

UNIVERSIDAD AUTÓNOMA DE CHIHUAHUA
FACULTAD DE CONTADURÍA Y ADMINISTRACIÓN
SECRETARÍA DE INVESTIGACIÓN Y POSGRADO



**Modelo predictivo de la trayectoria escolar de los estudiantes con base en el
Test Psicométrico Multidimensional y los datos académicos de ingreso**

**Caso de estudio: Alumnos del Área Económico-Administrativa de la
Universidad Autónoma de Chihuahua**

por

Víctor Alonso Domínguez Ríos

**Disertación como requisito para obtener el grado de
Doctor en Administración**

Director de Tesis

Dr. José Rene Arroyo Ávila

La Disertación “**Modelo predictivo de la trayectoria escolar de los estudiantes con base en el Test Psicométrico Multidimensional y los datos académicos de ingreso, caso de estudio: alumnos del Área Económico-Administrativa de la Universidad Autónoma de Chihuahua**, que presenta **Víctor Alonso Domínguez Ríos** como requisito parcial para obtener el grado de **Doctor en Administración**, ha sido revisada y aprobada por la **Facultad de Contaduría y Administración** por los miembros del **Comité Doctoral**:

Dr. José René Arroyo Ávila
Asesor Principal

Dra. Graciela María de Jesús Ramírez Alonso
Asesor Área Mayor

Dr. Luis Raúl Luján Vega
Asesor Área Menor

Dr. Jorge Jiménez Castro
Asesor de Estadística

Dra. Ana Isabel Ordoñez Parada
Asesor de Metodología

Por las autoridades de la Facultad:

Dr. Juan Oscar Ollivier Fierro
Secretario de Investigación y Posgrado

M.F. Luis Raúl Sánchez Acosta
Director de la
Facultad de Contaduría y Administración

© Derechos Reservados

Víctor Alonso Domínguez Ríos
Ciudad Universitaria s/n
Campus II UACH

Noviembre de 2017

Dedicatoria

A mi madre, por siempre estar al pendiente de mi bienestar, por su apoyo y amor incondicional y porque sé que celebra mis logros como propios.

A mi padre, que gracias a su apoyo es que tuve la oportunidad de dedicarme a estudiar y por estar al pendiente de mí.

A mi hermano Álvaro quien creció conmigo y fue cómplice de todas esas locuras que juntos llevamos a cabo y que nos sigue dando un ejemplo de lucha y trabajo como hermano mayor.

A mi hermano Daniel que no deja de superarse, que fue mi compañero por varios años dándole ese toque familiar y cómico a mi casa y que siempre busca como emprender y alcanzar nuevos sueños juntos.

A mi hermana Tania, la pequeña de la familia pero que mostrado mucha entereza y madurez en su vida.

Al resto de mi familia que, aunque unos estén más lejos que otros, los llevo siempre en mi mente y en mi corazón.

A mis amigos que han estado presentes en mis triunfos y fracasos y siempre al pendiente de mí, convirtiéndose en parte de mi familia.

Agradecimientos

A Dios, por permitirme vivir hasta el día de hoy y a quien le pido me siga dando salud, fuerza y pasión de seguir luchando por mis metas.

A mis docentes del doctorado, por guiar mi camino en esta etapa de mi vida, despertar inquietudes y responder a otras tantas, por compartir sus conocimientos y su experiencia.

Al comité doctoral de mi tesis, por su tiempo, esfuerzo y dedicación a este trabajo de investigación.

A mis compañeros del doctorado por hacerme recordar lo maravilloso que es la vida de estudiante y por sus aportaciones tan valiosas en mi formación.

Al personal tanto de la Dirección como de la Secretaría de Investigación y Posgrado de la Facultad de Contaduría y Administración por su todo su apoyo; les agradezco infinitamente.

A los directivos de la Universidad Autónoma de Chihuahua, por permitirme desarrollar este trabajo de investigación que confío en Dios será de gran utilidad.

A la Universidad Autónoma de Chihuahua, por ser mi casa tanto formativa como de desempeño profesional.

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 los ciclos agosto-diciembre de 2014 y enero-junio de 2015. A través del método *k-medias* se determinaron las dimensiones apropiadas del Test Psicométrico Multidimensional que, junto con los datos académicos de ingreso, se utilizaron como 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 el ciclo escolar agosto-diciembre de 2016, se tuvo una efectividad del 89.2%, mayor al 85% que se estableció para la presente investigación.

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

Abstract

A neural network used as the instrument established to determine the trajectory of a student, taking as input some results of a Multidimensional Psychometric Test (MPT) and admission academic information, has a minimum effectiveness of 85%. After the statistical analysis of the results of the MPT for the determination of those psychological factors, personality and competences with lower values, which represents a greater negative impact on their performance and school situation, together with academic income information integrated by the results of the students' entrance evaluation and their average in the highschool level, it was possible to design a backpropagation neural network which, when trained and tested with these data as input and the student's trajectory as a target, showed an effectiveness of 97.8%; so it is possible to use it as a predictive mechanism for new inputs allowing early detection of situations of risk of dropout or school delay and take preventive measures while allowing to know those intellectual and mental characteristics and skills, academics map and competences, learning styles and mental programming of students in which the University must pay attention to a better development of the student.

Key words: neural networks, school trajectory, applying computation in human behavior.

Índice general

	Página
Resumen	v
Abstract	v
Índice de tablas	vii
Índice de figuras	ix
I - Introducción.....	1
Antecedentes	2
Problema de investigación	16
Objetivos del estudio.....	18
Objetivo general.....	18
Objetivos específicos	18
Justificación y delimitación del estudio.....	18
Justificación	18
Delimitación	20
Formulación de la hipótesis	21
Hipótesis Central	21
Hipótesis Específicas	21
II. Revisión de literatura.....	23
Marco conceptual.....	66
Estado del arte	68
III. Criterios metodológicos	88
IV. Resultados y discusión	91
V. Conclusiones y recomendaciones	124
Conclusiones	124
Recomendaciones	126
Bibliografía	128

Índice de tablas

Tabla		Página
1	Alumnos de nivel licenciatura de la Universidad Autónoma de Chihuahua en los ciclos escolares agosto – diciembre 2014, enero – junio 2015 y agosto – diciembre 2016 por Unidad Académica	3
2	Alumnos de nivel licenciatura del área Económico–Administrativa de la Universidad Autónoma de Chihuahua en el ciclo escolar agosto – diciembre 2016 por Programa Educativo	4
3	Alumnos con situación de baja definitiva o reingreso no inscrito al inicia los ciclos escolares enero – junio 2015, agosto – diciembre 2015 y enero – junio 2017 por Unidad Académica	5
4	Alumnos con situación de baja definitiva o reingreso no inscrito al iniciar el ciclo escolar enero – junio 2017 del área Económico – Administrativa de la Universidad Autónoma de Chihuahua por Programa Educativo	7
5	Docentes y tutores certificados de la Universidad Autónoma de Chihuahua	9
6	Clasificación del desempeño escolar	14
7	Clasificación de la situación escolar	15
8	Riesgo escolar - clasificación de la trayectoria escolar	15
9	Test Psicométrico Multidimensional	24
10	Aplicaciones de las redes neuronales artificiales	50
11	Casos en los que una red neuronal puede ser utilizada	52
12	Funciones de salida de una red de retropropagación	63
13	Derivada y términos de error de las funciones lineal y sigmoideal	63
14	Publicaciones de Referencia	70
15	Características de entrada del artículo	80
16	Resultados de precisión de ambos experimentos	81



Tabla		Página
17	Factores considerados para determinar el rendimiento escolar	84
18	Peso de los factores en el desempeño académico de los estudiantes	85
19	Factores considerados dentro del conjunto de datos de entrada	86
20	Comparación de la clasificación real con los datos obtenidos por la red neuronal	87
21	Conversión a valor numérico de la Trayectoria Escolar	92
22	Agrupamiento de los factores que integran el coeficiente intelectual	96
23	Agrupamiento de los factores que integran las inteligencias múltiples	97
24	Agrupamiento de los factores que integran las competencias intelectuales	99
25	Agrupamiento de los factores que integran la programación mental	100
26	Agrupamiento de los factores que integran el mapa académico	102
27	Agrupamiento de los factores que integran las competencias académicas	104
28	Agrupamiento de los factores que integran las habilidades mentales	105
29	Agrupamiento de los factores que integran el estilo de aprendizaje	107
30	Agrupamiento de los datos académicos de ingreso	109
31	Dimensiones y factores seleccionados con datos de entrada de la red neuronal	112
32	Datos de salida de la red neuronal	114

Índice de figuras

Figura		Página
1	Modelo educativo de la Universidad Autónoma de Chihuahua	8
2	Cálculo de la trayectoria escolar	12
3	Cálculo del desempeño escolar	13
4	Cálculo del índice de aprobación	13
5	Cálculo del promedio	13
6	Cálculo de la situación escolar	14
7	Categorías en que se clasifica la Inteligencia Artificial	46
8	Modelo de una neurona artificial	53
9	Red neuronal de una capa	56
10	Red neuronal multicapa	57
11	Red neuronal con aprendizaje por corrección de error	59
12	Red neuronal backpropagation o de retropropagación	62
13	Histograma de error de la red neuronal de Skider, Uddin y Halder	87
14	Flujograma de actividades	93
15	Dimensiones del Test Psicométrico Multidimensional	94
16	Clasificación del coeficiente intelectual de los estudiantes	96
17	Clasificación de las inteligencias múltiples de los estudiantes	97
18	Clasificación de las competencias intelectuales de los estudiantes	100
19	Clasificación de la programación mental de los estudiantes	101
20	Clasificación del mapa académico de los estudiantes	103
21	Clasificación de las competencias académicas de los estudiantes	104



Figura		Página
22	Clasificación de las habilidades mentales de los estudiantes	106
23	Clasificación del desarrollo de los estilos de aprendizaje de los estudiantes	108
24	Clasificación de los datos académicos de ingreso de los estudiantes	109
25	Comparativo de la frecuencia por grupo de las principales dimensiones del TPM	110
26	Indicadores que integran la Trayectoria Escolar	113
27	Clasificación de la Trayectoria Escolar	114
28	Red neuronal de 3 capas ocultas de 15 neuronas por capa	115
29	Desempeño del entrenamiento de la red neuronal	117
30	Validación de la última época de la red neuronal	118
31	Matriz de confusión	119



I - Introducción

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

La Universidad Autónoma de Chihuahua, cuenta con los resultados del Test Psicométrico Multidimensional de una muestra de estudiantes que se encuentran almacenados en una base de datos, así como los resultados de su evaluación de ingreso a la institución y su promedio del nivel académico anterior. Esta información, puede ser utilizada para entrenar una red neuronal y a partir de ello, determinar cómo estos factores impactaron en el desempeño escolar de los estudiantes; lo cual conducirá, posteriormente, a apoyar en la detección temprana de patrones de comportamiento que pudieran originar bajo rendimiento académico y poder tomar acciones preventivas mediante la actividad tutorial en futuras generaciones.

Para ello es 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, es necesario acotar la investigación a una parte del alumnado, cuyas características sean similares y determinar cuáles dimensiones o información considerar como datos de entrada a la red neuronal. Para seleccionarlos es necesario utilizar métodos estadísticos para analizar la información con la que se cuenta.
- Una vez que se encuentren claramente definidos los datos de entrada, es necesario construir y entrenar la red, siendo necesario seleccionar una muestra adecuada de datos (80% de los datos con los que se cuentan) de forma que la red considere la mayor cantidad de particularidades posibles.



- Para concluir, y de acuerdo a la literatura revisada que se detalla posteriormente, la red neuronal debe ser sometida a una fase de pruebas donde se asegure que ésta tiene un mínimo del 85% de efectividad.

De lograrse lo anterior, se contará con un mecanismo predictivo muy eficaz que permitirá contar con mayor información al momento del ingreso de los estudiantes de la UACH y, a partir de ello, tomar acciones sobre la actividad tutorial que mejore la situación escolar de los estudiantes y, por ende, se reduzcan los índices de reprobación y deserción.

Antecedentes

El 19 de marzo de 1835 fue fundado en Instituto Científico y Literario con el fin de promover el desarrollo de la cultura en la naciente ciudad de Chihuahua y ofrecía a la comunidad estudios de latinidad y gramática castellana. En su inicio tenía 21 estudiantes, sin embargo, entre los años 1835 y 1900 alrededor de 996 personas recibieron educación en sus aulas.

La demanda de educación en el estado fue creciendo, de tal manera que muchos alumnos tuvieron que salir de la entidad hacia la Cd. de México para realizar sus estudios y un gran número de ellos se quedaron a radicar en aquella ciudad, por tal motivo el estado perdió con ello importantes personalidades.

El 8 de diciembre de 1954 el Congreso del Estado de Chihuahua, siendo Gobernador Constitucional el Lic. Oscar Soto Máynez, expidió el decreto 171 con el cual se fundó la Universidad de Chihuahua (UCH), la cual inició con las escuelas de Medicina, Ingeniería, Derecho, Educación Física y Farmacia (Universidad Autónoma de Chihuahua, 2008).

En el año 1968, la Universidad obtiene su autonomía, siendo rector el Lic. Oscar Ornelas K. y gobernador del Estado el Lic. Oscar Flores Sánchez (Universidad Autónoma de Chihuahua, 2008b).

Hacia el año 2010 el Plan de Desarrollo Universitario establece como primer eje rector el Aseguramiento de la Calidad Educativa.

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 2016 distribuidos como se señala en la tabla 1, que a su vez permite realizar 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. En la tabla 1 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 2016.

Tabla 1. *Alumnos de nivel licenciatura de la Universidad Autónoma de Chihuahua en los ciclos escolares agosto – diciembre 2014, enero – junio 2015 y agosto – diciembre 2016 por Unidad Académica*

Unidad Académica	Alumnos Inscritos		
	Ago – Dic 2014	Ene – Jun 2015	Ago – Dic 2016
Artes	752	780	750
Ciencias Agrícolas y Forestales	547	506	547
Ciencias Agrotecnológicas	733	686	733
Ciencias de la Cultura Física	2,229	2,542	2,230
Ciencias Políticas y Sociales	3,772	3,394	3,754
Ciencias Químicas	1,543	1,338	1,543
Contaduría y Administración	4,453	4,248	4,454
Derecho	2,476	2,232	2,476
Economía Internacional	585	303	585
Enfermería y Nutriología	1,999	1,993	1,998
Filosofía y Letras	754	697	752
Ingeniería	2,993	3,181	2,995
Medicina y Ciencias Biomédicas	2,468	2,231	2,467
Odontología	1,282	1,171	1,282
Zootecnia y Ecología	760	749	760
Total	27,346	26,051	27,323

Fuente: (Universidad Autónoma de Chihuahua, 2016).

Los 5,039 estudiantes del área económico-administrativa, se encuentran distribuidos en 8 programas educativos, 2 modalidades y 9 sedes o campus en el estado de Chihuahua, la tabla 2 muestra la distribución del alumnado.

Tabla 2. Alumnos de nivel licenciatura del área Económico – Administrativa de la Universidad Autónoma de Chihuahua en el ciclo escolar agosto – diciembre 2016 por Programa Educativo

Campus CHIHUAHUA		
Programa Educativo	Presencial	Virtual
Contador Público	1,022	35
Administración de Empresas	942	284
Admón. de Tecnologías de Información y Comunicaciones	155	16
Administración Financiera	733	23
Administración Gubernamental	217	11
Sistemas de Computación Administrativa	2	0
Economía Internacional	257	0
Negocios Internacionales	106	0
Campus DELICIAS	Presencial	Virtual
Contador Público	309	0
Administración de Empresas	232	7
Administración Financiera	99	0
Administración Gubernamental	1	0
Campus CAMARGO	Presencial	Virtual
Contador Público	83	0
Administración de Empresas	77	0
Campus PARRAL	Presencial	Virtual
Contador Público	9	0
Administración de Empresas	11	0
Administración Financiera	58	0
Administración Gubernamental	55	0
Economía Internacional	115	0
Negocios Internacionales	107	0
Centros Regionales de Educación Superior (CRES)	Presencial	Virtual
Contador Público	0	8
Administración de Empresas	0	58
Admón. de Tecnologías de Inf. y Comunicaciones	0	2
Administración Financiera	0	1
Administración Gubernamental	0	4
Subtotales	4,590	449
Total	5,039	

Fuente: (Universidad Autónoma de Chihuahua, 2016).

Nota: CRES están ubicados en Madera, Ojinaga, Guachochi, Guerrero y Guadalupe y Calvo.

De acuerdo con la información mostrada en la tabla 2, es posible identificar que la mayor parte del alumnado del área Económico-Administrativa se encuentra en el campus Chihuahua con un 75.47%, del mismo modo, la mayor parte de los estudiantes se encuentran realizando sus estudios en modalidad presencial, el 91.09% de la matrícula.

Como es notable, la Universidad cuenta con una amplia matrícula, sin embargo, es necesario contrastar este dato con los alumnos que desertan de su plan de estudios, presentándose dos situaciones: alumnos que caen en baja definitiva por reprobación y alumnos que simplemente ya no se inscriben al siguiente ciclo escolar; sobre esta situación los datos se comportan como se observa en la tabla 3.

