en la visión del mundo, puede ser utilizado en una gran cantidad de situaciones incluso si no es totalmente exacto o completo, para ayudar a superar su propio volumen, ayudando a acotar el rango de posibilidades que normalmente deben ser consideradas (Rich & Knight, 1991).

Existen varios elementos que componen la Inteligencia Artificial, dentro de los cuales se pueden encontrar tres grandes ramas:


- **Lógica difusa.** Mientras que la teoría de conjuntos tradicional define al miembro de un conjunto como un predicado booleano, la teoría de conjuntos difusa permite representar el miembro como un conjunto de una distribución de probabilidades (Rich & Knight, 1991). Se parte del hecho de que conceptos como alto, bajo, ruidoso, dulce, caro, amargo, barato, delgado, son percibidos de manera diferente por cada persona, por esta razón los conjuntos caliente, tibio y frío son llamados conjuntos difusos. (Guzmán & M. Castaño, 2015).
- **Algoritmos genéticos.** Los algoritmos genéticos se basan en la mecánica de la selección natural y la genética para evolucionar una población inicial de puntos o individuos hacia mejores regiones del espacio de búsqueda. La evolución de la población se realiza mediante la aplicación de operadores genéticos probabilísticos de selección, cruzamiento y mutación. Los algoritmos genéticos requieren conocer solamente el valor de la función objetivo en la población de puntos y no sus derivadas (Estévez Valencia, 1997). Los algoritmos genéticos han usado tradicionalmente una representación más independiente del dominio, normalmente cadenas binarias, sin embargo, muchas aplicaciones recientes han usado otras representaciones tales como: grafos, expresiones Lisp, listas ordenadas o vectores de parámetros reales (Palma Méndez & Marín Morales, 2008).
- **Redes neuronales artificiales.** Las redes neuronales artificiales son aproximaciones no lineales a la forma en que funciona el cerebro. Se definen como sistemas de mapeos no lineales cuya estructura se basa en principios observados en los sistemas nerviosos humanos y animales; constan de un gran número de procesadores simples ligados por conexiones con “pesos”. Las unidades de procesamiento se llaman neuronas; cada unidad recibe entradas de otros nodos y genera una salida simple escalar que depende de la información local disponible, guardada internamente o que llega a través de las conexiones con pesos (Ponce



Cruz, 2010). En virtud de que el enfoque de la investigación es sobre la utilización de redes neuronales, se dará a continuación mayor información sobre esta temática.

Cada una de las neuronas que conforman la red, recibe un conjunto de entradas ( $x_1, x_2, x_3 \dots x_n$ ) y devuelve una salida  $y$ . además, dentro de una red neuronal existen numerosas conexiones entre las distintas neuronas que la forman, las cuales simulan las conexiones interneuronales del cerebro, y al igual que éstas, pueden establecerse con mayor o menor intensidad, la cual determina los pesos sinápticos. De este modo cada entrada  $x_i$  de una neurona se encuentra afectada por un peso  $w_i$  tal como se observa en la figura 1 (Palma Méndez & Marín Morales, 2008).

**Figura 1.** Modelo de una neurona artificial



Fuente: (Palma Méndez & Marín Morales, 2008)

Una red neuronal se caracteriza por que contiene los siguientes elementos:

- Conjunto de unidad de procesamiento o neuronas.
- Estado de activación para cada unidad, equivalente a la salida de la unidad.
- Conexiones entre las unidades, generalmente definidas por un peso que determina el efecto de una señal de entrada en la unidad.
- Una regla de propagación, que termina la entrada efectiva de una unidad a partir de las entradas externas.
- Una función de activación que actualiza el nuevo nivel de activación basándose en la entrada efectiva y la activación anterior.
- Una entrada externa que corresponde a un término determinado como bías para cada unidad.
- Un método para reunir la información, correspondiente a la regla de aprendizaje.
- Un ambiente en el que el sistema va a operar, con señales de entrada e incluso señales de error (Ponce Cruz, 2010).

Al igual que el cerebro humano, una red neuronal busca el aprendizaje. Este proceso, consiste en hallar los pesos que codifican los conocimientos. Una regla de aprendizaje hace variar el valor de los pesos de una red hasta que estos adoptan un valor constante, cuando esto ocurre se dice que la red ya "ha aprendido" (Sotolongo & Guzmán, 2001). Suponiendo que la red tiene un número suficiente de neuronas, podrá ajustar cualquier función continua con una cierta precisión con tan sólo escoger los valores adecuados para los parámetros ajustables de dicha red. Estos parámetros son los pesos, y representan el medio que la red emplea para almacenar su conocimiento sobre el problema a resolver a través del proceso de entrenamiento, que no es más que la modificación de los parámetros de la red mediante un procedimiento preestablecido, con la finalidad de conseguir una mejora en su rendimiento (Palma Méndez & Marín Morales, 2008).

El aprendizaje de una red neuronal puede ser de dos tipos:


- Aprendizaje supervisado: consiste en hacer predicciones a futuro basadas en comportamientos o características que se han visto en los datos ya almacenados (el histórico de datos); permite buscar patrones en datos históricos relacionando todos los campos con un campo especial, llamado campo objetivo (González, 2014).
- Aprendizaje no supervisado: es un método de aprendizaje automático donde un modelo es ajustado a las observaciones; se distingue por el hecho de que no hay un conocimiento a priori. El aprendizaje no supervisado típicamente trata los objetos de entrada como un conjunto de variables aleatorias, siendo construido un modelo de densidad para el conjunto de datos. Todos los algoritmos de compresión dependen tanto explícita como implícitamente de una distribución de probabilidad sobre un conjunto de entrada (Flores Gutiérrez, 2013).