Tabla 3. Alumnos con situación de baja definitiva o reingreso no inscrito al inicia los ciclos escolares enero – junio 2015, agosto – diciembre 2015 y enero – junio 2017 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
Artes	51	23	74	38	40	78	19	45	64
Ciencias Agrícolas y Forestales	29	18	47	24	9	33	20	34	54
Ciencias Agrotecnológicas	38	11	49	29	15	44	25	42	67
Ciencias de la Cultura Física	185	88	273	195	79	274	122	103	225
Ciencias Políticas y Sociales	222	215	437	215	232	447	200	307	507
Ciencias Químicas	82	28	110	74	29	103	63	72	135
Contaduría y Administración	295	260	555	269	228	497	220	317	537
Derecho	56	59	115	113	63	176	58	74	132
Economía Internacional	15	2	17	21	7	28	12	46	53
Enfermería y Nutriología	76	34	110	74	36	110	28	61	89
Filosofía y Letras	77	31	108	37	30	67	30	116	146
Ingeniería	274	105	379	279	88	367	228	156	384
Medicina y Ciencias Biomédicas	142	25	167	247	35	282	158	42	200
Odontología	55	32	87	73	21	94	28	29	57
Zootecnia y Ecología	46	53	99	53	48	101	49	63	112
Total	1,643	984	2,627	1,741	960	2,701	1,260	1,502	2,762

Fuente: (Universidad Autónoma de Chihuahua, 2016)

La información presentada en la tabla 3 es de suma importancia, y es que con base en estos datos son elaborados los indicadores de deserción escolar de la Universidad. Estableciendo una relación entre la tabla 2 y la tabla 3 se determina que para el ciclo escolar agosto – diciembre 2016 un 10.11% de la matrícula universitaria en nivel licenciatura, no continuaron sus estudios al semestre siguiente (enero – junio 2017), situación que resulta preocupante porque en un estudio más a profundidad de deserción escolar, este porcentaje se acumula cada ciclo escolar, dando como resultado un escenario que con el presente trabajo de investigación se pretende reducir.

Por su parte, la información en este rubro para el área Económico–Administrativa se comportó según la tabla 4, los cuales, en relación con los descritos en la tabla 3, permiten determinar un 11.81% de estudiantes que no se inscribieron al próximo ciclo escolar, valor mayor al 10.11% analizado de forma global para la Universidad. Lo que permite establecer que en el área Económico-Administrativa el porcentaje de alumnos que desertan de un ciclo escolar a otro, es mayor que a nivel Universidad.

Con la finalidad de reducir estos indicadores y brindar apoyo a los alumnos en el transcurso de sus estudios, se ha diseñado el Programa Institucional de Tutorías que se deriva de una constante preocupación por parte de la UNESCO y el Centro Regional para la Educación Superior de América Latina y el Caribe (CERSALC) por mejorar, no solo problemas académicos de los estudiantes, sino también la calidad educativa de las Instituciones. En el programa de tutorías se observa la necesidad de apoyar la formación integral de los estudiantes con tutorías académicas, entendidas como la responsabilidad del docente, en la que interactúa de forma personal con el estudiante para orientarlo en su aprendizaje, considerando sus condiciones individuales y su estilo de aprender, de modo que cada estudiante alcance el mayor nivel de dominio de las competencias (García Nieto, 2008).

Tabla 4. *Alumnos con situación de baja definitiva o reingreso no inscrito al iniciar el ciclo escolar enero – junio 2017 del área Económico – Administrativa de la Universidad Autónoma de Chihuahua por Programa Educativo*

Campus CHIHUAHUA				
Programa Educativo	Baja Definitiva		No Inscritos	
	Presencial	Virtual	Presencial	Virtual
Contador Público	28	6	53	11
Administración de Empresas	53	31	76	29
Admón. de Tecnologías de Inf. y Comunicaciones	8	1	10	7
Administración Financiera	34	6	38	8
Administración Gubernamental	17	1	18	3
Economía Internacional	6	0	22	0
Negocios Internacionales	4	0	13	0
Campus DELICIAS	Baja Definitiva		No Inscritos	
	Presencial	Virtual	Presencial	Virtual
Contador Público	6	0	9	0
Administración de Empresas	5	1	19	1
Administración Financiera	2	0	8	0
Campus CAMARGO	Baja Definitiva		No Inscritos	
	Presencial	Virtual	Presencial	Virtual
Contador Público	1	0	3	0
Administración de Empresas	6	0	4	0
Campus PARRAL	Baja Definitiva		No Inscritos	
	Presencial	Virtual	Presencial	Virtual
Contador Público	0	0	1	0
Administración de Empresas	1	0	2	0
Administración Financiera	0	0	2	0
Administración Gubernamental	2	0	6	0
Economía Internacional	1	0	4	0
Negocios Internacionales	1	0	7	0
Centros Regionales de Educación Superior (CRES)	Baja Definitiva		No Inscritos	
	Presencial	Virtual	Presencial	Virtual
Contador Público	0	1	0	1
Administración de Empresas	0	8	0	6
Admón. de Tecnologías de Inf. y Comunicaciones	0	0	0	1
Administración Financiera	0	0	0	1
Administración Gubernamental	0	2	0	0
Subtotales	175	57	295	68
Totales	232		363	

Fuente: (Universidad Autónoma de Chihuahua, 2017).

Nota: CRES están ubicados en Madera, Ojinaga, Guachochi, Guerrero y Guadalupe y Calvo.

El programa surge para la Universidad Autónoma de Chihuahua (UACH), en el Plan de Desarrollo Institucional (PIDE) 1996-2000, el cual considera, dentro del Programa de Reforma Académica y Flexibilidad Curricular a la tutoría con el

propósito de apoyar a los estudiantes en su proceso formativo (Universidad Autónoma de Chihuahua, 2016b), el cual es implementado por la Dirección Académica de la Universidad a partir del 2002, año en el que fue aprobado por el Consejo Consultivo Académico y el Honorable Consejo Universitario.

La tutoría como tal, se convierte en un eje fundamental del modelo educativo de la Universidad




Figura 1. Modelo educativo de la Universidad Autónoma de Chihuahua

Fuente: (Marín Uribe, 2003)

La figura 1, muestra los 5 ejes sobre los cuales está desarrollado el modelo educativo de la Universidad, haciendo hincapié en la actividad tutorial, actividad que representa un reto, pero de lograrse de manera adecuada, contribuye enormemente al desarrollo de las competencias y el aprendizaje. En un currículo flexible, el alumno participa en la toma de decisiones, por ello, es imperativo proporcionarle la guía y el apoyo necesarios para que sus decisiones sean las correctas. En ese sentido, el modelo educativo no concibe el currículo flexible sin la participación activa de los tutores (Marín Uribe, 2003).

Un tutor académico es aquel docente formado en el ejercicio de la tutoría que orienta, asesora y acompaña al estudiante durante su trayectoria escolar, para colaborar en su formación integral y propiciar en el tutorando la responsabilidad del

autoaprendizaje, durante diferentes momentos y situaciones que enfrentan a lo largo de su formación profesional (Universidad Autónoma de Chihuahua, 2016b).

La Universidad Autónoma de Chihuahua (UACH), establece los siguientes requisitos institucionales para ser tutor:

- Ser docente activo de la Universidad Autónoma de Chihuahua
- Una antigüedad mínima de dos años como docente.
- Haber acreditado el Diplomado de Tutorías impartido por la UACH.
- Contar con el perfil del tutor académico (Universidad Autónoma de Chihuahua, 2016b).

Tabla 5. *Docentes y tutores certificados de la Universidad Autónoma de Chihuahua*

Unidad Académica	Docentes	Tutores
Facultad de Artes	142	30
Facultad de Ciencias Agrícolas Y Forestales	66	25
Facultad de Ciencias Agrotecnológicas	135	46
Facultad de Ciencias De La Cultura Física	167	61
Facultad de Ciencias Políticas Y Sociales	263	37
Facultad de Ciencias Químicas	132	78
Facultad de Contaduría y Administración	504	102
Facultad de Derecho	295	41
Facultad de Economía Internacional	62	19
Facultad de Enfermería y Nutriología	194	58
Facultad de Filosofía y Letras	129	46
Facultad de Ingeniería	370	77
Facultad de Medicina y Ciencias Biomédicas	428	42
Facultad de Odontología	115	27
Facultad de Zootecnia y Ecología	87	64
TOTALES	3,089	753

Fuente: (Universidad Autónoma de Chihuahua, 2017).

De ahí que la cantidad de tutores certificados del total de docentes de la UACH se comporte como lo indica la tabla 5.

Como se puede notar, dada la relación de alumnos – docentes – tutores no es posible que todos los estudiantes de la Universidad tengan asignado un tutor, ya que, analizando la relación entre la tabla 5 y la tabla 1, cada tutor certificado, tendría que brindar apoyo a 36 estudiantes de licenciatura aproximadamente por ciclo escolar, por lo anterior la Universidad Autónoma de Chihuahua, cuenta con los siguientes criterios para la asignación de tutorandos según el Programa Institucional de Tutorías:

- El estudiante tendrá opción de seleccionar a su tutor y se asignarán con base en el número de tutores disponibles.
- Los estudiantes con riesgo según el Test Psicométrico Multidimensional, Módulo Introdutorio, CENEVAL y estudio socioeconómico deberán ser asignados a un tutor.
- Los estudiantes con poco aprovechamiento académico deberán ser asignados a un tutor.
- Los estudiantes que tengan referencia de algún profesor o Secretario Académico.
- El Coordinador de Actividades Deportivas deberá enviar el listado de los estudiantes deportistas para ser asignados a un tutor.
- Todos los estudiantes del Programa de Atención a Estudiantes Indígenas deberán contar con tutor.
- Los estudiantes con alto potencial académico.

Durante los ciclos escolares agosto – diciembre 2014, enero – junio 2015 y agosto – diciembre 2015, se aplicó a los alumnos de nuevo ingreso el Test Psicométrico Multidimensional, implementando en el Sistema de Tutorías Académicas, la opción que permite a los tutores verificar los resultados académicos de esta valoración. Sin embargo, dado la poca capacitación que los tutores recibieron, la utilización que se le dio a la herramienta fue muy poca.

Así mismo, desde el año 2005, la Universidad Autónoma de Chihuahua, ha venido aplicando a los aspirantes que desean ingresar a algún programa de licenciatura el

Examen Nacional de Ingreso a la Educación Superior (EXANI II), diseñado por el Centro Nacional de Evaluación para la Educación Superior (CENEVAL).

Para el presente trabajo de investigación se consideran sólo a los alumnos de nivel licenciatura inscritos en la Facultad de Contaduría y Administración y en la Facultad de Economía Internacional de la Universidad Autónoma de Chihuahua, que en lo sucesivo se denominarán Alumnos de Área Económico-Administrativa.

Examen Nacional de Ingreso a la Educación Superior EXANI II

Los resultados del Test Psicométrico Multidimensional son complementados con los obtenidos por el Examen Nacional de Ingreso a la Educación Superior, EXANI II; el cuál brinda información sobre el aprendizaje logrado por el aspirante en áreas que son predictivas del desempeño académico que tendrán los estudiantes en el nivel superior al que ingresarán.

El Centro Nacional de Evaluación para la Educación Superior (CENEVAL) es una asociación civil sin fines de lucro cuya actividad principal es el diseño y la aplicación de instrumentos de evaluación de conocimientos, habilidades y competencias, así como el análisis y la difusión de los resultados que arrojan las pruebas. Desde 1994 proporciona información confiable y válida sobre los conocimientos y habilidades que adquieren las personas como beneficiarios de los programas educativos de diferentes niveles de educación formal e informal (Centro Nacional de Evaluación para la Educación Superior, 1994).

Trayectoria, desempeño, situación y riesgo escolar

Un programa de trayectoria escolar, tiene por objeto la medición del desarrollo académico de los estudiantes en un programa educativo. Dichas mediciones se hacen en términos de aprobación, deserción, rezago, egreso y titulación. Tener medidas descriptivas del comportamiento académico de los estudiantes, permite a una institución canalizar a los alumnos en riesgo a los programas de apoyo como lo

son las tutorías, asesorías y en determinado caso al departamento de atención psicológica (Facultad de Contaduría y Administración de la UACH, 2014).

Los estudios de trayectoria escolar se refieren a la cuantificación del comportamiento escolar de un conjunto de estudiantes (cohorte) durante su trayecto en la estancia educativa o establecimiento escolar, desde su ingreso, durante su permanencia y egreso, hasta la conclusión de los créditos y requisitos académicos-administrativos definidos por el plan de estudios (Rodríguez, 1997).

Este tipo de estudios implican el análisis de una serie de indicadores que permiten determinar el comportamiento académico de los estudiantes en su tránsito por la Unidad Académica, y proporcionan un diagnóstico institucional a través del cual se pueden identificar fortalezas y debilidades de las instituciones educativas, que servirán como punto de referencia para el establecimiento de estrategias que resuelvan en cierta medida los problemas enfrentados por la educación (Fernández Pérez, Peña Chumacero, & Vera Rodríguez, 2006). La trayectoria escolar se determina por la suma del desempeño escolar y la situación escolar tal como se muestra en la figura 2.




Figura 2. *Cálculo de la trayectoria escolar*

Fuente: (Chain Revuelta & Jácome Ávila, 2007)

El desempeño escolar es el comportamiento transversal en el ciclo escolar actual, tomando en cuenta la relación del número de materias acreditadas con respecto a las cursadas durante el ciclo, así como el promedio obtenido en el semestre actual (Chain Revuelta & Jácome Ávila, 2007) como se indica en la figura 3 .




Figura 3. Cálculo del desempeño escolar

Fuente: (Facultad de Contaduría y Administración de la UACH, 2014)

Índice de aprobación: tal como se muestra en la figura 4, es la relación de las materias aprobadas por el estudiante durante el semestre anterior con respecto a las cursadas en el mismo período (Chain Revuelta & Jácome Ávila, 2007).




Figura 4. Cálculo del índice de aprobación

Fuente: (Facultad de Contaduría y Administración de la UACH, 2014)

Promedio: es el resultante de la división de la sumatoria de las calificaciones obtenidas en las asignaturas por el número de asignaturas cursadas en el semestre y dividido entre 10 (Chain Revuelta & Jácome Ávila, 2007); expresado en la figura 5.




Figura 5. Cálculo del promedio

Fuente: (Facultad de Contaduría y Administración de la UACH, 2014)

La fórmula de desempeño escolar descrita en la figura 3, da como resultado un valor numérico que debe ser localizado en la tabla 6 para determinar la clasificación del desempeño escolar del alumno.

Tabla 6. Clasificación del desempeño escolar

Clasificación	Valor mínimo	Valor máximo
Bajo	0	59
Regular	60	89
Alto	90	100

Fuente: (Facultad de Contaduría y Administración de la UACH, 2014)

El desempeño escolar mostrado en la tabla 6 se clasifica en 3 rubros:

- Bajo: son estudiantes cuyo desempeño académico es preocupante, ya que se caracterizan por haber acreditado muy pocas materias el ciclo escolar anterior y/o tener un promedio muy bajo.
- Regular: alumnos que si bien, su índice de aprobación y/o promedio del ciclo inmediato anterior no es muy bajo, su desempeño académico debe considerarse para recibir alguna atención y mejorar esta situación.
- Alto: son alumnos con buen promedio y bajo índice de reprobación de materias.

Como se indica en la figura 6, la situación escolar es el comportamiento longitudinal durante el avance académico dentro de la malla curricular establecida en el plan de estudios, tomando en cuenta el número acumulado de créditos obtenidos hasta el momento, con respecto al número de créditos al que está obligado a acumular de acuerdo a su cohorte generacional (Chain Revuelta & Jácome Ávila, 2007).

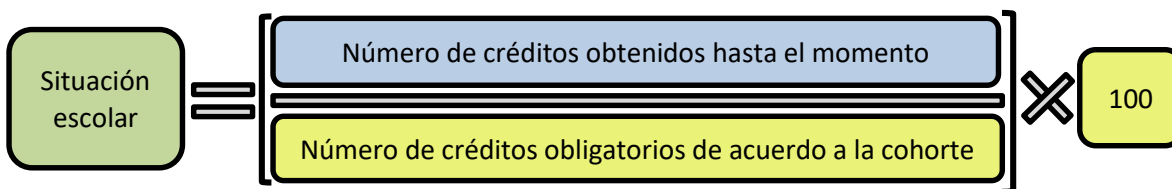


Figura 6. Cálculo de la situación escolar

Fuente: (Facultad de Contaduría y Administración de la UACH, 2014)

La fórmula descrita en la figura 6, genera un valor numérico, el cual es necesario ubicarlo en la tabla 7 para determina la clasificación de la situación escolar del estudiante.

Tabla 7. *Clasificación de la situación escolar*

Clasificación	Valor mínimo	Valor máximo
Rezago	0	69
Irregular	70	99
Óptimo	100	100

Fuente: (Facultad de Contaduría y Administración de la UACH, 2014)

La tabla 7 muestra tres clasificaciones:

- Rezago: son aquellos estudiantes que presentan menos de un 70% con respecto al avance que deberían tener hasta el momento en su plan de estudios, su situación es preocupante ya que su retraso es considerable.
- Irregular: son los alumnos que si bien, no tienen el avance que debería de tener hasta el momento, presentan como mínimo un 70%, su situación, aunque debe ser atendida, no es tan grave.
- Óptimo: son las personas que llevan acreditado un 100% de los créditos que deberían de tener hasta el momento.

Tabla 8. *Riesgo escolar - clasificación de la trayectoria escolar*

		Situación escolar		
		Rezago	Irregular	Óptimo
Desempeño escolar	Bajo	Riesgo Alto	Riesgo Alto	Riesgo Bajo
	Regular	Riesgo Alto	Riesgo	Sin Riesgo
	Alto	Riesgo	Riesgo Bajo	Sin Riesgo

Fuente: (Facultad de Contaduría y Administración de la UACH, 2014)

El riesgo escolar resulta de la clasificación de la trayectoria escolar de los estudiantes, que se obtiene del cruce de la información de la clasificación del desempeño escolar (tabla 6) con la situación escolar (tabla 7) y sus categorías y parámetros se establecen en la tabla 8.

Lo ideal es que los estudiantes se encuentren en una situación Sin Riesgo, y para aquellos que no se encuentran ubicado en este rubro, es importante emprender actividades que permitan mejorar su situación, ya que la clasificación de la trayectoria escolar de la tabla 8, indica el riesgo de deserción, por motivos académicos, de un estudiante.

Problema de investigación

En la Universidad Autónoma de Chihuahua, los alumnos de nuevo ingreso son asignados a un tutor académico utilizando para ello criterios establecidos en el Programa Institucional de Tutorías, sin embargo, y en relación a lo que se ha observado, estos parámetros no presentan mucha relación con la mejoría en el desempeño académico de los estudiantes.

Muchos de los datos considerados para asignar un tutor a los alumnos de nuevo ingreso, provienen del registro de su ficha de admisión, que en muchas ocasiones son datos proporcionados con la ayuda de un tercero y en el peor de los casos es otra persona la que responde cada una de las preguntas, lo que conlleva a que eventualmente la información no sea fiable.

Por otro lado, 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; con información más elaborada que una simple encuesta e ir más allá, procesándola con nuevos mecanismos de explotación de la información que permita 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, específicamente al Área Económico-Administrativa.

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, resulta interesante la idea de entrenar una red neuronal con una serie de datos previamente definidos con base en un análisis estadístico y que ésta adquiera la capacidad de determinar la trayectoria escolar de un estudiante. Para lo anterior, es necesario lograr una efectividad mínima del 85%; si esto sucede se puede hablar de que los resultados del entrenamiento y pruebas de la red neuronal pueden ser aplicados en la predicción de casos.

De lo anterior, surge 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, surgen una serie de preguntas específicas a responder:

- ¿Cómo seleccionar las dimensiones apropiadas del Test Psicométrico Multidimensional para construir, mediante una red neuronal, un modelo predictivo de trayectoria escolar?
- ¿Cómo diseñar una red neuronal que reciba como entrada los resultados seleccionados del Test Psicométrico Multidimensional y los datos académicos de ingreso y como salida la trayectoria escolar de los estudiantes?
- ¿Cómo asegurar que la red neuronal pueda utilizarse como mecanismo predictivo de la trayectoria escolar?

Objetivos del estudio

Objetivo general

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.

Objetivos específicos

- Seleccionar las dimensiones apropiadas del Test Psicométrico Multidimensional para construir, mediante una red neuronal, un modelo predictivo de trayectoria escolar.
- Diseñar una red neuronal cuyas entradas sean los resultados del Test Psicométrico Multidimensional de mayor impacto, así como los datos académicos de ingreso de los alumnos y las salidas la trayectoria escolar de dichos estudiantes.
- Asegurar que la red neuronal pueda utilizarse como un modelo predictivo de la trayectoria escolar, logrando una eficiencia mínima del 85% en la fase de pruebas.

Justificación y delimitación del estudio

Justificación

Considerando el valor de la información de los alumnos del Área Económico-Administrativa y la poca explotación de que ha sido objeto, aunado a los nuevos modelos matemáticos-computacionales, existe la posibilidad de desarrollar una herramienta que conjugue de manera óptima las nuevas tecnologías y herramientas para darle un giro al uso de la información y que, con base en los resultados que se generen, 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 y procesamiento de los datos del Test Psicométrico Multidimensional en conjunto con los datos académicos de ingreso, genera un ambiente propicio para detectar, de manera temprana, alumnos de nuevo ingreso cuyo desempeño escolar pudiera estar en situación de riesgo y dotar al programa institucional de tutorías de herramientas sólidas para asignar tutores académicos a estos estudiantes de manera anticipada, con información que le permita identificar claramente los aspectos en los cuales debe poner especial atención para lograr que el alumno concluya de manera exitosa sus estudios.

Sin lugar a dudas, los principales beneficiados con este trabajo de investigación serán los alumnos de nuevo ingreso, quienes al momento de su incorporación a la Universidad Autónoma de Chihuahua y después de obtener resultados del Test Psicométrico Multidimensional, tendrán la posibilidad de ser canalizados de manera oportuna y eficiente con expertos que, mediante un trabajo colaborativo, le ayuden al estudiante a elevar su calidad educativa y llevar a buen término sus estudios de licenciatura.

Del mismo modo se verán favorecidos, los tutores académicos, ya que la presente investigación va a desarrollar un modelo matemático-administrativo que les propicie la asignación de estudiantes con algún problema que pueda repercutir en su trayectoria escolar; esto es, la asignación de tutorandos se realiza de una manera más precisa con la que el tutor académico puede tomar acciones más encaminadas a la mejoría de la situación escolar de los estudiantes.

En tercer lugar, pero no menos importante, es el beneficio que obtiene la Institución al detectar de manera temprana estudiantes en posible situación de riesgo, ya que del mismo modo 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.

Las redes neuronales son modelos matemáticos que comúnmente se utilizan para tareas de clasificación de datos. Esta clase de algoritmos tienen la capacidad de generar modelos no lineales y pueden manejar grandes cantidades de información.

De igual manera, son tolerantes a fallas, lo que significa que, si por alguna razón la información de entrada no está completa, puede lograr una correcta clasificación de los datos.

El desarrollo de la presente investigación contribuye a un avance significativo en el mundo de la inteligencia artificial, al conjugar a través de los algoritmos de redes neuronales, los resultados producto de otras investigaciones; integrando de manera óptima aspectos psicológicos, conocimientos y aptitudes, con resultados previamente calculados que sirvan de base para la predicción de nuevas entradas.

Tal como se describió anteriormente, la Universidad actualmente utiliza mecanismos para la asignación de tutores-tutorandos que no aseguran que los estudiantes atendidos en el programa, sean los más vulnerables en primera instancia, por lo que es necesidad de la institución asegurar que el Programa Institucional de Tutorías atienda en primer lugar, a estos estudiantes en posibilidad de riesgo, situación que se pretende lograr con el desarrollo de una red neuronal.

Las redes neuronales han avanzado a pasos agigantados en la solución de problemas de este tipo, tal como han sido los trabajos desarrollados por Villagrà Arredondo, Gallego Durán, Llornes Largo, Compañ Rosique, Sature Cuerda y Molina Carmona (2016), Pandey y Taruna (2016), Costa, Fonseca, Almeida Santana, Ferrera de Araújo y Rego (2017), entre otros; en donde la predicción del comportamiento con base en el aprendizaje, logra una efectividad tan alta que proporcionan una alternativa viable para la lograr una confiabilidad mínima del 85% en los resultados.

Delimitación

La Universidad Autónoma de Chihuahua está integrada por 15 Unidades Académicas, de las cuales se consideran para el problema de investigación a la Facultad de Contaduría y Administración y a la Facultad de Economía Internacional, las cuales conforman el Área Económico-Administrativa.

Del total de estudiantes que éstas unidades tienen, la muestra está integrada por aquellos alumnos de nivel licenciatura en los campus Chihuahua, Delicias, Parral y Camargo que hayan ingresado en los ciclos escolares agosto – diciembre 2014 y enero – junio 2015 y que de igual forma hayan respondido el Test Psicométrico Multidimensional durante esos periodos.

Es necesario considerar, que debe hacerse una depuración para eliminar aquellos resultados que no se encuentren dentro de los rangos validos en sus valores con la finalidad de eliminar posibles desviaciones posteriores.

Formulación de la 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.
- Una red neuronal de retropropagación diseñada y entrenada con base en los datos de entrada y salida previamente establecidas logrará una efectividad mínima del 85% en el entrenamiento.



- 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.

II. Revisión de literatura

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-dimensionalmente para sustentar la orientación psicopedagógica y los programas institucionales de tutoría estos se encuentran indicados en la indicados en la tabla 9.

El TPM tiene el valor agregado de haberse diseñado, validado y estandarizado especialmente para nuestro contexto mexicano con excelentes índices de confiabilidad (Turborienta, 2014).

En el año 2007 la empresa Turborienta lo desarrolló especialmente para el acompañamiento psicopedagógico y tutorial. Se sustenta en las neurociencias y en casi 30 años de investigación y desarrollo tecnológico.

Su proceso de evaluación sistematizado integra complejos algoritmos computacionales y una conformación flexible en sus gráficas de tal manera que sus resultados pueden contemplar únicamente la información que cada institución determine oportuno que conozcan tanto tutores como estudiantes, complaciendo así cualquier criterio o política al respecto (Turborienta, 2014).

Esta herramienta genera una gran cantidad de información de cada alumno que al ser analizada de manera cuidadosa puede impactar de manera muy positiva en el mejoramiento de los indicadores de deserción escolar, considerando no solo aspectos académicos sino también de otro tipo como psicológicos, sociales, familiares, etc.

Tabla 9. Test Psicométrico Multidimensional

Test Psicométrico Multidimensional		
Inteligencia	Análisis de potenciales complementarios	
• Coeficiente intelectual • Velocidad intelectual	• Razonamiento espacial • Inteligencias múltiples • Percepción • Creatividad • Memoria • Razonamiento concreto	• Razonamiento abstracto • Persuasión • Toma de decisiones • Programación mental • Automotivación
Personalidad	Estilos de aprendizaje	Orientación vocacional
• Temperamento • Agresividad • Madurez • Sociabilidad • Ambición • Instintos	• Visual, auditivo, kinestésico, • Experimental/teórico • Memorizado / comprendido • Concreto / abstracto • Imágenes / textual • Sistemático / espontáneo	• Detección de las principales vocaciones de los examinados
Factores de riesgo	Valores y mapa familiar	Mapa académico
• Predisposición a adicciones • Predisposición a depresión	• Valores físicos, afectivos, estéticos, morales, humanos, socioculturales. • Constitución dinámica y apoyo familiar	• Aptitud, actitud y estabilidad académica • Habilidad cognoscitiva • Liderazgo • Hábitos de estudio • Trabajo en equipo • Responsabilidad • Adaptabilidad • Dinámica académica

Fuente: (Turborienta, 2014)

Esta herramienta genera una gran cantidad de información de cada alumno que al ser analizada de manera cuidadosa puede impactar de manera muy positiva en el mejoramiento de los indicadores de deserción escolar, considerando no solo aspectos académicos sino también de otro tipo como psicológicos, sociales, familiares, etc.

Para efectos prácticos, los resultados del Test Psicométrico Multidimensional utilizados en esta investigación se agrupan en 8 dimensiones, todas ellas integradas por una serie de factores cuya definición se muestra a continuación:

Coefficiente intelectual

- *Coefficiente intelectual*: es el nivel de desarrollo mental basado en la eficacia y rapidez en sus procesos y funciones, de acuerdo a la edad del examinado. Considera su habilidad para resolver situaciones nuevas y/o complejas, la aptitud cognoscitiva (proceso de adquirir conocimiento), la capacidad de codificación de la información, comprensión, planeación, solución de problemas y evaluación de resultados, etc. Se basa en pautas básicas intelectuales con énfasis en la lógica matemática, las relaciones espaciales y la lingüística que le dan facilidad, eficiencia y perdurabilidad a su aprendizaje para saber hacer en contexto y afrontar estratégicamente sus responsabilidades escolares y laborales bajo una expresión natural.
- *Inteligencia emocional*: es el conjunto de habilidades y actitudes relacionales en el alumno que le permite entender, manejar controlar y comunicar sus emociones y sentimientos adecuadamente, así como escuchar y comprender los sentimientos y opiniones de otros. Involucra la capacidad de controlar sus propias reacciones y temperamento ante situaciones de estrés, negociación, crisis, discusión o conflicto, manteniendo una comunicación prudente y asertiva mediante una negociación inteligente.
- *Hemisferio cerebral izquierdo*: gobierna principalmente la parte derecha del cuerpo y se caracteriza o especializa en manejar los procesos intelectuales de manera delimitada o circunscrita, procesando la información de manera analítica y de forma secuencial, paso a paso y de forma lógica y lineal. De esta forma, analiza, abstrae, cuenta, mide los tiempos, planea procedimientos, verbaliza, piensa en palabras y en números; es decir, contiene la capacidad para dominar las matemáticas y para leer y escribir, donde la percepción y la generación verbal depende del conocimiento mismo del orden o secuencia en el que se pueden producir los sonidos. El hemisferio

izquierdo conoce el tiempo y su transcurso y se guía por la lógica lineal y binaria y con pensamientos realistas fríos y dominantes. Emplea un estilo de pensamiento convergente, obteniendo nueva información al usar datos ya disponibles, formando nuevas ideas o datos convencionalmente aceptables.

- *Hemisferio cerebral derecho:* se especializa en la percepción global, sintetizando la información que le llega. Gracias a este, se aprecian las cosas en el espacio y cómo se combinan las partes para formar el todo. Entiende las metáforas, sueña y crea nuevas combinaciones de ideas. Es el experto en el proceso simultáneo o de proceso en paralelo; es decir, no pasa de una característica a otra, sino que busca pautas y similitudes. Procesa la información de manera global, partiendo del todo para entender las distintas partes que componen ese todo. Es intuitivo en vez de lógico, piensa en imágenes, símbolos y sentimientos. Tiene capacidad imaginativa y fantástica, espacial y perceptiva. Concibe las situaciones y las estrategias del pensamiento de una forma total. Integra varios tipos de información (sonidos, imágenes, olores, sensaciones) y los transmite como un todo.
- *Cerebro reptílico:* las personas con preeminencia de este cerebro reflejan una inclinación conductual más instintiva con atención especial a las necesidades vitales. Su conducta suele ser un tanto inconsciente, refleja y/o automática. Su proceder cotidiano tiende a obedecer más a su inclinación instintiva que a sus sentimientos, razonamiento o reflexión profunda, por lo que tienden a ser prácticos, reactivos o arrebatados y no suelen detenerse a prever las consecuencias de sus actos al momento de reaccionar. Esta área cerebral no entiende de pasado o futuro, sólo vive el presente y así reacciona. Su función es actuar y ante posibles amenazas sólo tiene dos tipos de respuesta: ataque o huida con muy poco o ningún proceso sentimental. Incluye el impulso por la supervivencia: comer, beber, temperatura corporal, sexo, territorialidad, necesidad de cobijo y de protección.
- *Corteza cerebral:* tendencia al razonamiento frío y calculador en el discernimiento cotidiano del estudiante. Comprende los dos hemisferios

cerebrales y es la estructura más reciente y avanzada en la evolución y, por ende, significativa para el aprendizaje. Protagonista de las funciones trascendentales de la inteligencia y el lenguaje; presenta especial inclinación hacia los retos cognitivos y es donde se llevan a cabo los procesos intelectuales superiores, el desarrollo social, el proceso racional de entendimiento, análisis, planificación, habilidad de procesar experiencias futuras y la creatividad mediante la imaginación. Su carácter más específico es la capacidad de anticipar, de poner el futuro posible en el presente.

- *Cerebro límbico*: está asociado a la capacidad de sentir y desear y se dan procesos emocionales y estados de calidez, amor, gozo, depresión, odio, etc., así como procesos que tienen que ver con las motivaciones básicas. De esta manera, este sistema constituye el asiento de las emociones de la inteligencia afectiva y motivacional, por lo que incide en este sentido en la productividad, la satisfacción en el trabajo escolar y en el aprendizaje, máxime que en ella se encuentra gran parte de la memoria. Con su aparición surge la capacidad de aprender y modelar las respuestas automáticas pro-supervivencia y, por lo tanto, memorizar nuevas respuestas para poder utilizarlas en situaciones futuras semejantes; es decir, procesa experiencias presentes y pasadas de manera adaptable y, por lo tanto, acepta situaciones o estímulos nuevos, a los que evalúa como placer o dolor.

Inteligencias múltiples

- *Inteligencia lingüística*: es la capacidad del uso efectivo del lenguaje (hablado, escrito y no verbal). Implica la habilidad comunicativa de acuerdo al contexto sociocultural del estudiante, que demanda un nivel mínimo determinado a fin de integrarse y desenvolverse adecuadamente en su ámbito, ya sea educativo, familiar o laboral. Utiliza predominantemente el hemisferio izquierdo.
- *Inteligencia lógica – matemática*: intenta de dar una “forma universal” al pensamiento, expresándolo por un sistema unívoco de signos en el que cada uno tenga un significado en un mismo contexto y donde sus relaciones se

puedan reducir a “expresiones matemáticas” de manera comparable y cuantificable. De esta manera, ayuda a relacionar conceptos de forma esquemática y técnica, como: números, relaciones y patrones lógicos, así como otras funciones y abstracciones. Esta inteligencia corresponde al modo de pensamiento del hemisferio lógico (izquierdo) y se pone en marcha cuando nuestro cerebro debe relacionar datos de manera cruzada y procesarlos para obtener un resultado o una combinación de resultados, proporcionando un método, orden y sentido a nuestras acciones y/o decisiones.

- *Inteligencia espacial:* habilidad de apreciar con certeza las imágenes visuales y espaciales con sentido de orientación y ubicación, así como de representar gráficamente de las ideas. Incluye sensibilidad para apreciar el color, la línea, la forma, la figura, el espacio y sus relaciones con una capacidad de hacer un modelo mental en tres dimensiones del mundo y discernir una variante diferente de este (o un fragmento de él, según la situación). También, está relacionada con el movimiento de las diversas partes de nuestro cuerpo, con la coordinación y el equilibrio, etc.
- *Inteligencia musical:* capacidad para percibir, distinguir, transformar y expresar el ritmo, timbre y tono de los sonidos musicales. Puede incluir capacidad para componer e interpretar piezas con creatividad, así como juzgar eficazmente tanto la música como el sonido en general.
- *Inteligencia corporal:* es la capacidad de unir el cuerpo y la mente para lograr el perfeccionamiento del desempeño físico, así como adquirir información por efecto del movimiento y la vivencia. Se usa el propio cuerpo para expresar ideas y sentimientos, al involucrar particularidades de coordinación, equilibrio, destreza, fuerza, flexibilidad y velocidad. Comprende la capacidad de utilizar el propio cuerpo para realizar actividades o resolver problemas y como medio de auto-expresión, e incluye el uso de las manos para crear y manipular objetos físicos relacionándose con la posibilidad que tiene el estudiante para controlar sus movimientos.