Para la investigación se decidió probar diferentes métodos de aprendizaje y, con base en los resultados que fueron dándose, se decidió utilizar un algoritmo de entrenamiento con aprendizaje supervisado del tipo *Red backpropagation* o de *retropropagación*, que es probablemente la más conocida y ampliamente utilizada entre los tipos actuales de sistemas de redes neuronales disponibles. Concretamente, una red *backpropagation* aprende un mapeo desde un conjunto de patrones de entrada a un conjunto de patrones de salida. Esta capacidad proviene de las neuronas de la capa o capas ocultas de la red que aprenden a responder a las características encontradas en los patrones de entrada. Las características reconocidas o extraídas por las neuronas ocultas corresponden a la correlación de actividad entre diferentes neuronas de entrada.

En la figura 2, se muestra el principio de una red neuronal de retropropagación, en donde las salidas de error se propagan hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de las capas ocultas que contribuyen directamente a la salida. Sin embargo, las neuronas de las capas ocultas, solo reciben una fracción de la señal total del error basándose aproximadamente en la contribución relativa que haya aportado cada neurona a la salida original.

Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución relativa al error total. Basándose en la señal de error percibida, donde se actualizan los pesos de conexión de cada neurona, para hacer que la red converja hacia un estado que permita clasificar correctamente todos los patrones de entrenamiento (García Martínez, Pasquini, & Servente, 2003).

**Figura 2.** Red neuronal backpropagation o de retropropagación



Fuente: (Fu, 1994)

## II. METODOLOGÍA

### 1. Objetivos

El **objetivo general** de la investigación fue diseñar un modelo para predecir la trayectoria escolar de los estudiantes del área Económico-Administrativa de la Universidad Autónoma de Chihuahua, tomando como base el Test Psicométrico Multidimensional y los datos académicos de ingreso.

Los **objetivos específicos** fueron:

- Seleccionar las dimensiones apropiadas del Test Psicométrico Multidimensional para construir, mediante una red neuronal, un modelo predictivo de trayectoria escolar.
- Determinar la red neuronal recomendable para diseñar el modelo predictivo de trayectoria escolar, probando diversos tipos de algoritmos.

- Asegurar que la red neuronal pueda utilizarse como un modelo predictivo de la trayectoria escolar, logre una eficiencia mínima del 85% en la fase de pruebas.

## 2. Enfoque

El enfoque de la investigación fue cuantitativa ya que se asignaron valores numéricos a los indicadores con la finalidad de manejarlos estadísticamente; los resultados se interpretaron desde el punto de vista de los investigadores.

## 3. Diseño y Tipo

El diseño de la investigación fue longitudinal de evolución de grupos - correlacional, ya que los datos se recolectaron durante dos ciclos escolares (período de tiempo) con la finalidad de que el entrenamiento que recibe la red neuronal fuera más completo y contara con aspectos del ciclo escolar. El tipo de investigación fue correlacional, ya que busca a través de una red neuronal determinar la relación existente entre los resultados del Test Psicométrico Multidimensional, los datos académicos de ingreso y la trayectoria escolar de los estudiantes y a partir de dicha relación tener la capacidad de predecir el comportamiento académico de nuevos estudiantes de los cuales solo se conoce los resultados de las dos primeras variables.

## 4. Variables e indicadores

Las **variables independientes** de la investigación fueron:

- Resultados del Test Psicométrico Multidimensional
- Datos académicos de ingreso de los estudiantes

La **variable dependiente** del estudio fue:

- Trayectoria escolar de los estudiantes

Los indicadores que integran la variable *resultados del Test Psicométrico Multidimensional* son: coeficiente intelectual, competencias intelectuales y académicas, mapa académico, habilidades mentales, estilos de aprendizaje, inteligencias múltiples y programación mental. Los indicadores que integran la variable *datos académicos de ingreso de los estudiantes* son: resultado de evaluación de ingreso y promedio del nivel académico anterior (preparatoria), promedio del

primer ciclo escolar e índice de aprobación del mismo. Los indicadores que integran la variable *trayectoria escolar de los estudiantes* son: desempeño escolar y situación escolar.

## 5. Población y muestra

La población considerada en el estudio fueron estudiantes de las Áreas Económico – Administrativas. La unidad de análisis para la investigación fueron 922 estudiantes que ingresaron durante los ciclos agosto-diciembre de 2014 y enero-junio de 2015, de quienes se cuenta con los datos académicos de trayectoria escolar (año 2017). El tipo de muestreo fue a través de censo (muestreo total).

El trabajo de investigación se realizó en Chihuahua, Chih., de septiembre 2015 a diciembre 2017.

## III. RESULTADOS

### 1. Análisis de las dimensiones del Test Psicométrico Multidimensional

De acuerdo a la información obtenida por el Test Psicométrico Multidimensional, se analizó de manera precisa con el afán de determinar los datos de entrada a la red, para ello se agruparon los resultados en 8 dimensiones como lo indica la figura 3.

**Figura 3.** Dimensiones del Test Psicométrico Multidimensional



*Fuente:* Propia de los autores.

Cada una de las dimensiones, estuvo integrada por varios factores, los cuales fueron analizados con el Paquete Estadístico para las Ciencias Sociales SPSS, utilizando el método *k-medias*, el cual tiene como objetivo la partición de un conjunto de  $n$  observaciones en  $k$  grupos en el que cada observación pertenece al grupo más cercano a la media. Para el caso de 7 de las 8

dimensiones la conglomeración de datos fue en 5 grupos, donde cada uno de ellos corresponde a las clasificaciones *bajo*, *intermedio-bajo*, *intermedio*, *intermedio-alto* y *alto*. En la dimensión restante, *estilos de aprendizaje*, se generaron únicamente tres grupos, correspondientes a las categorías *bajo*, *intermedio* y *alto*, debido a la uniformidad que presentan los datos.


La tabla 3 muestra los valores para cada uno de los 5 grupos generados para **Coefficiente Intelectual**, teniendo correspondencia con la información que se observa en la figura 3.