- *Inteligencia interpersonal:* se basa en el desarrollo de la empatía y la capacidad de manejar las relaciones interpersonales a fin de entenderse y relacionarse favorablemente con los demás, distinguir sus motivaciones, las razones que explican su comportamiento, sus estados emocionales y signos interpersonales y responder de manera efectiva a dichas acciones de forma lógica, sensata, empática y práctica. Define la capacidad para establecer y mantener relaciones sociales y para asumir diversos roles dentro de grupos, ya sea como un miembro más o como líder.
- *Inteligencia intrapersonal:* siendo parte medular de la inteligencia emocional, refiere a la habilidad del estudiante para formar un modelo preciso y verídico de sí mismo y conocer y manejar adecuadamente los aspectos intrínsecos de su persona como la autocomprensión, el acceso a la propia vida emocional, los sentimientos, así como la capacidad de efectuar discriminaciones de estas emociones para interpretar y orientar la propia conducta al conocerse introspectivamente. Incluye el diálogo y el contacto con la vida afectiva interna y le permite ver con claridad sus verdaderos anhelos y deseos para orientar su conducta hacia dichos objetivos. Tienen especial relevancia tres capacidades: la capacidad de percibir las propias emociones, la capacidad de controlarlas y la capacidad de motivarse a sí mismo.

Competencias intelectuales

- *Percepción:* es la habilidad del joven para dirigir sus pensamientos, concentración y observación a los aspectos esenciales de algo específico y abstenerse de hacer caso de aquellos estímulos o ideas que son irrelevantes o ajenas y que se pueden manifestar como producto de la imaginación, o bien físicamente a través de objetos o personas que están presentes como fuente de distracción. Se mide por la intensidad y por la resistencia para mantener la focalización por periodos prolongados y suficientes de acuerdo con los requerimientos de cada situación a fin de recibir, entender y canalizar cognoscitivamente lo que se debe percibir. De esta manera, se tiene dominio

de la capacidad de recibir, interpretar, discriminar y organizar la información captada por los sentidos, sensaciones y/o ideas, tomando conciencia y conocimiento de ello.

- *Análisis*: es el pensamiento experto en focalizar el detalle, la precisión, la enumeración y la diferenciación de las cosas que han sido consistentes o previamente agrupadas, con la facultad de descomponerlo en sus elementos constitutivos y percibir las relaciones existentes de sus partes. Su capacidad puede profundizar hasta el grado de conocer sus elementos fundamentales y concentrarse en la información significativa según criterios preestablecidos de acuerdo con un propósito. La capacidad de análisis permite al estudiante conocer más profundamente las realidades con las que se enfrenta, simplificar su descripción, descubrir relaciones aparentemente ocultas y construir nuevos conocimientos a partir de otros que ya poseía.
- *Síntesis*: capacidad de conceptualizar objetivamente con alto nivel de significabilidad a partir de la reunión y análisis de las partes que conjugan un contenido y la integración de los elementos relevantes, a fin de extraer y asentar la información más importante. Puede expresarse con otras palabras y estilo cambiando el orden o utilizando analogías; trabajo de investigación y ampliación de contenidos. Permite recordar con claridad lo estudiado y exige el descubrimiento de lo esencial, desarrollando la capacidad de juzgar críticamente, concentrarse en el tema y liberar la creatividad personal. Esta competencia resulta fundamental en la capacidad de “aprender a aprender”.
- *Razonamiento abstracto*: habilidad para combinar elementos separados de información o respuestas específicas y, a partir de ello, generar ideas, conceptos, conocimientos, convicciones, emociones o deducciones. Se sustenta principalmente de información suministrada por la memoria y, posteriormente, la recombina creativamente con la información nutrida por el razonamiento concreto. Involucra el análisis de elementos de manera aislada al tiempo que presta atención al conjunto, advirtiendo patrones o tendencias que permiten arribar a una conclusión lógica. El pensamiento abstracto sirve

para ahondar en los detalles y poder ver más allá de lo que se puede ver, sentir o tocar, creando nuevas ideas y potenciando al mismo tiempo el pensamiento creativo, el cual conduce hacia soluciones nunca antes planteadas.

- *Comprensión:* la comprensión es un proceso de creación mental donde, a partir de datos percibidos por cualquiera de los sentidos, el estudiante crea una imagen del mensaje que se le quiere transmitir, otorgándole un significado que puede ser correcto o incorrecto, a fin de tratar de llegar a comprender el contenido o mensaje en su real intención o significado. Los datos pueden ser palabras, conceptos, relaciones, implicaciones, formatos, estructuras, ya sean lingüísticas, culturales, sociales, etc. Consiste en aislar, identificar y unir de forma coherente la información y realizar una interpretación lo más adecuada y acorde posible para poder entenderla. La creación de interpretaciones puede ser inconsciente o consciente.
- *Aprendizaje:* proceso mediante el cual se adquiere una determinada habilidad, se asimila con pertinencia y suficiencia una información o contenido, o bien, a raíz del cúmulo de experiencias previas, se sustenta y acredita la incorporación de decisiones con la certidumbre de lograr buenos resultados. Asimismo, da por sentado la comprensión correcta y el convencimiento tácito sobre un conocimiento o contenido, dando lugar a que el estudiante se apropie de sus conceptos, procedimientos, actitudes y valores y, a partir de ello, adquiera distintas destrezas o habilidades adoptando nuevas formas de abordar sus experiencias, retos y vivencias. El aprendizaje permite adaptarse motora e intelectualmente al medio en el que se vive.
- *Memoria:* nos permite tener la capacidad de contemplar el pasado y planificar el futuro recordando o evocando información previamente aprendida y alojada en la memoria de corto, mediano y largo plazo; además, considera los diversos procesos de adquisición, almacenamiento, codificación, construcción, reconstrucción y recuperación de la información que enmarcan

recuerdos con permanencia desde un segundo, hasta toda la vida (memoria remota). Se realiza con base en sistemas complejos interconectados con diferentes propósitos y comportamientos y funciones como: memoria auditiva, registra preferentemente lo que oye; visual, retiene detalles relacionados con figuras, colores, lugares, personas, etc.; conceptual, de datos, cuestiones y relaciones abstractas; motora, vinculada a las habilidades motoras, a cómo manejar y otras varias que difieren por contenido o utilización. Es fundamental aprender a transferir contenidos de la memoria de corto plazo a mediano y largo plazo para generar aprendizaje académico significativo y perdurable. El cerebro no está simplemente esperando a un estímulo externo para reaccionar, sino que está ocupado con su propia actividad interna.

- *Adaptabilidad:* la adaptabilidad mental es una de las facultades trascendentales de la inteligencia con grandes repercusiones en el ánimo, sentimientos, tranquilidad e incluso felicidad. Refleja la habilidad para adaptarse positivamente y con estabilidad en situaciones que representen un reto en el individuo. Es también la posibilidad de entender y apreciar perspectivas diferentes de una situación y adaptarse a nuevas circunstancias que modifican las ya conocidas. Incluye cambiar o adaptar nuevos enfoques en función de los requerimientos, evaluando y cuestionando lo que se estaba realizando para encontrar nuevas ideas o alternativas de mejora. Bajo el ámbito de competencias intelectuales, esta facultad hace énfasis en la adaptación de la información nueva con la ya obtenida en un entorno cambiante.
- *Creatividad:* la creatividad infiere añadir un problema o desafío a la mente, ya sea imaginándolo, visualizándolo, suponiéndolo, meditando y luego elaborar un conjunto de reflexiones que puedan aterrizar convenientemente a una idea, concepto o esquema que pueda darle respuesta, añadiendo alta inventiva e innovación, o bien permitiendo hallar soluciones novedosas o no convencionales. Supone estudio y reflexión más que acción y se acredita mediante la idea de la “originalidad”, con el propósito de instrumentar mejoras

en un entorno determinado. En su materialización puede adoptar, entre otras, formas artísticas, literarias, publicitarias, mercadológicas, científicas, etc., y, si bien no es privativa de ningún área en particular, es el germen de una creación que es nueva, útil u original.

- *Adaptación:* capacidad de prever lo que puede llegar a pasar a partir de ciertos indicios o elementos clave y, sobre ello, prever las consecuencias o posibles acontecimientos futuros y considerar de forma realista acciones, respuestas o soluciones alternativas a favor de sus objetivos. Analizar el futuro incluye ser capaz de entender su dinámica y articular sus componentes clave como: ¿qué va a pasar?, ¿cómo aprovecharlo o prevenirlo?, ¿cuáles son las principales incertidumbres?, ¿qué escenarios futuros son razonables a mediano o largo plazo?, ¿cómo gestionar los riesgos? Las previsiones o predicciones se basan en datos o tendencias y de forma cautelar se gestionarán las probabilidades y las acciones.
- *Persuasión:* capacidad para influir en los puntos de vista o acciones de los demás hacia una nueva decisión reflexiva y colaborativa y no por convencimiento o imposición. Es una característica básica para alcanzar metas importantes en la vida, ya que, de una u otra manera, todo el tiempo se hacen esfuerzos para hacer valorar la forma de sentir, pensar y actuar, así como la fortaleza de las ideas y de lo que son capaces. La persuasión es combinar armónica y estratégicamente los hechos con una forma particular al exponerlos, por ello un argumento contado por diferentes personas pueden tener resultados dramáticamente diferentes, aunque empleen el mismo contenido o palabras. La persuasión debe ser utilizada siempre para fines justos y positivos y es una competencia que resulta trascendental en el liderazgo y en las actividades administrativas y comerciales futuras de los jóvenes.
- *Planeación y toma de decisiones:* capacidad de organizar, planear y ejecutar el trabajo académico eficazmente y determinar el mejor curso de acción ante las diferentes situaciones o problemas que se presenten. Se basa en elegir

una opción entre varias alternativas y programar un esquema estratégico de acciones encaminadas al logro de un objetivo en tiempo y forma. Para realizarlo, se necesitan entender y establecer metas específicas que sean medibles, cuantificables y con fechas alcanzables, a partir de tres premisas: congruencia, factibilidad y claridad. La toma de decisiones se fundamenta mediante el rastreo de información de calidad según la naturaleza de cada problema, y las acciones que se deriven de ella pueden marcar trascendentales diferencias.

- *Velocidad intelectual*: este factor pondera el coeficiente entre la rapidez y la precisión con la que el joven resolvió el test y refleja la celeridad y eficacia de su capacidad de entendimiento y agilidad mental.

Programación mental

- *Mentalidad propositiva (optimista)*: se refiere a una actitud positiva hacia la vida, considerando los retos y obstáculos que se presentan como desafíos claramente superables o reversibles bajo una expectativa psicológica que formula que todo saldrá bien a pesar de los contratiempos, escenarios adversos o problemas. Es una manera natural en el estudiante de percibir y juzgar las cosas desde una perspectiva o enfoque más favorable, donde la actitud impide caer en la apatía, la desesperación o la depresión frente a las adversidades, pues emplea modelos de pensamiento mucho más eficientes y constructivos al enfrentarse a los conflictos y las frustraciones.
- *Auto-programación subconsciente*: señala cómo se suele programar mentalmente mediante la calidad de los pensamientos que, consciente o inconscientemente, se impregnan constantemente en la parte subconsciente de nuestra mente. Se basa en pensamientos positivos o negativos que actuarán a favor o en contra la manera imparcial e impersonal y de forma precisa y exacta.
- *Sinergia emocional- intelectual*: retroalimentación que suele sostener el estudiante entre sus sentimientos y pensamientos cotidianamente que

actuarán como temores o facilitadores de una parte sensible de su seguridad cotidiana con afectación (entre otros) en sus decisiones, en su comunicación verbal y no verbal, en su conducta cotidiana y en cómo es percibido por los demás. El bienestar emocional depende de no dejarse llevar por sentimientos o emociones automáticas negativas que pueden ser exageradas o dramáticas; en contraparte, depende de tener la retroalimentación consistente y positiva de nuestros pensamientos, a fin de mantener un sano equilibrio interior y destreza a favor de la interacción y manejo de las fortalezas y debilidades, así como de las amenazas y las oportunidades.

- *Aprovechamiento de su capacidad de mentalización:* este factor pondera el grado de concientización del joven respecto a la importancia y trascendencia de mantener un pensamiento positivo leal y permanente de calidad en su programación mental; esto, en perspectiva y prospectiva de la gestión cotidiana de los diferentes retos, anhelos y desafíos que vive y enfrenta en las circunstancias que le rodean. El optimismo perseverante y persistente da acceso a un modelo emocional y racional más esperanzador y sereno, que posibilita sentir con mayor certidumbre y confianza los diferentes retos que se nos presentan, como si fuera una fuente de atracción natural al bienestar. Por el contrario, pensar negativamente puede disminuir o dificultar el logro de las metas, pues, entre otras cosas, nos impregna una sensación plegada de incertidumbre, mala suerte y fracaso en lo que nos rodea.
- *Capacidad de automotivación:* este factor engloba la capacidad y habilidad total del estudiante para motivarse a sí mismo, dándose las razones, el impulso, el entusiasmo o el interés para encontrar robustos estímulos positivos (internos y/o externos) que sean perdurables e impulsen todas las acciones que le ayuden a conseguir sus metas. Asimismo, se refiere a minimizar en sus esfuerzos los efectos y sensaciones negativas de experiencias y fracasos pasados que le han sido desagradables. La automotivación le permite allegarse del entusiasmo y positivismo suficiente para luchar con determinación y consolidar las dosis necesarias de

autoestima y energía que se puedan traducir en continuas y perseverantes ganas de hacer y lograr las cosas.

Mapa académico

- *Aptitud académica:* revisa el conjunto de competencias, conocimientos y aptitudes que facultan a un estudiante para desempeñar bien sus responsabilidades escolares desde un punto de vista pragmático y general. Da un contexto claro de su habilidad para aquilatar la experiencia académica en función de su potencial intelectual; de esta manera perfila el crecimiento con aptitudes que permitan abordar adecuadamente los desafíos por venir, así como aprender continuamente al resolver los problemas de forma autónoma. Se basa en pautas básicas intelectuales que le dan facilidad, eficiencia y perdurabilidad a su aprendizaje para saber hacer en contexto y afrontar estratégicamente sus responsabilidades escolares bajo una expresión natural.
- *Actitud académica:* describe la postura que decide adoptar el alumno para hacer frente a sus responsabilidades escolares, al conjugar la motivación heredada de sus éxitos o fracasos académicos previos frente a sus intereses, prioridades y circunstancias personales como: grado de responsabilidad, pasatiempos, diversión, amigos, novia, búsqueda de identidad, problemas, etc.
- *Dinámica interpersonal:* este factor determina cómo interactúa el estudiante con el resto de las personas que conforman la comunidad académica, así como su posibilidad de resultar aceptado o rechazado por estas en términos generales, y por lo tanto la posibilidad de percibir y/o disfrutar de un ambiente ameno y agradable en la institución. Los jóvenes buscan su integración adaptando su personalidad y moldeando sus signos socioculturales en perspectiva y prospectiva de las características del contexto escolar que enfrentan, a fin de lograr aceptar y ser aceptados.

- *Disposición a la autoridad:* señala la capacidad del estudiante para acatar las órdenes y disposiciones de personas que tienen una mayor edad y/o un mayor cargo jerárquico, como: profesores, directores, jefes e incluso padres, tutores u otras figuras de autoridad. Enmarca la capacidad de reflexionar, detenerse y actuar regulando su comportamiento para evitar una actitud desafiante, irrespetuosa, conflictiva o impertinente con quien social, moral o jurídicamente no debe tenerla. Cada persona o institución tiene una justipreciación inherente al respeto elemental que se le debe conceder y su juicio se dictamina de acuerdo al sentido común establecido por los valores de cada sociedad.
- *Interrelación con los maestros:* analiza y evalúa la relación interpersonal del joven con los maestros que ha tenido durante su vida académica, con énfasis en su dinámica más reciente. Medirá la factibilidad de caer en situaciones conflictivas, o bien una relación cordial que posibilita un contexto académico con sentido y dominio disciplinar. Esta interrelación pudiera estar ligada con el factor de disposición a la autoridad o dinámica interpersonal, entre otros.
- *Interrelación con compañeros:* determina cómo interactúa el alumno con el resto de sus compañeros. Los jóvenes buscan su integración adaptando su personalidad y moldeando sus signos socioculturales en perspectiva y prospectiva de las características del contexto escolar que enfrentan, a fin de lograr aceptar y ser aceptados. La interrelación podrá condicionar su actitud, participación en trabajos en equipo, posibilidad de tener amigos, seguridad en sí mismo, autoestima, así como su rendimiento y estabilidad académica.

Competencias académicas

- *Inclinación hacia el "trabajo bien hecho":* inclinación a la valoración de la perfección lograda como muestra patente, cabal y evidente del trabajo realizado. El alumno está convencido de que el esfuerzo que reclama el trabajo en su confección, no solo supone incorporar sostenidamente la inteligencia (pensar) y voluntad (querer), sino vencer su complejidad con un alto sentido de eficiencia.