**Tabla 3.** Agrupamiento de los factores que integran el coeficiente intelectual utilizando el Método K-medias.

Coeficiente Intelectual	Grupos				
	Bajo	Intermedio - bajo	Intermedio	Intermedio – alto	Alto
Coeficiente Intelectual Nativo	57.2	66.0	81.7	86.1	99.9
Coeficiente Intelectual	58.4	66.2	81.7	86.1	100.0
Inteligencia Emocional	63.2	83.8	92.8	72.3	94.5
Hemisferio Izquierdo	3.8	4.4	5.3	5.3	6.4
Hemisferio Derecho	3.9	4.5	5.0	4.4	5.2
Cerebro Reptílico	5.5	6.7	7.3	6.1	7.3
Corteza Cerebral	3.7	5.2	6.2	4.6	6.3
Cerebro Límbico	5.5	5.7	5.7	5.7	5.7

Fuente: Propia de los autores

**Figura 3.** Clasificación del coeficiente intelectual de los estudiantes



Fuente: Propia de los autores

Una gran cantidad de alumnos están clasificados en las categorías de *intermedio* e *intermedio-bajo*, inclusive 96 estudiantes resultaron catalogados en el rango de *bajo* por lo que esta dimensión pudiera tener gran impacto en la trayectoria escolar de los estudiantes.


La tabla 4 muestra los valores para cada uno de los 5 grupos generados para **Inteligencias Múltiples**, teniendo correspondencia con la información que se observa en la figura 4.

**Tabla 4.** Agrupamiento de los factores que integran las inteligencias múltiples

Inteligencias Múltiples	Grupos				
	Bajo	Intermedio – bajo	Intermedio	Intermedio - alto	Alto
Lingüística	4.7	4.7	6.1	6.2	6.1
Lógica- matemática	3.7	3.5	5.4	6.4	5.5
Espacial	3.6	3.5	4.7	5.6	4.9
Musical	1.7	3.1	5.9	2.2	7.0
Corporal	3.3	4.8	4.4	4.4	5.5
Interpersonal	4.2	6.7	4.1	6.3	7.3
Intrapersonal	5.8	6.9	5.8	6.8	7.2

Fuente: Propia de los autores

**Figura 4.** Clasificación de las inteligencias múltiples de los estudiantes



Fuente: Propia de los autores

La figura 4, resalta que las categorías *bajo* e *intermedio-bajo* acumulan una gran cantidad de estudiantes y, por el contrario, la categoría de *alto* tiene una frecuencia muy baja, por lo que esta dimensión resulta ser más preocupante por el impacto que pudiera tener en la trayectoria escolar de los estudiantes.


La tabla 5 muestra los valores para cada uno de los 5 grupos generados para **Competencias Intelectuales**, teniendo correspondencia con la información que se observa en la figura 5.

**Tabla 5.** Agrupamiento de los factores que integran las competencias intelectuales

Competencias Intelectuales	Grupos				
	Bajo	Intermedio - bajo	Intermedio	Intermedio - alto	Alto
Percepción	2.9	3.8	4.9	4.9	6.0
Análisis	3.5	4.0	5.9	5.2	7.0
Síntesis	3.7	4.1	5.9	5.1	6.8
Razonamiento Abstracto	3.5	4.1	4.5	4.8	5.5
Comprensión	4.0	4.3	6.4	5.4	7.4
Aprendizaje	3.9	4.2	5.6	5.2	6.5
Memoria	4.3	4.6	4.6	5.1	5.1
Adaptabilidad	4.7	5.6	5.3	6.2	6.2
Creatividad	2.7	3.5	4.1	4.3	5.1
Anticipación	4.4	6.0	5.0	6.7	6.7
Persuasión	3.7	5.6	3.9	6.7	6.3
Planeación y toma de decisiones	4.2	5.4	4.9	6.2	6.3
Velocidad intelectual	3.7	4.1	5.0	5.0	5.8

Fuente: Propia de los autores

**Figura 5.** Clasificación de las competencias intelectuales de los estudiantes



Fuente: Propia de los autores

En las *competencias intelectuales*, la propensión de los estudiantes apunta a un nivel *intermedio-bajo*; resalta una tendencia hacia el lado izquierdo que aunado al hecho de que son competencias básicas para un desempeño exitoso en los estudios, esta dimensión resulta amenazante en la trayectoria escolar.


La tabla 6 muestra los valores para cada uno de los 5 grupos generados para **Programación Mental**, teniendo correspondencia con la información que se observa en la figura 6.

**Tabla 6.** Agrupamiento de los factores que integran la programación mental

Programación Mental	Grupos				
	Bajo	Intermedio - bajo	Intermedio	Intermedio - alto	Alto
Mentalidad propositiva (optimista)	3.0	4.7	6.0	7.0	8.1
Autoprogramación subconsciente	3.0	4.4	5.3	6.2	7.3
Sinergia emocional – intelectual	2.7	4.2	5.2	6.0	7.0
Aprovechamiento de su capacidad de mentalización	2.7	4.7	5.1	6.1	7.8
Capacidad de automotivación	3.0	4.4	5.4	6.3	7.4

Fuente: Propia de los autores

**Figura 6.** Clasificación de la programación mental de los estudiantes



Fuente: Propia de los autores



Observando la información en la figura 6 es posible determinar que la mayor parte de los alumnos están ubicados en las categorías de *intermedio*, *intermedio-alto* y *alto*, por lo que esta dimensión no representa un riesgo para los estudiantes.

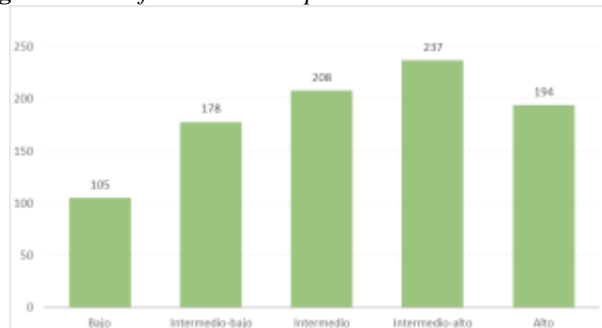
La tabla 7 muestra los valores para cada uno de los 5 grupos generados para *Mapa Académico*, teniendo correspondencia con la información que se observa en la figura 8.