- *Hábitos de estudio:* este factor enmarca la disposición del alumno para orientar el proceso formativo de una manera eficiente y pertinente con base en hábitos, deseos, orden, métodos y motivación por cumplir. Incluye las actitudes y los hábitos del estudiante ante sus responsabilidades académicas en general como: administración del tiempo, métodos de estudio, estilos y habilidades de aprendizaje, su responsabilidad ante tareas, exámenes, etc. versus sus actividades sociales, de esparcimiento, diversión o, en su caso, ocio y flojera.
- *Liderazgo positivo:* evalúa la capacidad del joven para guiar, motivar y persuadir a un grupo de personas para que logren metas específicas de manera voluntaria (rol de líder), con el convencimiento de que sus ideas cumplen el mejor interés para la mayoría. Este factor analiza el don de mando y carisma, entre otras aptitudes innatas, así como ciertas capacidades adquiridas como la comunicación, conducción de equipos, motivación grupal, capacidad para enfrentar y resolver problemas con responsabilidad, entre otros.
- *Trabajo en equipo:* capacidad de participar, adaptarse y trabajar en armonía con distintas personas al mismo tiempo en torno a un objetivo y trabajo común. Aporta gran sinergia y creatividad en la identificación de variables críticas de manera incluyente, maximizando la atención al detalle y la capacidad para resolver retos con mayor rapidez y eficacia. Involucra la disposición del examinado para interactuar con sus compañeros de clase bajo una actitud de compromiso, integración, armonía, productividad, compañerismo, respeto y libertad de opinión. Se considera este factor como uno de los valores fundamentales para desempeño en el mundo laboral.
- *Responsabilidad:* actitud ante los diversos compromisos adquiridos en su vida académica, personal y social, mediante la cual demuestra de forma consciente capacidad de respuesta al asumir las consecuencias de sus actos, acciones y decisiones en un marco de libertad. Este factor evalúa qué tan comprometido está el alumno en todos los ámbitos de su vida, con énfasis

en sus responsabilidades académicas, y emite la media de su comportamiento.

- *Adaptabilidad:* dentro del marco escolar, valora la capacidad de acoplarse rápida y armoniosamente a los diferentes ámbitos de convivencia, incluyendo convenientes e inconvenientes del entorno, políticas escolares, condiciones de limpieza o estéticas, exigencias especiales, dinámica interpersonal con compañeros y condiciones particulares de estudio, con la posibilidad de entender y apreciar perspectivas diferentes; también, valora la capacidad para adaptarse a las nuevas circunstancias que modifican las ya conocidas. Lo anterior tiene grandes repercusiones en el ánimo, los sentimientos, el manejo y/o causa de estrés, la tranquilidad y aún la felicidad.
- *Liderazgo negativo:* tendencia para persuadir con fines negativos a grupos de estudiantes o personas bajo el argumento o bandera de ofrecer o conseguir algo que les beneficiará directa o indirectamente, y como respuesta las personas lo siguen, esperando recibir la recompensa o beneficio prometido. Lo anterior genera desintegración, confrontación, división, e incluso puede derivar en algún tipo de violencia. También, el liderazgo negativo incluye actitudes de rebeldía o indisciplina grupal hacia otros estudiantes dentro y fuera de las instalaciones, lo que genera sentimientos que afectan de modo nocivo la estabilidad general, así como molestia a los demás alumnos o maestros, e inclusive deriva en burlas u hostigamiento a determinados compañeros.

Habilidades mentales

- *Razonamiento numérico:* es la habilidad entender, estructurar, organizar y resolver un problema, utilizando un método o fórmula matemática. Asimismo, es la capacidad para utilizar y relacionar los números, sus operaciones básicas, los símbolos y las formas de expresión y razonamiento matemático, para producir e interpretar distintos tipos de información, ampliar el conocimiento sobre aspectos cuantitativos y espaciales de la realidad, así como para resolver problemas relacionados con la vida cotidiana y con el mundo académico y laboral. Los cálculos aritméticos son considerados

procesos bilaterales (pertenecientes al hemisferio izquierdo y hemisferio derecho).

- *Razonamiento verbal:* mide la capacidad para conceptuar y expresar con palabras las ideas, los objetos y los elementos en general que rodean. Permite conocer mejor las expresiones y articulaciones complejas del lenguaje y la gramática. Este proceso del pensamiento, organiza, compara, analiza y sintetiza para los fines de la comunicación oral y escrita. El razonamiento verbal tiene su ubicación neurológica en el hemisferio izquierdo.
- *Razonamiento abstracto:* capacidad fundamental del pensamiento que empieza a desarrollarse comúnmente en la adolescencia y sirve para razonar a partir de elementos intangibles, es decir, se nutre de información abstracta: experiencias, conocimientos, intuiciones, creatividad, convicciones, etc. Es indispensable para toda respuesta inteligente en la solución de problemas y en la planeación. El pensamiento abstracto es fundamental, pues gracias a este, el ser humano cuenta con la capacidad para la deducción, relación, comparación, aplicación de lo aprendido, así como la posibilidad de sacar conclusiones.
- *Razonamiento concreto:* este razonamiento se enfoca en los hechos y elementos concretos o tangibles. Para poder analizarlos objetivamente, se sustenta principalmente en la información que se apega sensorialmente al estímulo, es decir en la que es percibida por los cinco sentidos. Se procesa en mayor proporción en el hemisferio izquierdo.
- *Razonamiento lógico:* uso del entendimiento para pasar de una idea a otra, con total integración, continuidad y congruencia. Esta clase de razonamiento, parte de una o varias premisas para llegar a una conclusión que puede determinarse como verdadera, falsa o posible. El razonamiento lógico, es una habilidad cognitiva a través de la cual se llega a conclusiones sólidas para tomar decisiones y resolver problemas en la vida cotidiana y académica.



- *Razonamiento espacial:* capacidad para calcular mentalmente la masa (espacio) y velocidad de los objetos y elementos que nos circundan, así como la capacidad de guiar o modificar los movimientos y sus desplazamientos en una determinada área, teniendo en cuenta a la vez, los límites exteriores y los de su propio campo de acción. Involucra también la capacidad de observación y la representación mental de los elementos físicos en sus diferentes perspectivas. El hemisferio derecho es el centro de las facultades viso-espaciales.
- *Memoria:* es la capacidad de reconocer y recordar una experiencia anterior con exactitud y puntualidad, incluyendo información, imágenes visuales, auditivas, sensoriales, etc. Este factor evalúa desde la memoria inmediata hasta la del largo plazo. El lóbulo temporal y el hipocampo están relacionados con la adquisición de los recuerdos.
- *Creatividad:* es la capacidad del cerebro para crear y producir cosas nuevas y valiosas, llegar a conclusiones nuevas y resolver problemas en una forma original; puede implicar aventura, audacia, intuición, riqueza de opciones, inventiva, alternativas de solución e imaginación entre otros, e ir más allá de la realidad que se conoce.
- *Lectura:* Proceso donde intervienen funciones sensoriales, psíquicas y cerebrales, para la decodificación, interpretación y comprensión de un sistema de signos lógicos, modelos y símbolos, que al procesarlos como lenguaje y luego interiorizarlos, el individuo construye su propio significado. Neurológicamente, la lectura se trabaja en el hemisferio izquierdo.
- *Concentración:* es la capacidad para centrar la atención de manera selectiva, intencionada y voluntaria sobre un objetivo, con independencia del entorno, sin permitir que en el pensamiento entren elementos ajenos a este y que interfieran en su consecución.
- *Comprensión:* serie de acciones que demuestran que la persona es capaz de captar la esencia o el sentido a partir de referencias aportadas de forma oral, gráfica, escrita, etc., dándoles una interpretación o significado propio.

La comprensión es un proceso activo que consiste en aislar, identificar y unir datos de forma coherente, con información que ya se tiene por medio de la experiencia.

- *Síntesis*: capacidad para realizar una versión abreviada de la información que se ha recibido, conservando con acierto lo importante o esencial. Implica la tarea de elegir, comprender, relacionar e integrar correctamente la información. Esta capacidad resulta importante en el proceso de aprender a aprender, en la comprensión y memorización, y en el aprovechamiento académico en general.

Estilos de aprendizaje

- *Teórico*: rasgo cognitivo predominante en cual el alumno aprende y desarrolla su trabajo académico a partir de información teórica. Implica apertura y facilidad para manejar y comprender los contenidos y explicaciones textuales de sus materias.
- *Experimental*: rasgo cognitivo en el que el alumno se inclina a vivir personalmente parte o todo de lo que desea aprender para entenderlo y desarrollarlo mejor. Implica una tendencia pragmática en su forma de validar las cosas y procesarlas mentalmente.
- *Kinestésico*: rasgo cognitivo en el que el alumno aprende procesando la información a través de la asociación a las sensaciones, los movimientos y los sentimientos. Son alumnos que pueden requerir movimientos y actividad física para captar mejor la información (podrían aparentar ser inquietos o hiperactivos), o bien que el aprendizaje contenga cargas emocionales que le permitan retener los datos en general.
- *Auditivo*: rasgo cognitivo que se orienta más hacia la asimilación de datos a través del oído. El alumno aprende procesando la información a través de las descripciones verbales y explicaciones orales y hablando.
- *Visual*: rasgo cognitivo neurolingüístico en el que el alumno aprende procesando la información a través de estímulos visuales. Este tipo de

aprendizaje suele ser muy rápido; los alumnos retienen la información de un libro y esquemas existentes.

- *Memorístico*: aprendizaje que promueve la adquisición de nuevos conocimientos mediante la retención. Se le facilita memorizar la información sin necesidad de comprenderla y sin seguir un proceso de significación como requisito.
- *Comprendido*: tendencia al aprendizaje por medio del cual el alumno elabora e internaliza nuevas ideas, conceptos y proposiciones con base en experiencias anteriores, con un sentido especial, trascendental y de valor para sí mismo. El aprendizaje se logrará siempre que estén adecuadamente claros y disponibles los contenidos en la estructura cognitiva del individuo y que funcionen como un punto de relación a sus conocimientos previos.
- *Concreto*: indica la proporción en la que el alumno utiliza su razonamiento concreto en su procesamiento mental cotidiano. Prefiere observar los hechos y los elementos objetivos para poder analizarlos. Se centra principalmente en la información obtenida por los cinco sentidos.
- *Abstracto*: indica la proporción en la que el alumno utiliza su razonamiento abstracto. El alumno se inclina a razonar integralmente los elementos y las actividades en las que se involucra. Se nutre en mayor medida por imágenes mentales, recuerdos y creatividad. Suele asociarse principalmente a una ejecución desestructurada, espontánea y creativa.
- *Espontáneo*: el alumno carece de un control o preparación estructurada para el aprendizaje y desempeño cotidiano escolar.
- *Sistemático*: el alumno lleva a cabo acciones preparadas y estructuradas para poder prever y enfrentar el proceso académico y realiza lo necesario ante sus responsabilidades escolares. Muestra interés para aprender a aprender e interés en los contenidos para comprender, dominar y aplicar los conceptos de manera práctica.

- *Textual:* la comprensión y retención del alumno es mayor cuando está apoyada en lecturas y textos.
- *Imágenes:* la concentración y retención del alumno es mayor cuando está soportada en imágenes e integra una interpretación relacionando los gráficos que analiza (Universidad Autónoma de Chihuahua, 2014).

Inteligencia Artificial

La inteligencia artificial es un campo de estudio bastante amplio en las ciencias sociales ha sido el comportamiento humano; disciplinas como la sociología, la psicología y la filosofía han enfocado sus esfuerzos en descifrar el impacto que tienen diversas acciones en el proceder del individuo y la manera de procesar la información para llegar a cierta reacción.

Con el avance de la computación, en los años cuarenta, los estudiosos del área se planteaban la idea de aplicar los adelantos existentes al respecto del comportamiento humano en la computación y lograr que, con el desarrollo de diversas técnicas, la computadora simulara el procesamiento de la información como lo realiza un ser humano; fue el origen de la inteligencia artificial.

Se podría considerar que uno de los primeros pasos hacia la Inteligencia Artificial fueron dados hace mucho tiempo por Aristóteles (384-322 a.C.), cuando se dispuso a explicar y codificar ciertos estilos de razonamiento deductivo que él llamo silogismos. Hacia finales de los setenta y principios de los ochenta, algunos programas que se desarrollaron contenían mayor capacidad y conocimientos necesarios para imitar el desempeño humano de expertos en varias tareas (Ponce Cruz, 2010).

Desde la época de las primeras máquinas de computación primitivas, sus diseñadores y usuarios han estado tratando de empujar las computadoras más allá de la función de automatización (Masters, 1993). No obstante, el primer trabajo de Inteligencia Artificial, fue realizado por Warren McCulloch y Walter Pitts (1943),

quienes propusieron un modelo constituido por neuronas artificiales, en el que cada una se caracterizaba por estar encendida o apagada; el encendido se daba como respuesta a la estimulación producida por una cantidad suficiente de neuronas vecinas (Russell & Norving, 2004).

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 a 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).

Para poder afirmar que un programa utiliza algún tipo de razonamiento humano, previamente habrá que definir cómo piensan los seres humanos. Habrá que penetrar en el funcionamiento de la mente humana. Hay dos formas de hacer esto: mediante la introspección o mediante la realización de experimentos psicológicos. Una vez que se cuente con una teoría bastante precisa de la mente, puede procederse a expresar tal teoría en un programa de computadora. Si los datos de entrada/salida del programa y la duración de tiempo de su comportamiento corresponden a los de la conducta humana, existe evidencia de que algunos de los mecanismos del programa también funcionan en los seres humanos (Russell & Norving, 2004).

La Inteligencia Artificial 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).

Algunas definiciones de Inteligencia Artificial se agrupan en las categorías establecidas en la figura 7.




Figura 7. *Categorías de la Inteligencia Artificial*

Fuente: (Ponce Cruz, 2010)

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).

Elementos de la Inteligencia Artificial

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

- Lógica difusa
- Algoritmos genéticos
- Redes neuronales artificiales

Se describe a continuación una pequeña introducción de los dos primeros, para posteriormente presentar de manera completa información al respecto de redes neuronales artificiales, herramienta primordial de este trabajo de investigación.

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).

En lógica difusa se parte del hecho de que conceptos como alto, bajo, ruidoso, dulce, caro, amargo, barato, delgado, etc., son percibidos de manera diferente por cada persona. Por ejemplo, para una persona de Alaska el concepto de caliente puede ser arriba de 10 °C, mientras que para un mexicano caliente es arriba de 30°C o en un proceso de fundición caliente es arriba de 300°C. Por esta razón los conjuntos caliente, tibio y frío son llamados conjuntos difusos.

Un conjunto difuso es un conjunto con límites borrosos o “no muy bien definidos” (Guzmán & M. Castaño, 2015).

Esta rama de la inteligencia artificial, le permite a una computadora analizar información del mundo real en una escala entre lo falso y lo verdadero. Cuando los matemáticos carecen de algoritmos que dictan cómo un sistema debe responder a ciertas entradas, la lógica difusa puede controlar o describir el sistema usando reglas de sentido común que se refieren a cantidades indefinidas. Los sistemas difusos frecuentemente tienen reglas tomadas de expertos, pero cuando no hay un experto, aprenden las reglas observando cómo la gente manipula los sistemas reales (Ponce Cruz, 2010).

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).

- Selección: es el mecanismo para la obtención de los individuos para la reproducción, acorde con la función de aptitud. En esta sección se obtienen cuales individuos son capaces de reproducirse y cuales no (Ponce Cruz, 2010).
- Cruce: una vez seleccionados los individuos, éstos son recombinados para producir la descendencia que se insertará en la siguiente generación. La idea principal del cruce se basa en que, si se toman dos individuos correctamente adaptados al medio y se obtiene una descendencia que comparta genes de ambos, existe la posibilidad de que los genes heredados sean precisamente los causantes de la bondad de los padres (Gestal, Rivero, Rabuñal, Dorado, & Pazos, 2010).
- Mutación: provoca una variación en el árbol de la población; este operador suele usarse con probabilidad muy baja (menos que 0.1) antes de introducir un individuo en la nueva generación (Gestal, Rivero, Rabuñal, Dorado, & Pazos, 2010).

En una búsqueda empleando dichas operaciones, se puede plantear una familia de individuos los cuales se seleccionan y después se considera a los más óptimos para realizar un cruzamiento entre ellos y la forma de evitar caer en mínimos locales es el empleo de la mutación (Ponce Cruz, 2010).

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

Las soluciones tradicionales en computación, están basadas en reglas o ecuaciones las cuales definen un sistema y deben ser explícitamente programadas. Esto es aplicable en situaciones en las que las reglas son conocidas, sin embargo, existen muchos sistemas para los cuales las reglas no son conocidas (Swingler, 2001).

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).

A lo largo de la historia, las redes neuronales han sido aplicadas en varios campos del conocimiento tal como de mencionan en la tabla 10.

Tabla 10. *Aplicaciones de las redes neuronales artificiales*

Área	Aplicación
Aeroespacial	Pilotos automáticos de alto rendimiento, simulaciones de trayectoria de vuelo, sistema de control de aeronaves, mejoras de piloto automático, simulaciones de componentes de aeronaves, detectores de averías de aviones.
Automotriz	Sistema automático de guía automovilístico, control de inyectores de combustible, detección de fallos de encendido, sensores de emisiones virtuales, analizadores de actividad de garantía.
Bancaria	Evaluadores de solicitudes de crédito, pronóstico de caja, clasificación de empresas, previsión de tipos de cambio, predicción de tasas de recuperación de préstamos, medición del riesgo de crédito.

Defensa	Control de armas, rastreo de blancos, discriminación de objetos, reconocimiento facial, nuevos tipos de sensores, procesamiento de señales incluyendo compresión de datos, extracción de características y eliminación de ruido, identificación de señales e imágenes.
Electrónica	Predicción de secuencia de código, disposición de sensores de circuitos integrados, control de procesos, análisis de fallos de sensores, visión de máquina, síntesis de voz, modelación no lineal.
Entretenimiento	Animaciones, efectos especiales, pronóstico de mercado.
Financiera	Evaluación de bienes raíces, asesor de préstamos, selección de hipotecas, clasificación de bonos corporativos, análisis de uso de líneas de crédito, programa de negociación de carteras, análisis financiero corporativo, predicción de precios de divisas.
Aseguradoras	Evaluación de solicitudes de pólizas, optimización de productos.
Fabricación	Control del proceso de fabricación, análisis y diseño de productos, diagnóstico del proceso y maquinaria, identificación práctica en tiempo real, inspección visual de sistemas de calidad, análisis de calidad de soldadura, predicción de la calidad del papel, análisis de la calidad de sensores de computadoras, análisis y diseño de productos químicos, análisis de máquinas de mantenimiento, vinculación de proyectos, planeación y administración, modelado dinámicos de sistemas de procesos químicos.
Medicina	Análisis de cáncer de células de mama, diseño de prótesis, optimización de tiempos de trasplantes, reducción de gastos de hospital, mejora de la calidad de hospitales, asesoramiento para pruebas de sala de emergencia.
Petróleo y gas	Exploración, sensores inteligentes, modelado de depósitos, decisiones de tratamiento de pozos, interpretación sísmica.
Robótica	Control de trayectoria, controladores, sistemas de visión, vehículos autónomos.
Lingüística	Reconocimiento de voz, compresión del habla, clasificación de la voz, sintetizador de texto a voz.
Telecomunicaciones	Compresión de datos e imágenes, servicios automatizados de información, traducción entre idiomas en tiempo real, sistemas de procesamiento de pago.
Trasporte	Sistema de diagnóstico de frenos, programación de vehículos, trazo de rutas.

Fuente: (Hagan, Demuth, Hudson Beale, & de Jesús, 2014)

Las redes neuronales se basan en una serie de principios, gracias a los cuales es posible resolver problemas, los cinco más importantes son:

- **Aprendizaje adaptativo:** esta es quizás la característica más importante de las redes neuronales, pueden comportarse en función de un entrenamiento con una serie de ejemplos ilustrativos. De esta forma, no es necesario elaborar un modelo a priori, ni establecer funciones probabilísticas. Una red neuronal artificial es adaptativa porque puede modificarse constantemente con el fin de adaptarse a nuevas condiciones de trabajo.

- Auto-organización: mientras que el aprendizaje es un proceso donde se modifica la información interna de la red neuronal artificial, la auto-organización consiste en la modificación de la red completa con el fin de llevar a cabo un objetivo específico. Auto-organización significa generalización, de esta forma una red puede responder a datos o situaciones que no ha experimentado antes, pero que puede inferir sobre la base de su entrenamiento. Esta característica es muy útil sobre todo cuando la información de entrada es poco clara o se encuentra incompleta.
- Tolerancia a fallos: en la computación tradicional la pérdida de un fragmento pequeño de información puede acarrear comúnmente la inutilización de un sistema. Las redes neuronales artificiales poseen una alta capacidad de tolerancia a fallos. Se entiende por ello que las redes pueden reconocer patrones de información con ruido, distorsión o incompletos, pero que pueden seguir trabajando, aunque se destruya parte de la red (con cierta degradación). La explicación de este fenómeno se encuentra en que mientras la computación tradicional almacena la información en espacios únicos, localizados y direccionables, las redes neuronales lo hacen de forma distribuida y con un alto grado de redundancia.
- Operación en tiempo real: las redes neuronales artificiales, de todos los métodos existentes, son las más indicadas para el reconocimiento de patrones en tiempo real, debido a que trabajan en paralelo actualizando todas sus instancias simultáneamente. Es importante destacar que esta característica sólo se aprecia cuando se implementan redes con hardware especialmente diseñados para el procesamiento paralelo.
- Fácil inserción en la tecnología existente: es relativamente sencillo obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas, lo que facilita la integración modular en los sistemas existentes (Hilera González & Martínez Hernández, 1995).

Ahora bien, existen ciertas características que indican cuando es posible utilizar una red neuronal para resolver un problema, las cuales se muestran en la tabla 11.

Tabla 11. Casos en los que una red neuronal puede ser utilizada

Caso	Descripción
Las redes neuronales operan en representaciones numéricas.	Una tarea debe expresarse en términos de una función de una codificación numérica a otra. Si un problema no puede expresarse de tal manera, no puede ser resuelto por una red neuronal.
Las redes neuronales con funciones no lineales.	Una tarea es de naturaleza no lineal si el efecto que un cambio en cualquier variable tiene en la salida depende de los valores de esa o cualquier otra variable de entrada. Las categorías son linealmente separables si es posible usar una línea recta para dividir puntos de datos que describen objetos en diferentes clases.
Las redes neuronales son diferenciables.	Es posible diferenciar la función con la que una red neuronal aprende. Muchos sistemas industriales o físicos necesitan expresarse en términos del efecto que tendría un pequeño cambio en los insumos, más que el efecto de un nuevo ajuste de entrada.
Las redes neuronales son capaces de generalizar.	Una red neuronal es un modelo generalizable de un conjunto de datos. La capacidad de generalizar significa que las redes neuronales son capaces de aprender de los datos ruidosos o incompletos.

Fuente: (Swingler, 2001)

Como puede notarse en la tabla 11, los casos en los que la viabilidad de utilizar una red neuronal para solucionarlos, se puede agrupar en dos tipos: problemas de clasificación y problemas de regresión.

En los problemas de clasificación, el objetivo consiste en crear un procedimiento mediante el cual un nuevo caso representado por unos atributos observados o características que constituyen los datos de entrada de la red, se asigne a una de entre un conjunto de clases predefinidas. A la construcción de estos clasificadores también se le conoce como reconocimiento de patrones.

Los problemas de regresión son problemas de ajuste de funciones, es decir, se trata de obtener una función de los atributos de entrada a la red o, lo que es lo mismo, se trata de encontrar una función continua de ciertas variables (Palma Méndez & Marín Morales, 2008).

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 8 (Palma Méndez & Marín Morales, 2008).




Figura 8. 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 bias 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). El aprendizaje supervisado permite buscar patrones en datos históricos relacionando todos los campos con un campo especial, llamado campo objetivo. Por ejemplo, los correos electrónicos se etiquetan como "spam" o "legítimo" por parte de los usuarios. El proceso de predicción se inicia con un análisis de qué características o patrones tienen los correos ya marcados con ambas etiquetas. Una vez determinados todos los patrones los correos nuevos que nunca han sido

marcados como spam o legítimos se comparan con los patrones y se clasifican en función de sus características (González, 2014).

- Aprendizaje no supervisado: es un método de aprendizaje automático donde un modelo es ajustado a las observaciones. Se distingue del aprendizaje supervisado por el hecho de que no hay un conocimiento a priori. En el aprendizaje no supervisado, un conjunto de datos de objetos de entrada es tratado. Así, 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, es útil para la compresión de datos fundamentalmente, todos los algoritmos de compresión dependen tanto explícita como implícitamente de una distribución de probabilidad sobre un conjunto de entrada (Flores Gutiérrez, 2013).

Cada uno de estos dos métodos de aprendizaje, cuenta con diversas redes. Para el caso del aprendizaje supervisado, las redes neuronales se pueden dividir en redes de una sola capa y redes multicapa.

Redes neuronales con aprendizaje supervisado

Redes de neuronas de una capa: el perceptrón

Las redes de una capa, presentan las entradas directamente conectadas a las salidas mediante pesos, tal como se muestra en la figura 9. Las salidas no interactúan, por lo que una red con n salidas puede ser analizada como n redes separadas.

El perceptrón es la red neuronal más sencilla. Está compuesto únicamente por una capa de neuronas de entrada y otra capa de neuronas de salida; si bien este tipo de red no tiene muchas aplicaciones, su estructura es la base de métodos más actuales. La principal aportación del perceptrón es que la adaptación de sus pesos

se realiza teniendo en cuenta el error entre la salida que obtiene la red y la salida que se desearía obtener (Palma Méndez & Marín Morales, 2008).




Figura 9. Red neuronal de una capa

Fuente: (Ponce Cruz, 2010)

El algoritmo de aprendizaje del perceptrón funciona para aprender funciones binarias linealmente separables, ya que de otra manera el algoritmo no convergería ni produciría la mejor solución. Debido a que las salidas son binarias, se emplean unidades lineales de umbral (Ponce Cruz, 2010).

Los perceptrones tienen dos limitantes principales: los valores de salida sólo pueden ser binarios, debido a la función de activación empleada y sólo pueden clasificar vectores linealmente separables, es decir, los pesos determinan zonas de clasificación separadas por un hiperplano (Palma Méndez & Marín Morales, 2008).

Redes multicapa

Una red neuronal artificial se utiliza para modelar la relación no lineal y complicada entre variables de entrada y salida. Esto es posible gracias a la existencia de más de una capa en la topología, aparte de las capas de entrada y salida, llamadas capas ocultas, las cuales se pueden observar en la figura 10 (Kotu & Deshpande, 2015).




Figura 10. Red neuronal multicapa

Fuente: (Villada, Muñoz, & García, 2012)

Las limitaciones de las redes de una sola capa hicieron que se planteara la necesidad de implementar redes en las que se aumentará el número de capas introduciendo capas intermedias entre la capa de entrada y la de salida, de manera que pudiera implementar cualquier función con el grado de precisión deseado. La función que cumple dicha capa intermedia es tratar de realizar una proyección en la que resulten separables linealmente los patrones de entrada de manera que la unidad de salida pueda realizar una clasificación correcta (Palma Méndez & Marín Morales, 2008).

Una capa oculta contiene una capa de nodos que conecta la entrada de capas anteriores y aplica una función de activación (Kotu & Deshpande, 2015).

Con una única capa oculta suficientemente grande, es posible representar cualquier función continua de las entradas con una precisión arbitraria; con dos capas, incluso se pueden representar funciones discontinuas (Russell & Norving, 2004).

Al proceso mediante el cual la red neuronal obtiene aprendizaje, es decir, aprende se denomina entrenamiento.

Algoritmos de entrenamiento de redes neuronales con aprendizaje no supervisado

Aprendizaje de coincidencia o heibbiano

Consiste en el ajuste de los pesos de las conexiones, de acuerdo con la correlación de los valores de activación de las dos neuronas conectadas; pretende medir la familiaridad o extraer las características de los datos de entrada (Tomas Mariano, 2011).

En el cerebro, una neurona recibe muchas entradas de un gran número de otras neuronas a través de conexiones sinápticas. La ley de Hebb afirma qué, si una neurona A es activada repetidamente por otra neurona B, entonces la neurona A será más sensible a los estímulos de la neurona B y la conexión sináptica de B a A será más eficiente. Por lo tanto, una sinapsis que conecta dos neuronas se fortalece cada vez que ambos se activan simultáneamente. Esta idea puede ser concebida como el fortalecimiento de las neuronas interconectadas (Fu, 1994).

Aprendizaje competitivo

Generalmente se puede ver como un procedimiento que aprende a agrupar patrones de entrada en clústeres de una manera inherente a los datos de entrada. En este sentido, el aprendizaje competitivo está estrechamente relacionado con la agrupación (Fu, 1994).

Si un patrón nuevo se determina que pertenece a una clase reconocida previamente, entonces la inclusión de este nuevo patrón a esta clase matizará la representación de la misma. Si el patrón de entrada se determinó que no pertenece a ninguna de las clases reconocidas anteriormente, entonces la estructura y los pesos de la red neuronal serán ajustados para reconocer la nueva clase (Ruiz & Basualdo, 2001).

Algoritmos de entrenamiento de redes neuronales con aprendizaje supervisado

Aprendizaje por corrección de errores

Consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y obtenidos en la salida de la red; es decir, en función del error contenido en la salida, tal como se muestra en la figura 11.




Figura 11. Red neuronal con aprendizaje por corrección de error

Fuente: (González Penedo, 2009)

Ejemplos de este método de aprendizaje son el perceptrón, adaline/medaline y backpropagation.

Aprendizaje por refuerzo

Consiste en presentarle a la red un conjunto de patrones de entrada y se le indica a la red si la salida obtenida es o no correcta. Sin embargo, no se le proporciona el valor de la salida esperada. Este tipo de aprendizaje es muy útil en aquellos casos en que se desconoce cuál es la salida exacta que debe proporcionar la red (Bertona, 2005).

En el aprendizaje por refuerzo la función del supervisor se reduce a indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada y en

función de ello se ajustan los pesos basándose en un mecanismo de probabilidades. Se podría decir que en este tipo de aprendizaje la función del supervisor se asemeja más a la de un crítico (que opina sobre la respuesta de la red) que a la de un maestro (que indica a la red la respuesta concreta que debe generar), como ocurría en el caso de supervisión por corrección del error (Ruiz & Basualdo, 2001).

Aprendizaje estocástico

Consiste en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad. Se suele hacer una analogía en términos termodinámicos, asociando a la red neuronal con un sólido físico que tiene cierto estado energético.

Por lo tanto, el aprendizaje consistiría en realizar un cambio aleatorio de los valores de los pesos y determinar la energía de la red (habitualmente la función energía es una función de Liapunov). Si la energía es menor después del cambio, es decir, si el comportamiento de la red se acerca al deseado, se acepta el cambio; si, por el contrario, la energía no es menor, se aceptaría el cambio en función de una determinada y preestablecida distribución de probabilidades (Ruiz & Basualdo, 2001).

Red backpropagation o de retropropagación

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.

Como la red es entrenada con diferentes ejemplos, tiene la capacidad de generalizar sobre características similares que se encuentran en diferentes patrones. La clave es que las neuronas en las capas ocultas deben ser entrenadas para extraer un conjunto suficiente de características generales aplicables tanto a los casos vistos como a los no vistos (Fu, 1994).

En la figura 12, 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 12. Red neuronal backpropagation o de retropropagación

Fuente: (Fu, 1994)

De acuerdo a la figura 12, Valencia Reyes, Yáñez Márquez y Sánchez Fernández (2006) establecen los siguientes pasos para el algoritmo *backpropagation*:

1. Inicializar los pesos de la red con valores pequeños aleatorios.
2. Presentar un patrón de entrada y especificar la salida deseada que debe generar la red.
3. Calcular la salida actual de la red. Para ello se presentan las entradas a la red y se calcula la salida de cada capa hasta llegar a la capa de salida, ésta será la salida de la red. Los pasos son los siguientes:

- a. Se calculan las entradas netas para las neuronas ocultas procedentes de las neuronas de entrada. Para una neurona j oculta:

$$net_{pj}^k = \sum_{i=1}^N w_{ji}^k x_{pi} + \theta_j^k \quad (Ec. 1)$$

en donde el índice h se refiere a magnitudes de la capa oculta; el subíndice p , al p -ésimo vector de entrenamiento, y j a la j -ésima neurona oculta. El término θ puede ser opcional, pues actúa como una entrada más.

- b. Se calculan las salidas de las neuronas ocultas:

$$y_{pj} = f_j^k(net_{pj}^k) \quad (Ec. 2)$$

- c. Se realizan los mismos cálculos para obtener las salidas de las neuronas de salida:

$$net_{pk}^o = \sum_{j=1}^L w_{kj}^o y_{pj} + \theta_k^o \quad (Ec. 3)$$

$$y_{pk} = f_k^o(net_{pk}^o) \quad (Ec. 4)$$

4. Calcular los términos de error para todas las neuronas. Si la neurona k es una neurona de la capa de salida, el valor de la delta es

$$\delta_{pk}^o = (d_{pk} - y_{pk}) f_k^{o'}(net_{pk}^o) \quad (Ec. 5)$$

La función f debe ser derivable. En general se dispone de dos formas de función de salida las cuales se indican en la tabla 12.

Tabla 12. Funciones de salida de una red de retropropagación

Nombre de la función	Definición de la función
----------------------	--------------------------

Lineal	$f_k(net_{jk}) = net_{jk}$	(Ec. 6)
Sigmoidal	$f_k(net_{jk}) = \frac{1}{1 + e^{-net_{jk}}}$	(Ec. 7)

Fuente: (Valencia Reyes, Yáñez Márquez, & Sánchez Fernández, 2006)

La selección de la función depende de la forma que se decida representar la salida: si se desea que las neuronas de salida sean binarias, se utiliza la función sigmoidal, en otros casos, la lineal; determinando el error como se expresa en la tabla 13.

Tabla 13. Derivada y términos de error de las funciones lineal y sigmoidal.

Función Lineal	Derivada	$f_k^{o'} = 1$	(Ec. 8)
	Términos de error	$\delta_{pk}^o = (d_{pk} - y_{pk})$	(Ec. 9)
Función Sigmoidal	Derivada	$f_k^{o'} = f_k^o(1 - f_k^o) = y_{pk}(1 - y_{pk})$	(Ec. 10)
	Términos de error	$\delta_{pk}^o = (d_{pk} - y_{pk})y_{pk}(1 - y_{pk})$	(Ec. 11)

Fuente: (Valencia Reyes, Yáñez Márquez, & Sánchez Fernández, 2006)

Si la neurona j no es de salida, entonces la derivada parcial del error no puede ser evaluada directamente, por tanto, se obtiene el desarrollo a partir de valores que son conocidos y otros que pueden ser evaluados. La expresión obtenida en este caso es:

$$\delta_{pj}^k = f_j^{k'}(net_{pj}^k) \sum_k \delta_{pk}^o w_{kj}^0 \quad (Ec. 12)$$

donde se observa que el error en las capas ocultas depende de todos los términos de error de la capa de salida. De aquí surge el término propagación hacia atrás.