**Tabla 7.** Agrupamiento de los factores que integran el mapa académico.

Mapa Académico	Grupos				
	Bajo	Intermedio – bajo	Intermedio	Intermedio - alto	Alto
Aptitud académica	4.5	4.7	5.4	5.2	6.0
Actitud académica	3.5	4.1	6.2	5.5	7.2
Dinámica interpersonal	4.7	6.2	5.6	6.9	7.4
Disposición a la autoridad	4.4	5.0	5.7	6.0	6.7
Interrelación con los (as) maestros	4.9	5.3	5.8	6.0	6.9
Interrelación con compañeros (as)	4.3	6.4	4.9	7.3	7.8

Fuente: Propia de los autores

**Figura 7.** Clasificación del mapa académico de los estudiantes



Fuente: Propia de los autores

Es notable una tendencia de la información hacia el lado derecho, lo que indica que en esta dimensión la mayor parte de los estudiantes tiene valores muy aceptables, de ahí que el impacto en la deserción de esta categoría no presenta mayor trascendencia.

La tabla 8 muestra los valores para cada uno de los 5 grupos generados para *Competencias Académicas*, teniendo correspondencia con la información que se observa en la figura 8.

La gráfica muestra mayor cantidad de estudiantes ubicados en el lado izquierdo (*bajo* e *intermedio-bajo*) que en el lado derecho (*alto* e *intermedio-alto*), esto sin considerar que la categoría con mayor frecuencia es *intermedio*, situación que no es tan deseable.

**Tabla 8.** Agrupamiento de los factores que integran las competencias académicas.

Competencias Académicas	Grupos				
	Bajo	Intermedio – bajo	Intermedio	Intermedio - alto	Alto
Inclinación hacia el “trabajo bien hecho”	4.1	4.5	5.3	6.2	6.4
Hábitos de estudio	3.6	4.0	4.7	5.8	5.8
Liderazgo positivo	3.6	4.6	4.9	5.8	6.3
Trabajo en equipo	4.8	5.4	5.9	6.6	6.7
Responsabilidad	4.4	4.5	5.3	6.0	6.1
Adaptabilidad	3.9	4.0	4.9	5.6	5.8
Liderazgo negativo	3.7	6.1	4.1	3.3	5.6

Fuente: Propia de los autores

**Figura 8.** Clasificación de las competencias académicas de los estudiantes



Fuente: Propia de los autores

La tabla 9 muestra los valores para cada uno de los 5 grupos generados para **Habilidades Mentales**, teniendo correspondencia con la información que se observa en la figura 9.


**Tabla 9.** Agrupamiento de los factores que integran las habilidades mentales.

Habilidades Mentales	Grupos				
	Bajo	Intermedio – bajo	Intermedio	Intermedio - alto	Alto
Razonamiento numérico	3.0	4.3	5.6	5.3	7.3
Razonamiento verbal	4.6	5.3	6.4	5.3	7.1
Razonamiento abstracto	4.4	5.3	4.8	5.4	5.5
Razonamiento concreto	3.5	4.9	5.4	5.9	6.8
Razonamiento lógico	5.3	6.1	7.0	7.2	7.9
Razonamiento espacial	2.7	3.8	3.6	6.7	6.2
Memoria	4.2	4.8	4.8	4.6	5.1
Creatividad	2.7	3.8	3.7	4.7	5.0
Lectura	4.6	5.3	5.8	5.2	6.4
Concentración	4.4	5.3	5.7	6.1	6.8
Comprensión	4.8	5.5	6.9	6.6	7.9
Síntesis	5.6	6.1	7.2	7.0	8.1

Fuente: Propia de los autores

En los 5 grupos generados para el análisis, queda al descubierto de nueva cuenta, que las categorías de *bajo* e *intermedio-bajo* acumulan una gran cantidad de estudiantes encontrándose cargada la información hacia el lado izquierdo, lo que demuestra ser una dimensión a considerar.

**Figura 9.** Clasificación de las habilidades mentales de los estudiantes



Fuente: Propia de los autores


La tabla 10 muestra los valores para cada uno de los 3 grupos generados para *Estilos de Aprendizaje*, teniendo correspondencia con la información que se observa en la figura 10.

**Tabla 11.** Agrupamiento de los factores que integran el estilo de aprendizaje.

Estilos de Aprendizaje	Grupos		
	Bajo	Intermedio	Alto
Teórico	4.2	6.2	4.4
Experimental	5.4	6.1	6.4
Kinestésico	4.2	3.2	4.3
Auditivo	2.7	2.9	2.6
Visual	4.4	5.6	4.5
Memorizado	3.6	5.7	3.6
Comprendido	6.4	4.5	6.4
Concreto	6.8	6.8	7.3
Abstracto	4.6	4.7	5.6
Espontáneo	8.3	2.7	1.1
Sistemático	1.7	7.3	8.9
Textual	6.4	3.7	7.7
Imágenes	4.7	7.2	3.9

Fuente: Propia de los autores

**Figura 11.** Clasificación del desarrollo de los estilos de aprendizaje de los estudiantes



Fuente: Propia de los autores

Debido a que la mayor cantidad de la información se encuentra muy cerca de la media se optó por generar por el método de *k-medias* únicamente tres grupos identificados como *alto*,

*intermedio y bajo*. Como se muestra en la figura 11 no existe mucha diferencia entre un grupo y otro, por lo que esta dimensión no tiene impacto en la trayectoria escolar de los estudiantes.

## 2. Análisis de la situación de ingreso de los estudiantes

Derivado del análisis que se llevó a cabo con las dimensiones del Test Psicométrico Multidimensional, fue necesario realizar el mismo proceso con los datos académicos de ingreso de los estudiantes integrados por los resultados del Examen Nacional de Ingreso a la Educación Superior EXANI II del CENEVAL o del módulo introductorio para los alumnos de educación a distancia, los cuales se encuentran ponderados en la misma escala y el promedio general del nivel académico anterior, que para este caso es el nivel medio superior, el cual se muestra en la tabla 12.

**Tabla 12.** Agrupamiento de los datos académicos de ingreso

Datos Académicos de Ingreso	Grupos				
	Bajo	Intermedio - bajo	Intermedio	Intermedio – alto	Alto
Promedio Nivel Medio Superior	8.18	7.97	7.95	8.37	8.50
Evaluación de Ingreso	969.98	972.52	1080.17	1072.10	1178.920

Fuente: Propia de los autores

**Figura 12.** Clasificación de los datos académicos de ingreso de los estudiantes



Fuente: Propia de los autores

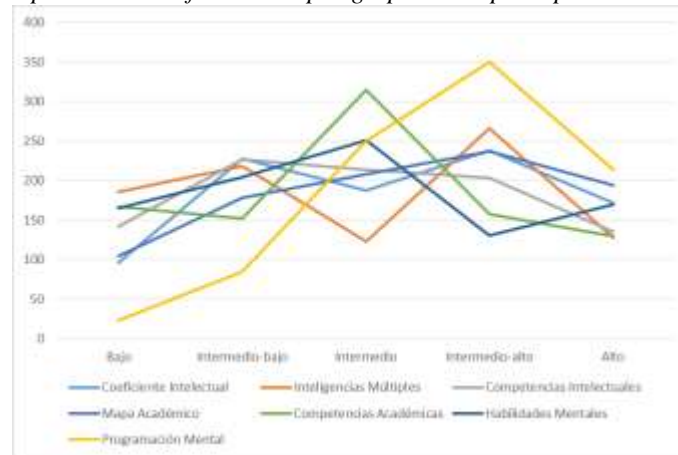
En la figura 12 se muestra la gran cantidad de estudiantes clasificados con un nivel *bajo* e *intermedio-bajo* en su evaluación de ingreso, de ahí la necesidad de integrar estos datos como parte de la entrada a la red neuronal.

## 3. Determinación de los datos de entrada de la red neuronal

Luego de analizar por separado cada una de las dimensiones que integran el Test Psicométrico Multidimensional, resultó conveniente realizar una comparación entre ellas, la figura 13 muestra la información en donde no fué incluida la dimensión *estilos de aprendizaje* por estar la

distribución uniforme y dividida únicamente en tres grupos, cuando para el resto de las dimensiones se utilizaron cinco.

**Figura 13.** Comparativo de la frecuencia por grupo de las principales dimensiones del TPM



Fuente: Propia de los autores


Para seleccionar los datos de entrada de la red, al realizar un análisis de lo antes analizado, se desprende que las *competencias académicas* y las *competencias intelectuales* tienen un comportamiento preocupante, al tener muchos alumnos clasificados como *bajo* e *intermedio-bajo*, por lo que son seleccionadas para formar parte de la entrada de la red neuronal. El *coeficiente intelectual*, el *mapa académico* y la *programación mental* tuvieron un comportamiento positivo, por lo que se deduce que la mayor parte de los estudiantes no tienen problema con estas dimensiones, por lo que quedan descartadas para formar parte de la entrada de la red. De las dimensiones pendientes: *inteligencias múltiples* y *habilidades mentales*, podrían ser incluidas, sin embargo, dado que cada una de ellas tiene varios factores que la integran, fue conveniente seleccionar sólo *habilidades mentales*, con la finalidad de que el entrenamiento de la red fuera más dirigido y por lo tanto la predicción sea más exacta y con un menor procesamiento. La información académica de ingreso también formó parte de los datos de entrada de la red.

#### 4. Análisis de la trayectoria escolar de los estudiantes

Conviene en este punto mostrar un análisis de la trayectoria escolar de los estudiantes cuyos datos integran los datos de salida a la red neuronal, ya que la idea de utilizar esta herramienta de la inteligencia artificial es mejorar las condiciones académicas de los estudiantes.

La figura 14, muestra la distribución del desempeño y la situación escolar de los estudiantes. Para el caso del *Desempeño Escolar* se detecta que es donde hay más problema, ya que el 26% de los estudiantes se encuentran clasificados como *bajo*. La *Situación Escolar* no es alarmante debido a que solo el 5% de los estudiantes presentan un rezago, sin embargo, si se acumula con el 32% que se encuentran de manera irregular, da como resultado un dato a considerar. Al conjuntar ambas figuras, da como resultado la trayectoria escolar de los estudiantes, ubicándolos en alguna de las categorías indicadas en la propia figura, en donde el 40% de los estudiantes presentan algún grado de riesgo.

**Figura 14.** Indicadores y clasificación que integran la Trayectoria Escolar



Fuente: Propia de los autores

Los datos de la clasificación de la trayectoria escolar representan los datos de salida de la red neuronal, clasificados numéricamente de acuerdo con la tabla 13.

**Tabla 13.** Datos de salida de la red neuronal

Valor Numérico	Clasificación de la Trayectoria Escolar
1	Riesgo Alto
2	Riesgo
3	Riesgo Bajo
4	Sin Riesgo

Fuente: Propia de los autores


## 5. Construcción y entrenamiento de la red neuronal

La red neuronal implementada, es una red con retropropagación (*backpropagation*); que utiliza el algoritmo *trainlm* de Matlab, el cual es una función de entrenamiento de redes que actualiza los valores de los pesos y sesgo según la optimización *Levenberg-Marquardt* cuyo funcionamiento se describe en la sección correspondiente. *Trainlm* es el algoritmo más rápido de retropropagación contenido en Matlab, que admite la formación con vectores de validación y prueba, los vectores de validación se usan para detener el entrenamiento temprano si el

rendimiento de la red en los vectores de validación no mejora o permanece. Los vectores de prueba se utilizan como una comprobación adicional de que la red está generalizando bien, pero no tienen ningún efecto en el entrenamiento. Este algoritmo puede entrenar cualquier red siempre y cuando su peso, su entrada neta y sus funciones de transferencia tengan funciones derivables ( The MathWorks, Inc., 2017).