- Actualización de los pesos: para ello se utiliza un algoritmo recursivo, comenzando por las neuronas de salida y trabajando hacia atrás hasta llegar a la capa de entrada, ajustando los pesos de la siguiente forma:
 - Para los pesos de las neuronas de la capa de salida:

$$w_{kj}^0(t+1) = w_{kj}^0(t) + \Delta w_{kj}^0(t+1) \quad (Ec. 13)$$

$$\Delta w_{kj}^o(t+1) = \alpha \delta_{pk}^o y_{pj} \quad (\text{Ec. 14})$$

- Para los pesos de las neuronas de la capa oculta:

$$w_{ji}^k(t+1) = w_{ji}^k(t) + \Delta w_{ji}^k(t+1) \quad (\text{Ec. 15})$$

$$\Delta w_{ji}^k(t+1) = \alpha \delta_{pj}^k x_{pi} \quad (\text{Ec. 16})$$

En ambos casos, para acelerar el proceso de aprendizaje se puede añadir un término momento.

6. El proceso se repite hasta que el término de error resulta aceptablemente pequeño para cada uno de los patrones aprendidos.

Algoritmo de entrenamiento Levenberg-Marquardt (LM)

Es un algoritmo conocido hace años y ampliamente utilizado en los problemas que requieren optimización. Para trabajar, el algoritmo *LM* calcula el Jacobiano del modelo en relación a los datos de entrada, y utilizando éste busca un mínimo local. El Jacobiano es necesario en cada iteración para calcular la dirección hacia el mínimo local. Para realizar un cálculo estimado del Jacobiano es necesario realizar numerosas corridas del modelo; cada corrida necesaria para la estimación es independiente de la otra, por lo que es trivialmente paralelizable.

La función para calcular el Jacobiano corre en un nodo principal que distribuye las tareas entre los nodos disponibles (que se denominan nodos esclavos), que sólo espera los parámetros con los cuales deben correr y la señal de inicio. Al recibir esta información, el nodo esclavo ejecuta el modelo con los parámetros recibidos. Luego el nodo principal espera a que cada nodo esclavo haya terminado y junta los resultados de todas las ejecuciones. Por último, realiza el cálculo devolviendo la estimación del Jacobiano (Choque Aspiazú, 2016).

El algoritmo *LM* admite la formación de vectores de validación y prueba si la propiedad *NET.divideFcn* de la red se establece en una función de división de datos.

Los vectores de validación se utilizan para detener el entrenamiento temprano si el rendimiento de la red en los vectores de validación no mejora o permanece igual para un número determinado de épocas. 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. *Levenberg-Marquardt* puede entrenar a cualquier red siempre y cuando su peso, su entrada neta y sus funciones de transferencia tengan funciones derivables.

El algoritmo *Levenberg-Marquardt* fue diseñado para acercarse a la velocidad de entrenamiento de segundo orden sin tener que calcular la matriz de Hessian. Cuando la función de rendimiento tiene la forma de una suma de cuadrados (como es típico en el entrenamiento de las redes avanzadas), entonces la matriz de Hessian se puede aproximar como:

$$H = J^T J \quad (\text{Ec. 17})$$

Y el gradiente se puede calcular como:

$$g = J^T e \quad (\text{Ec. 18})$$

Donde J es la matriz jacobiana que contiene primeras derivadas de los errores de red con respecto a los pesos y sesgos, y e es un vector de errores de red. La matriz jacobiana puede calcularse mediante una técnica estándar de retropropagación que es mucho menos compleja que calcular la matriz hessiana. El algoritmo de *Levenberg-Marquardt* usa esta aproximación a la matriz de Hessian en la siguiente actualización parecida a Newton:

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (\text{Ec. 19})$$

Cuando el escalar μ es cero, este es solo el método de Newton, usando la matriz aproximada de Hessian. Cuando μ es grande, se convierte en pendiente de

gradiente con un pequeño tamaño de paso. El método de Newton es más rápido y más preciso cerca de un mínimo de error, por lo que el objetivo es cambiar hacia el método de Newton lo más rápido posible. Por lo tanto, μ disminuye después de cada paso exitoso (reducción en la función de rendimiento) y se incrementa solo cuando un paso tentativo aumenta la función de rendimiento. De esta manera, la función de rendimiento siempre se reduce en cada iteración del algoritmo (The MathWorks, Inc., 2017).

De lo anterior es posible observar que una red neuronal requiere de una serie de patrones que representan la capa de entrada, a partir de la cual, será entrenada para lograr adquirir el conocimiento necesario y poder determinar, con un amplio grado de exactitud el comportamiento para lograr las salidas deseadas, en este caso la trayectoria escolar de los estudiantes; dicha capa de entrada está conformada por algunos elementos del Test Psicométrico Multidimensional y los datos académicos de ingreso de los estudiantes.

Marco conceptual

Test Psicométrico Multidimensional: es un instrumento que evalúa de manera integral, práctica y confiable un perfil de 160 competencias y factores de inteligencia, personalidad y valores inter-dimensionalmente para sustentar la orientación psicopedagógica y los programas institucionales de tutoría (Turborienta, 2014).

Dimensión del TPM: con cada uno de los 8 grupos de factores que integran el Test Psicométrico Multidimensional.

Factor del TPM: es el conjunto de rasgos, características o conceptos que integran cada una de las dimensiones del Test Psicométrico Multidimensional.

Trayectoria escolar: es la medición del desarrollo académico de los estudiantes de un programa educativo, se hacen en términos de aprobación, deserción, rezago, egreso y titulación (Facultad de Contaduría y Administración de la UACH, 2014).

Para efectos de esta investigación se expresa en términos de *Sin riesgo*, *Riesgo Bajo*, *Riesgo* y *Riesgo alto* con base en el desempeño y la situación escolar.

Desempeño escolar: Es el comportamiento transversal en el ciclo escolar actual, tomando en cuenta la relación del número de materias acreditadas con respecto a las cursadas durante el ciclo (Chain Revuelta & Jácome Ávila, 2007).

Situación escolar: es el comportamiento longitudinal durante el avance académico dentro de la malla curricular establecida en el plan de estudios, tomando en cuenta el número acumulado de créditos obtenidos hasta el momento, con respecto al número de créditos al que está obligado a haber acumulado de acuerdo a su cohorte generacional (Chain Revuelta & Jácome Ávila, 2007).

Índice de aprobación: relación existente de la cantidad de materias aprobadas por el estudiante durante un ciclo escolar con respecto a las cursadas en el mismo período.

Promedio escolar: es la media aritmética de las calificaciones obtenidas por un estudiante durante un ciclo escolar.

Riesgo escolar: resulta de la clasificación de la trayectoria escolar de los estudiantes, que se obtiene del cruce de la información de la clasificación del desempeño escolar con la situación escolar.

Promedio nivel medio superior: es la media aritmética de las calificaciones obtenidas por el estudiante durante sus estudios de bachillerato o equivalente.

EXANI II: Examen Nacional de Ingreso a la Educación Superior.

CENEVAL: Centro Nacional de Evaluación para la Educación Superior.

Inteligencia artificial: suele referirse a la simulación computacional de procesos cognitivos, es decir, 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 (Nilsson, 2001).

Lógica difusa: es la rama de la inteligencia artificial que trabaja con conjuntos con límites borrosos o “no muy bien definidos” (Guzmán & M. Castaño, 2015), le permite a una computadora analizar información del mundo real en una escala entre lo falso y lo verdadero, puede controlar o describir el sistema usando reglas de sentido común que se refieren a cantidades indefinidas (Ponce Cruz, 2010).

Algoritmos genéticos: es la rama de la inteligencia artificial que utiliza técnicas computacionales que 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 (Estévez Valencia, 1997).

Redes neuronales: es la rama de la inteligencia artificial que se basa aproximaciones no lineales a la forma en que funciona el cerebro, constan de un gran número de procesadores simples, llamados neuronas, ligados por conexiones con pesos (Ponce Cruz, 2010).

Aprendizaje supervisado: consiste en hacer predicciones a futuro basadas en comportamientos o características que se han visto en los datos ya almacenados (González, 2014), es decir parte del análisis de patrones ya conocidos para con base en ellos determinar los nuevos comportamientos.

Aprendizaje no supervisado: es un método de aprendizaje automático donde un modelo es ajustado a las observaciones (Flores Gutiérrez, 2013), esto es, no se

conoce ningún resultado o patrón de comportamiento, sino que la red neuronal comienza el aprendizaje de cero.

Retropropagación: aprende un mapeo desde un conjunto de patrones de entrada a un conjunto de patrones de salida, tiene la capacidad de generalizar sobre características similares que se encuentran en diferentes patrones (Fu, 1994), es decir, en la capa de salida se determina el error que existe con las salidas deseadas y este es regresado a las capas ocultas de la red para que ajuste sus pesos y ese error sea minimizado.

Entrenamiento de una red neuronal: es el proceso en el cual son introducidos datos, tanto de entradas como salidas, a la red neuronal, con la intención de que identifique los patrones de comportamiento de estas entradas para alcanzar los objetivos deseados y minimizando el error según se requiera.

Prueba de una red neuronal: es el proceso en el cual son introducidos datos, sólo los de entradas en la red, de forma que con el conocimiento adquirido ésta, determine las salidas, las cuales se comparan con las deseadas (que ya se conocen) para determinar su efectividad.

Estado del arte

Luego de una revisión de artículos de revistas publicadas por *ScienceDirect*, sitio que proporciona acceso a una amplia base de datos de revistas electrónicas de investigación científica y médica, la cual es uno de los productos de *Elsevier*, empresa de alto renombre a nivel mundial para el análisis, información y publicación de información científica, artículos publicados por la *IEEE* así como publicaciones de Universidades de distintas partes del mundo, se presenta en la tabla 14 un concentrado de varios trabajos, indicando sus principales características, para posteriormente seleccionar los más significativos y llevar a cabo un análisis más profundo, que sirvieron de base para la presente investigación. Los resultados de

estos autores son discutidos y contrastados con los obtenidos en la presente investigación en el capítulo correspondiente.

Tabla 14. Publicaciones de referencia

Nombre del Artículo	Revista, autor(es), lugar y fecha de publicación	Breve descripción del trabajo de investigación
Modelo neuro-difuso adaptativo para la predicción del rendimiento académico del estudiante	• Computadoras e Ingeniería Industrial • Osman Taylan Bahattin y Karagözog˘lu • Arabia Saudita • 5 de febrero de 2009	Este trabajo, presenta un enfoque sistemático para el diseño de un sistema de inferencia difusa basada en una clase de redes neuronales para evaluar el rendimiento académico de los estudiantes. En él, se utiliza un sistema neuro-difuso adaptivo (ANFIS) para mejorar algunas de sus características como la flexibilidad, la velocidad y la capacidad de adaptación. Dicho sistema está basado en los resultados del curso de ingeniería económica de un conjunto de estudiantes. Utilizando un algoritmo de retropropagación para realizar el entrenamiento del sistema. Las principales características de este trabajo se pueden resumir en: • Procesamiento de datos de acuerdo a mecanismos de razonamiento difuso. • Recupera el conocimiento codificado en reglas confusas y las traduce a unas más comunes. • El número deseado de reglas para representar el sistema neuro-difuso es la decisión central, la partición del espacio de entrada y los parámetros están siendo determinados automáticamente por el algoritmo de aprendizaje. • Aprende reglas que cubren todo el espacio de entrada y tiene un carácter de aproximación universal. • Procesa los datos y automáticamente determina los rangos de las funciones. Entre las conclusiones más significativas se encuentran que la evaluación de los logros de los estudiantes en el año anterior para evaluar el proceso de aprendizaje y el desempeño, podría ser más significativo que referir las calificaciones de manera individual (Taylan & Karagözoglu, 2019).
Mejorando la expresividad de los modelos de caja negra para predecir el rendimiento del estudiante	• Las computadoras en el comportamiento humano • J. Carlos Villagra Arnedo, Francisco J. Gallego Durán, Faraon Llorens Largo, Patricia Compañ Rosique, Rosana Satorre	En esta investigación, los autores consideran que mejorar el desempeño de los estudiantes, conocer su progreso real y tratar de predecir sus resultados en las primeras etapas del proceso de aprendizaje puede ser extremadamente importante para detectar de manera temprana y cortar los problemas académicos de raíz. En este trabajo, se propone el uso de técnicas de caja negra para aprovechar el poder y la versatilidad de estos métodos, al tiempo que toma algunas decisiones sobre el diseño del sistema que permite una interpretación más rica. Específicamente, se usa el diseño y la contención de un

	Cuerda, Rafael Molina Carmona • Alicante, España • 9 de septiembre de 2016	modelo de predicción basado en una máquina vectorial de soporte (SVM). La SVM permite tomar algunas decisiones acerca de los datos de entrada y el diseño de la clasificación que proporcionan un amplio conjunto de datos de salida. Para lograr lo anterior, se consideran una lista específica de eventos que se producen durante la interacción entre los estudiantes y el sistema, mismos que se registran en una base de datos con su marca de tiempo. La función del modelo predictivo es hacer predicciones de niveles de los estudiantes al final del curso, con base en los datos recogidos de la web interactiva. Estos datos, seleccionados y organizados en características, se normalizan y son proporcionados como datos de entrada a un algoritmo de aprendizaje automático. El sistema predictivo clasifica el desempeño esperado de los estudiantes es tres categorías: alto, mediano y bajo. El hecho de utilizar un modelo de predicción probabilístico multiclase, proporciona información mucho más rica acerca del desempeño de los estudiantes, que se puede utilizar para guiar y mejorar su proceso de aprendizaje. En conclusión, en este artículo, se ha diseñado un modelo de predicción de rendimiento de los estudiantes, proponiendo un conjunto de características que hacen que el sistema puede ser útil para guiar el proceso de aprendizaje de los alumnos (Villagrà Arendo, y otros, 2016).
Evaluación de la efectividad de las técnicas de <i>data minig</i> para la predicción temprana del fracaso académico de los estudiantes en cursos de Introducción a la Programación	• Computers in human beahavior • Evandro B. Costa, Balduino Fonseca, Marcelo Almeida Santana, Fabrísia Ferreira de Araújo, Joilson Rego • Brasil • 4 de febrero de 2017	En este trabajo, se busca dar solución a un problema considerado por los autores como relevante, el cual es la capacidad de predecir con exactitud y de manera oportuna los alumnos que probablemente reprobán los cursos introductorios de programación. Esto con la finalidad de llevar a cabo intervenciones pedagógicas que eviten un rezago o reprobación en los estudiantes. El objetivo principal de esta investigación, es evaluar la efectividad de técnicas de minería de datos en la educación para predecir el desempeño de los estudiantes. Para lograrlo, presentan un comparativo de los resultados de la efectividad de 4 técnicas utilizadas: Naive Bayes, árboles de decisión, redes neuronales y máquina vectorial de soporte. Los resultados del estudio permiten concluir que las 4 técnicas de <i>minería de datos</i> utilizadas en la educación, son lo suficientemente eficaces para detectar a tiempo las fallas o desviaciones académicas de los estudiantes, y partiendo de ahí proporcionar a los maestros información relevante para la toma de decisiones (Costa, Fonseca, Almeida Santana, Ferrera de Araújo, & Rego, 2017).
Predicción del desempeño y trayectoria académica como	• Learning and Individual Differences	En este trabajo de investigación se busca predecir el nivel académico en secundaria y su crecimiento a lo largo de un año escolar en una muestra de 145 estudiantes. Para realizarlo, se investiga la serie <i>Aurora</i>, una evaluación

una medida de inteligencia exitosa	• Samuel D. Mandelman, Baptiste Bardot, Elena L. Grigorenko • Estados Unidos • 10 de febrero de 2015	basada en la teoría de la inteligencia exitosa de Robert J. Sternberg, compuesta de habilidades cognitivas analíticas, creativas y prácticas. Los estudiantes a los que se les aplicó la evaluación <i>Aurora</i> fueron en total 145, 69 mujeres, 76 hombres los cuales se encontraban cursando los grados de 4º, 5º y 6º y fue utilizado para evaluar las habilidades cognitivas de los estudiantes (analítica, creativa y práctica). El modelado de curva de crecimiento latente seleccionado fue individualmente extendido en un modelo estructural en el que la intercepción y la pendiente fueron predichos simultáneamente por el rendimiento general de <i>Aurora</i>. Los análisis a nivel de las habilidades individuales medidas por <i>Aurora</i> indicaron una contribución diferente a cada habilidad en la predicción de la interceptación del promedio de las calificaciones, y sugirieron que las habilidades prácticas, en lugar de las capacidades analíticas, eran los mejores predictores. Con la implementación de este método, los autores pudieron predecir una cantidad sustancial (35%) de exceso de rendimiento académico un año después de su implementación. Específicamente, la capacidad de <i>Aurora</i> para predecir el rendimiento académico difería enormemente dependiendo de la materia de que se trataba, desde exponer casi ninguna variación en las calificaciones de nivel básico de ciencias, hasta ser altamente predictivo en Inglés, con un 46.2% de varianza (Mandelman, Barbot, & Grigorenko, 2015).
Modelo computacional de lógica difusa para la evaluación del desempeño de universidades sudanesas y personal académico	• Ciencias de la Computación y la Información • Mohamed Khalid Yousif, Adnan Shaout • Estados Unidos • 25 de agosto de 2016	Los autores de este trabajo, presentan un modelo computacional de lógica difusa basado en una encuesta para medir y clasificar el desempeño de las universidades y personal académico sudaneses, consistente en todos los pasos requeridos tales como control de consistencia, agregación, aproximación y clasificación final. Incluye el cálculo de los pesos de los criterios y la evaluación general de las universidades y el personal académico sudaneses usando técnicas de proceso analítico jerárquico y técnicas para la preferencia de orden por similitud con la solución ideal (AHP y TOPSIS respectivamente por sus siglas en inglés). Se incorporaron un conjunto adecuado de criterios de evaluación de las universidades y el personal académico en las comparaciones por parejas y encuestas de evaluación. Se identificaron, consideraron y ponderaron como criterio de evaluación de desempeño para los institutos académicos de alto nivel sudaneses nueve criterios principales y cuarenta y un sub criterios. Además, se identificaron, consideraron y ponderaron los niveles de los criterios de evaluación del personal académico. El primer nivel consta de seis criterios, el segundo nivel consta de veintisiete criterios y el último nivel consta de cincuenta criterios. El nuevo algoritmo propone un valor lingüístico de preferencia constante como una opción para los expertos