La figura 15 muestra la arquitectura de la red neuronal, indicando la cantidad de entradas, salidas, capas ocultas, número de neuronas por capas y la función de activación en cada una de las capas.

**Figura 15.** Red neuronal de 3 capas ocultas de 15 neuronas por capa



Fuente: Propia de los autores

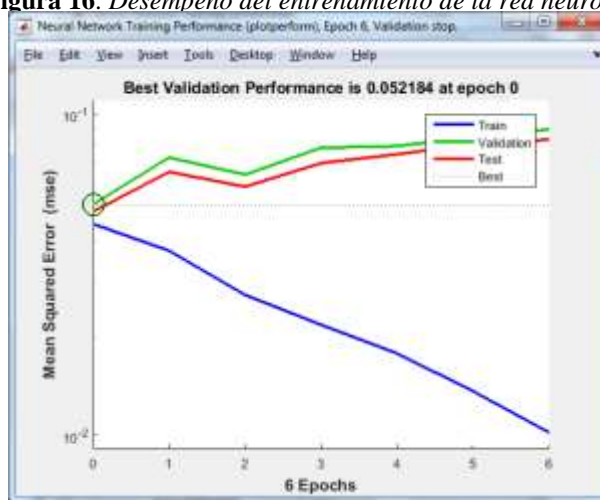
La red consta de tres capas ocultas de 15 neuronas cada una, recibiendo 36 parámetros de entrada que corresponden a cada uno de los factores de las dimensiones y datos académicos de ingreso seleccionados, las cuales están representadas como *input* en la figura 15 y generando 4 salidas y representadas como *output*

## 6. Pruebas de la red neuronal

*Desempeño del entrenamiento de la red neuronal.* Para describir el desempeño de una red neuronal, es necesario realizar una gráfica, en donde se cruce el error de la red neuronal contra la época del entrenamiento, la validación y los funcionamientos de la prueba del expediente de entrenamiento. Generalmente, el error se reduce después de más épocas de entrenamiento, pero puede comenzar a aumentar en el conjunto de datos de validación a medida que la red empieza a superponer los datos. En la configuración predeterminada, el entrenamiento se detiene después de seis aumentos consecutivos en el error de validación y el mejor rendimiento se obtiene de la época con el error de validación más bajo (The MathWorks, Inc., 2017). Se utiliza la configuración por defecto de *Matlab*, que considera el 70% de los datos para el entrenamiento, un 15% para la validación y el 15% restante para las pruebas. La figura 16, muestra la gráfica en donde se puede observar el comportamiento de las tres fases de la red (entrenamiento, validación y pruebas), durante las épocas necesarias que requiere para que el error sea mínimo.

Para el caso de esta red neuronal, el mejor resultado del desempeño en validación de entrenamiento se observa en la época número 0, con un valor de error de 0.052184 tal como se indica en la figura, después se observa que en validación como en pruebas el error comienza a no mostrar mejoría hasta la época 6; es aquí donde se detiene el entrenamiento de la red.

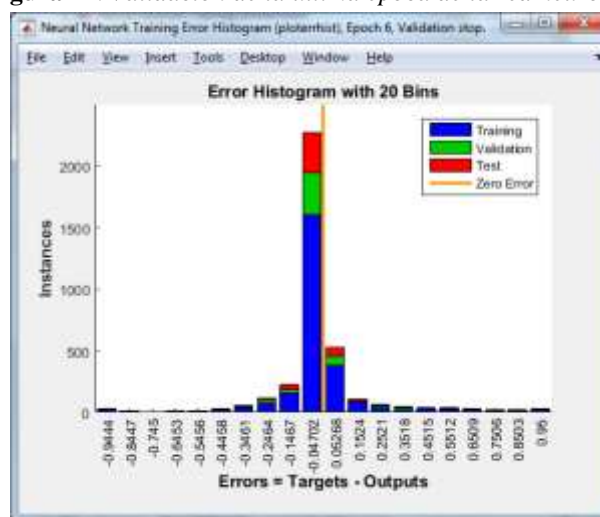
**Figura 16.** Desempeño del entrenamiento de la red neuronal



Fuente: Propia de los autores

*Error de entrenamiento.* El error de entrenamiento hace referencia a la disparidad entre los valores obtenidos por la red neuronal y los valores reales, el histograma de la figura 17 muestra que tanto en entrenamiento, validación y prueba los errores se encuentran concentrados en los valores más cercanos al cero, lo que significa un buen desempeño de la red.

**Figura 17.** Validación de la última época de la red neuronal



Fuente: Propia del autor



*Matriz de confusión.* La matriz de confusión es una herramienta que permite conocer de manera exacta la ubicación de los datos generados por la red neuronal en contraste con la salida deseada en sus tres fases: entrenamiento, validación y pruebas, así como un diagrama general del comportamiento. La figura 18 presenta la matriz de confusión; en cada uno de los apartados, el eje horizontal muestra el valor objetivo, es decir la clasificación real de los datos, y el eje vertical el obtenido por la red. Lo ideal es que todos los datos se encuentren ubicados en la diagonal principal de la tabla lo que significaría que todos los datos fueron clasificados de manera correcta.

**Figura 18.** Matriz de confusión



Fuente: Propia de los autores.

En esta clasificación, en el entrenamiento se muestra que el 89.5% de los datos utilizados para esta fase; se encuentran clasificados de manera correcta. Para el caso de la validación, el 87% se encuentran clasificados en la posición que les corresponde, mientras que, para la fase de pruebas, el 89.9% fueron ubicados en la categoría correcta. De manera general, el apartado del comportamiento global de la red de la figura presenta de manera integradas las 3 fases anteriores, señalando 822 elementos clasificados de manera correcta, mientras que 100 fueron ubicados de manera errónea, sin embargo sólo existe un dato que fue ubicado por la red neuronal en el extremo opuesto a la categoría que realmente pertenece, que significa que el objetivo era que el estudiante fuera ubicado en la categoría 4 – *Sin Riesgo* sin embargo la red los ubico en la categoría 1- *Riesgo Alto*, situación que ocurrió durante el entrenamiento de la red. Los recuadros azules de la figura muestra la efectividad de cada una de las fases, entrenamiento, validación y

prueba, así como el desempeño general de la red neuronal, siendo del 89.5%, 87%, 89.9% y 89.2% respectivamente.

#### IV. CONCLUSIONES

La primera hipótesis específica señala qué mediante un análisis estadístico del Test Psicométrico Multidimensional, es posible determinar las dimensiones que conforman, junto con los datos académicos de ingreso, las entradas de la red neuronal para la generación de un modelo predictivo de la trayectoria escolar, la cual *se acepta* ya que se comprobó que utilizando el método *k-medias* se pudieron agrupar los valores de los factores por cada dimensión mostrando información clara y confiable, en las cuales es necesario prestar más atención. Los resultados permitieron verificar cuales aspectos están catalogados como deficientes y por tanto, representan una amenaza de mayor índice de deserción escolar. Se seleccionaron 3 de las 8 dimensiones que integran el Test Psicométrico Multidimensional.

La segunda hipótesis específica que señala que la red neuronal recomendable para diseñar el modelo predictivo de trayectoria escolar es la de retropropagación., la cual *se acepta*; al respecto se diseñaron y probaron varias redes neuronales de una, de dos y de tres capas ocultas y con diferentes cantidades de neuronas en dichas capas. Fue una red neuronal de retropropagación *patternnet* de tres capas ocultas con 15 neuronas por capa y entrenada con el algoritmo *trainlm* de Matlab la que alcanzó, en su fase de entrenamiento una efectividad del 89.5%, esto demuestra ser la mejor red neuronal que permitió lograr los datos de salida correctos con un porcentaje de exactitud mayor al establecido inicialmente, que fue del 85%.

La tercera hipótesis específica que la red neuronal logrará una efectividad mínima del 85% en la fase de pruebas, lo cual indica que es confiable para utilizarse como mecanismo predictivo, *se acepta*; esto se demuestra ya que la matriz de confusión en la parte de pruebas indicó que la efectividad alcanzada por la red neuronal para esa fase fue del 89.9%, ubicando únicamente 14 de los 138 estudiantes en una categoría de trayectoria escolar distinta a la que realmente le correspondía. Estos 14 estudiantes distan sólo a una y dos categorías de la realidad, por lo que el grado de exactitud alcanzado por la red neuronal permite deducir que, efectivamente, puede ser utilizada para predecir el comportamiento con nuevos datos de entrada.

Por todo lo anterior, se puede concluir que la hipótesis central, que señala que una red neuronal entrenada y probada con una efectividad mínima del 85%, puede ser utilizada como modelo predictivo de la trayectoria escolar de los estudiantes del área Económico-Administrativa de la Universidad Autónoma de Chihuahua, recibiendo como datos de entrada el Test Psicométrico Multidimensional y datos académicos de ingreso, **es aceptada**, superando por una diferencia considerable el valor mínimo establecido.

### **Recomendaciones**

- La red puede ser utilizada en las diferentes áreas de la Universidad Autónoma de Chihuahua e inclusive en otras instituciones educativas con los datos de entrada que en esta investigación se indican; siempre y cuando tengan el mismo formato y semántica, sin embargo, es recomendable realizar el análisis estadístico para determinar si los factores utilizados en el área Económico – Administrativa tienen el mismo comportamiento y, por ende, impacto que en el universo en que sea utilizada, de ser así no existe ningún inconveniente en hacerlo, pero en caso contrario es recomendable entrenar la red neuronal nuevamente para que tenga la capacidad de recibir como datos de entrada estos nuevos parámetros.
- No es recomendable utilizar todos los datos con los que se cuentan debido a que el proceso de entrenamiento de la red sería muy lento, inclusive tendrían que diseñarse nuevas capas con distintas cantidades de neuronas para que los pesos sean ajustados correctamente, de ahí la importancia de seleccionar los más significativos.
- Resulta atractivo diseñar, en etapas posteriores, una interfaz gráfica de usuario amigable con conectividad a la red neuronal que permite una interacción con el usuario final de una manera más simple para realizar la predicción de la información lo cual no es objeto del presente, pero queda como una recomendación para trabajos futuros.
- La red neuronal diseñada, entrenada y probada, mostró una efectividad muy aceptable, lo que asegura una correcta clasificación de nuevos datos de entrada. Sin embargo, cada cierto tiempo es recomendable que la red sea entrenada nuevamente con datos conocidos de forma que los pesos se ajusten a nuevos comportamientos que pudieran surgir.

## BIBLIOGRAFÍA

- Bertona, L. F. (2005). *Entrenamiento de redes neuronales basado en algoritmos evolutivos*. Buenos Aires, Argentina: Universidad de Buenos Aires. Obtenido de <http://laboratorios.fi.uba.ar/lsi/bertona-tesisingenieriainformatica.pdf>
- Choque Aspiazu, G. (19 de Septiembre de 2016). *Algoritmo Levenberg-Marquardt*. Obtenido de El diario, ciencia y computación: [http://www.eldiario.net/noticias/2016/2016\\_09/nt160919/ciencia.php?n=6&-algoritmo-levenberg-marquardt](http://www.eldiario.net/noticias/2016/2016_09/nt160919/ciencia.php?n=6&-algoritmo-levenberg-marquardt)
- Costa, E. V., Fonseca, B., Almeida Santana, M., Ferrera de Araújo, F., & Rego, J. (2017). Evaluating the effectiveness of educational data mining techniques for early prediction of students' academic failure in introductory programming courses. *Computers in Human Behavior*, 247-256.
- Estévez Valencia, P. (1997). Optimización mediante Algoritmos Genéticos. *Anales del Instituto de Ingenieros de Chile*, 83-92.
- Flores Gutiérrez, H. (11 de Junio de 2013). *Redes neuronales con aprendizaje no supervisado*. Obtenido de Redes neuronales con aprendizaje no supervisado: <http://www.hugo-inc.com/RNA/Unidad%204/index.html>
- Fu, L. (1994). *Neural Network in Computer Intelligence*. Gainesville, Florida, EEUU: McGraw-Hill International Editions.
- García Martínez, R., Pasquini, D., & Servente, M. (2003). *Sistemas inteligentes*. Buenos Aires, Argentina.: Nueva Librería.
- González Penedo, M. F. (24 de Abril de 2009). *Aprendizaje y entrenamiento*. Obtenido de <http://www.varpa.org/~mgpenedo/cursos/scx/archivospdf/Tema2-0.pdf>
- González, A. (30 de Julio de 2014). *Conceptos básicos de Machine Learning*. Obtenido de Conceptos básicos de Machine Learning: <http://cleverdata.io/conceptos-basicos-machine-learning/>
- Guzmán, D., & M. Castaño, V. (2015). La lógica difusa en ingeniería: principios, aplicaciones y futuro. (U. d. Rica, Ed.) *Revista de Ciencia y Tecnología*, 24(2 2009).
- Hilera González, J., & Martínez Hernández, V. (1995). *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*. Madrid, España.: RA-MA.
- Kotu, V., & Deshpande, B. (2015). *Predictive analytics and data mining*. Waltham, MA, EEUU.: Morgan Kaufmann.
- Masters, T. (1993). *Practical Neural Network Recipes in C++*. Orlando, Florida: Academic Press.
- Negrete, J. (1992). *De la Filosofía a la Inteligencia Artificial*. México, D.F.: Editorial Limusa, S.A. de C.V.
- Nilsson, N. (2001). *Inteligencia Artificial una nueva síntesis*. Madrid, España.: McGraw-Hill/Interamericana de España S.
- Palma Méndez, J., & Marín Morales, R. (2008). *Inteligencia artificial; técnicas, métodos y aplicaciones*. Madrid, España: McGraw Hill / Interamericana de España, S. A. U.

- Pandey, M., & Taruna, S. (2016). Towards the integration of multiple classifier pertaining to the Student's performance prediction. *Perspectives in Science*, 364-366.
- Ponce Cruz, P. (2010). *Inteligencia Artificial con aplicaciones a la Ingeniería*. México.: Alfaomega Grupo Editor.
- Rashid, T. A., & Aziz, N. K. (Marzo de 2016). Student Academic Performance Using Artificial Intelligence. *Student Academic Performance Using Artificial Intelligence*, 56-69. Obtenido de [https://www.researchgate.net/publication/291262353\\_Student\\_Academic\\_Performance\\_Using\\_Artificial\\_Intelligence](https://www.researchgate.net/publication/291262353_Student_Academic_Performance_Using_Artificial_Intelligence)
- Rich, E., & Knight, K. (1991). *Artificial Intelligence*. Singapore: McGraw-Hill, Inc.
- Ruiz, C. A., & Basualdo, M. S. (2001). *Redes neuronales: conceptos básicos y aplicaciones*. Rosario, Santa Fe, Argentina: Universidad Tecnológica Nacional – Facultad Regional Rosario. Recuperado el 12 de Junio de 2017, de [https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monograis/matich-redesneuronales.pdf](https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograis/matich-redesneuronales.pdf)
- Russell, S., & Norving, P. (2004). *Inteligencia Artificial un enfoque moderno*. Madrid, España.: Pearson Prentice Hall.
- Sikder, F., Uddin, J., & Halder, S. (2016). Predicting students yearly performance using neural network: A case study of BSMRSTU. *2016 5th International Conference on Informatics, Electronics and Vision (ICIEV)* (págs. 524-529). Dhaka, Bangladesh: IEEE .
- Sotolongo, G., & Guzmán, M. V. (2001). Aplicaciones de las redes neuronales. El caso de la Bibliometría. *Ciencias de la Información*.
- Swingler, K. (2001). *Applying Neural Networks a practical guide*. San Francisco, CA.: Academic Press.
- The MathWorks, Inc.;. (2017). *MathWorks Documentation*. Natick, Massachusetts, E.U.A.: MathWorks. Recuperado el 6 de Agosto de 2017, de <https://www.mathworks.com/help/>
- Tomas Mariano, V. T. (2011). *Aprendizaje no supervisado*. Huejutla, Hidalgo: Universidad Autónoma del Estado de Hidalgo. Obtenido de [https://www.uaeh.edu.mx/docencia/P\\_Presentaciones/huejutla/sistemas/redes\\_neuronales/aprendizaje.pdf](https://www.uaeh.edu.mx/docencia/P_Presentaciones/huejutla/sistemas/redes_neuronales/aprendizaje.pdf)
- Turborienta. (2014). *Test Psicométrico Multidimensional*. Cd. de México.
- Universidad Autónoma de Chihuahua. (2016). *Estadística Básica - Universidad Autónoma de Chihuahua*.
- Valencia Reyes, M. A., Yáñez Márquez, C., & Sánchez Fernández, L. P. (2006). *Algoritmo Backpropagation para Redes Neuronales: conceptos y aplicaciones* . Cd. de México.: Instituto Politécnico Nacional, Centro de Investigación en Computación.
- Villada, F., Muñoz, N., & García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. *Información tecnológica*, 11-20.
- Villagrà Arendo, C. J., Gallego Durán, F. J., Llornes Largo, F., Compañ Rosique, P., Satorre Cuerda, R., & Molina Carmona, R. (2016). Improving the expressiveness of black-box models for predicting student performance. *Computers in Human Behavior*, 621-631. Recuperado el 2017