		en caso de inconsistencia en el desempeño de la evaluación. Basado en el algoritmo propuesto, la investigación introduce nuevas herramientas que permiten a los expertos rastrear y comprender las raíces de la inconsistencia y seleccionar las opciones consistentes relevantes (Khalid Yousif & Shaout, 2016).
Modelo de predicción del desempeño académico del estudiante usando un árbol de decisión y un algoritmo genético difuso	• Procedia Technology • Hashmia Hamsa, Simi Indiradevi y Jubilant J. Kizhakkethottam • India • 22 de abril de 2016	El objetivo de esta investigación, es desarrollar un modelo de predicción del desempeño académico de los estudiantes de licenciatura y maestría en ciencias de la computación y la electrónica y flujos de comunicación utilizando dos métodos de clasificación seleccionados: árbol de decisión y algoritmos genéticos difusos. Utiliza parámetros como notas internas, de sesión y puntuación de admisión para realizar este trabajo. Según lo expuesto por los autores, con árboles de decisión, se siguen las decisiones estrictas predefinidas, por lo que los estudiantes ubicados en el límite de la situación de éxito se identifican como en riesgo. En el punto de vista de los profesores, los estudiantes de nivel medio también estarán bajo el cuidado de expertos. Así que en los exámenes finales, se puede esperar un buen resultado. Con algoritmos genéticos difusos, un estudiante con una puntuación baja en algunos atributos, tienen la oportunidad de estar a salvo debido a la alta puntuación obtenida de otros atributos. Los resultados del algoritmo del árbol de decisión hicieron que más estudiantes fueran ubicados en la clase de riesgo, lo que ocasiona que los profesores tomen una decisión de tomar más cuidado para esos estudiantes (Hamsa, Indiradevi, & Kizhakkethottam, 2016).
Hacia la integración de múltiples clasificadores pertenecientes a la predicción del desempeño del estudiante	• Recent trends in Engineering and Material Sciences • Mrinal Pandey y S. Taruna. • India • 27 de abril de 2016	En este trabajo, para construir el modelo, se usaron como clasificadores base tres algoritmos, k-vecinos más cercanos, Bayes y árbol de decisión. Los autores señalan que el clasificador de árbol de decisión se selecciona debido a su mejor representación visual, mientras que el clasificador k-vecinos más cercanos se selecciona debido a su mejor rendimiento para conjuntos de datos de gran tamaño. Por otro lado, el algoritmo de Bayes supera la limitación del problema de sobreajuste de árbol de decisión, ya que es un clasificador lineal y también presenta menos probabilidades de sufrir de un sobreajuste en caso de grandes conjuntos de datos. El modelo integrado fue construido y probado en base a tres conjuntos de datos de los estudiantes y los resultados se reflejan como un comportamiento consistente y exacto en el desempeño (Pandey & Taruna, 2016).
Rendimiento académico del estudiante utilizando la Inteligencia Artificial	• ZANCO Journal of Pure and Applied Sciences • Tarik A. Rashid y Nian Kh. Aziz • Erbil, Irák • 6 de junio de 2016	Estos investigadores pretenden encontrar la relación entre los resultados de los estudiantes de un curso en particular y sus antecedentes sociales, los logros anteriores y los entornos académicos mediante el uso de Inteligencia Artificial. Para lograrlo, fueron recolectados datos sobre el estatus socioeconómico de los padres de los estudiantes, categoría

		de tutores, resultados académicos de procedencia, tipo de escuela de procedencia y aprendizaje de idiomas; mismos que fueron preprocesados, depurados, filtrados, normalizados y clasificados mediante la técnica de Red Neural Artificial. Para llevar a cabo el entrenamiento, se utiliza el aprendizaje supervisado porque se conoce el rendimiento del estudiante al final del curso y se ha utilizado como una salida de la red neuronal. Se concluye que los departamentos y tutores son factores muy significativos que afectan el desempeño académico. Estas dos variables tienen los pesos más significativos entre el resto de las 14 variables. El estudio muestra que los factores género, edad, nivel de estudio de los padres y promedio no tienen ningún efecto en el rendimiento académico (Rashid & Aziz, 2016).
Predicción del rendimiento anual de los estudiantes mediante redes neuronales: un estudio de caso de la Universidad de Ciencia y Tecnología Bangabandhu Sheikh Mujibur Rahman	• 2016 5th International Conference on Informatics, Electronics and Vision (ICIEV) • Fahim Sikder, Jamal Uddin y Sajal Halder • 1 de diciembre de 2016	Las principales contribuciones de esta investigación es que diseña una nueva técnica basada en una red neuronal supervisada, la cual extrae información de los datos de los estudiantes. Los resultados experimentales muestran que el rendimiento académico depende en gran medida de antecedentes familiares y los compromisos de los estudiantes con las interacciones de los medios de comunicación social. Primero se recolectan los datos de los institutos educativos. Después de recopilar los datos, se procesan previamente para la herramienta de minería de datos. Se utiliza MATLAB, herramienta con la cual se organizan los datos. Se diseña una red neuronal supervisada que entrena los datos y extrae la información mediante el algoritmo de retropropagación de <i>Levenberg-Marquardt</i>. Utiliza un conjunto de 14 factores divididos en dos partes para realizar la predicción. El estudio ha puesto de manifiesto, que el rendimiento anual de los estudiantes depende en gran medida no sólo las actividades académicas, sino también en las actividades externas, tales como, la interacción de medios de comunicación social, la condición del área de vida entre otros (Sikder, Uddin, & Halder, 2016).
Sistema inteligente para la predicción del desempeño académico basado en diferentes factores durante la adolescencia.	• Journal of information and telecommunication • Shakil Ahamed, Navid Tanzeem y Rashedur m Rahman • Estados Unidos • 17 de mayo de 2017	Esta publicación se dirige hacia el problema de la efectividad educativa. Para llevarlo a cabo, los autores analizaron a un gran número de estudiantes en diferentes distritos de Bangladesh. Se llevó a cabo un profundo preprocesamiento y balance de datos, la reducción de la dimensionalidad, la discretización y la normalización. Después de una cuidadosa consulta con los expertos pertinentes, se logra diseñar un cuestionario que contenga los atributos más relevantes en cuanto a los logros académicos de los estudiantes. La encuesta consta de 38 preguntas entre las cuales 5 son preguntas psicológicas que aumentan la probabilidad de que los estudiantes respondan sinceramente, misma que se aplicó a 423 estudiantes, entre los cuales 8 fueron excluidos del conjunto de datos debido a la falta de información.

		Se puede observar que una red neuronal artificial tiene mejor desempeño que <i>máquina vectorial de soporte</i> y <i>k-vecinos</i> más cercanos con una precisión de más del 86%. En la mayoría de los casos, la reducción de la dimensionalidad juega un papel importante en la reducción de la integridad de los datos y, a su vez, reduce las precisiones para la mayoría de los modelos, excepto en algunos casos como <i>máquina vectorial de soporte</i> sin preprocesamiento y <i>máquina vectorial de soporte</i> con SMOTEBoost cuando se usa con análisis principal de componentes (Ahamed, Tanzeem Mahmood, & Rahman, 2017).
Predicción del rendimiento académico de los estudiantes de física a través de las redes bayesianas en la unidad de cantidad de movimiento lineal.	• Escuela Superior Politécnica del Litoral • Miguel E. López Balanzátegui, Jorge Flores Herrera, Bolívar Flores Nicolalde, Francisca Flores Nicolalde • Guayaquil, Ecuador • Marzo de 2016	Con este trabajo, se pudo inferir resultados futuros del desempeño de los estudiantes y la relación de los conocimientos teóricos con la resolución de problemas en la materia de Física, presentando una investigación de probabilidades estadísticas con Redes Bayesianas, basándose en los resultados de las evaluaciones realizadas a estudiantes de Física de una universidad ecuatoriana. Se analizaron ocho redes bayesianas en total, cada una buscando la posibilidad de que sea útil a la hora de inferir resultados con ella. Una de las redes diseñadas, es una relación donde se utiliza las dos evaluaciones y el resultado de que si aprueba o no la materia. De acuerdo a los cálculos, se obtuvo la probabilidad a priori y posteriori, de todas las variables, y la probabilidad a posteriori de la variable en este caso, se toma una evidencia futura de que un alumno apruebe o repruebe la materia y se analiza relacionándola con las demás variables. Al final de la investigación, los autores concluyen que con el análisis de los datos con los que cuentan, la probabilidad de aprobar la materia da el 49%, información muy cercana a la realidad final que fue del 48%. En los resultados de esta red se observa que, si un alumno aprobó la materia, la probabilidad de conocer las preguntas conceptuales de la evaluación 2 y la evaluación 1 es respectivamente del 55% al 59%, y de resolver bien los problemas está entre el 44% y 68% (López Balanzátegui, Flores Herrera, Flores Nicolalde, & Flores Nicolalde, 2016).
Predicción del éxito académico en la carrera de Ciencias de la Computación de la universidad "Agostinho Neto"	• Referencia pedagógica • Pedro Antonio Kinsumba I, María Julia Becerra Alonso II, Rogelio Lau Fernández • Angola • 4 de julio de 2016	Esta divulgación científica presenta un análisis de los factores que influyen en el éxito académico de los estudiantes de primer año en las asignaturas Lógica de Programación y Programación Imperativa. Para realizarlo, los autores proponen modelos basados en redes neuronales que emplean los factores más significativos, en el contexto de la Universidad Agostinho Neto (UAN), para predecir el éxito académico en estudiantes de primer año. Los diversos factores que están influyendo en los bajos resultados académicos en el primer año destacan la débil preparación en el nivel medio y preuniversitario de la mayor parte de los alumnos, las peculiaridades de las regiones de origen que difieren en cultura, lengua, costumbres y actividades económicas; un cuerpo docente con poca experiencia pedagógica y limitada dedicación; un volumen

		significativo de alumnos que trabajan y reciben clases en horario nocturno (Kinsumba , Becerra Alonso, & Lau Fernández, 2016).
Modelo de predicción del desempeño final del estudiante basado en la participación a través de la programación genética interpretable: Integración del análisis del aprendizaje, minería de datos educativa y teoría	- Computers in human behavior - Wanli Xing, Riu Gou, Eva Petakovic, Sean Goggins - Brasil - Junio 2015	Esta publicación sintetiza los enfoques de análisis de aprendizaje, la minería de datos educativa y la teoría de la interacción humano - computadora para explorar el desarrollo de modelos de predicción más usables y representaciones de modelos de predicción usando datos de un entorno de resolución de problemas. Así mismo, intenta demostrar cómo la integración de la utilidad y comprensibilidad del modelo de predicción es una dirección prometedora para la investigación centrada en la automatización de los análisis en torno a los seres humanos que trabajan en sistemas computacionales. Se seleccionó el modelo de predicción programación genética el cual representa el equilibrio más óptimo entre la comprensibilidad del modelo y la precisión de la predicción. Este estudio construyó medidas en torno a la participación de los estudiantes en un curso derivado de la teoría de la actividad. Como resultado, cada estudiante puede ser representado por un conjunto de 6 dimensiones con un fondo semántico. Estos resultados cuantificados proporcionan pistas semánticas que los instructores pueden usar para investigar el rendimiento del estudiante. En este estudio se han aplicado e integrado cuatro enfoques diferentes para el modelo de predicción del desempeño estudiantil: análisis de aprendizaje, minería de datos educativa, práctica aplicada y teoría de la interacción humano - computadora. Los resultados de esta investigación muestran que el modelo basado en programación genética es interpretable y tiene una tasa de predicción optimizada en comparación con los algoritmos de modelado tradicionales. En términos de la singularidad del campo educativo, donde el juicio humano es un factor clave, se desarrolló un marco teórico para guiar la investigación y la aplicación del modelo de predicción del desempeño futuro. La medición y la selección de algoritmos y la construcción son las claves para un modelo exitoso de predicción de desempeño estudiantil (Xing, Gou, Petakovic, & Goggins, 2015).
La predicción del rendimiento académico de los estudiantes usando técnicas de minería de datos de clasificación	- Applied Mathematical Sciences - Fadhilah Ahmad, Nur Hafieza Ismail and Azwa Abdul Aziz - Kuala Terengganu, Malaysia 2 de noviembre de 2015	Con la publicación de su trabajo, los autores proponen un marco para predecir el rendimiento académico de los estudiantes de primer año de licenciatura en Ciencias de la Computación. Los datos fueron recolectados de períodos de 8 años tomados de julio 2006/2007 a julio 2013/2014 que contiene la demografía de los estudiantes, antecedentes académicos previos e información de antecedentes familiares. Tiene como objetivo hacer un análisis comparativo entre los tres algoritmos de clasificación seleccionados: árbol de decisión, Naive Bayes y basado en reglas (RB). El resultado del experimento muestra que la minería de datos basada en reglas de clasificación es el mejor modelo entre las otras técnicas al recibir el mayor valor de precisión del 71.3%. El modelo permitirá a los profesores tomar medidas tempranas para tomar acciones pertinentes y ayudar a los

		estudiantes ubicados en las categorías bajo y regular a mejorar sus resultados (Ahmad, Ismail, & Aziz, 2015).
Modelos para predecir tempranamente a estudiantes en riesgo en un curso usando calificaciones basadas en estándares	• Computers & Education • FarshidMarbouti, Heidi A.Diefes-Dux y Krishna Madhavan • Estados Unidos • 15 de septiembre de 2016	Esta investigación compara los métodos predictivos para identificar a los estudiantes en riesgo en un curso. Se eligieron seis métodos diferentes de predicción que se usan comúnmente en la minería de datos educativa para identificar a los estudiantes en riesgo: regresión logística, <i>máquina vectorial de soporte</i>, árbol de decisión, perceptrón multicapa, clasificador Naive Bayes y k-vecinos más cercanos. Para seleccionar el subconjunto de variables predictivas que están más relacionadas con el riesgo se calcula las correlaciones entre ellas. Un coeficiente de correlación de Pearson de menos de 0,3 no es una correlación alta. Por lo tanto, después de calcular los coeficientes de correlación de Pearson entre la variable predicha (es decir, pasar o fallar en el curso) y las variables predictoras, sólo se usaron los modelos con coeficientes de correlación de más de 0,3. <i>Máquina vectorial de soporte</i>, k-vecinos más cercanos y el clasificador de Naive Bayes tuvieron los mejores resultados entre los seis métodos de modelado probados (Marbouti, Diefes-Dux, & Madhavan, 2016).

Fuente: Autores citados en el texto.

Del material expuesto en la tabla 14, se observa que existen varios autores que han implementado técnicas basadas en algoritmos computacionales como árboles de decisión, algoritmos genéticos, redes neuronales, etc., de los cuales resulta conveniente para este trabajo de investigación profundizar más a detalle para algunos de ellos.

Mejorando la expresividad de los modelos de caja negra para predecir el desempeño estudiantil

El modelado de herramientas de predicción automática basadas en análisis estadístico o técnicas de aprendizaje automático es una línea de investigación interesante.

Un sistema de predicción automático es una herramienta tecnológica que, a partir de una serie de variables que se refieren al comportamiento o actividad de los estudiantes en un sistema de aprendizaje, obtiene de antemano una estimación del rendimiento final del estudiante.

Más allá de los aspectos técnicos del modelo, el enfoque en esta investigación es sobre la expresividad del sistema. Las teorías educativas modernas abogan por un entrenamiento centrado en el estudiante, con una evaluación verdaderamente formativa y no sólo una clasificación. Por lo tanto, para que un modelo de predicción sea realmente útil debería ofrecer algo más que una mera clasificación de los estudiantes al final del proceso de aprendizaje.

El objetivo de esta investigación es diseñar un poderoso modelo de predicción y aprovechar el rico catálogo de métodos de visualización de datos para mostrar el resultado del modelo y apoyar a los estudiantes y profesores en su toma de decisiones.

La función del modelo predictivo es hacer predicciones de las calificaciones de los estudiantes al final del curso, con base en un conjunto de datos recopilados en la web. Estos datos, seleccionados y organizados en características, se normalizan y se dan a un algoritmo de aprendizaje automático como entrada.

Para ello utilizan técnicas de *máquina vectorial de soporte* (SVM), las cuales suelen ser más precisas, especialmente cuando hay relaciones complejas y son más fáciles de aplicar, ya que son más generales. La interpretación de los métodos de caja negra es mucho más compleja ya que los modelos subyacentes son demasiado complejos para ser fácilmente explicados.

El sistema predictivo clasifica el desempeño esperado del estudiante (medido como un grado en porcentaje) en tres posibles rangos:

- Alto rendimiento (nivel esperado 80.5%).
- Desempeño medio (57.5% nivel esperado <80.5%).
- Bajo rendimiento (nivel esperado <57,5%).

Para ellos había un total de 400 estudiantes, sin embargo 336 fueron los que participaron en el experimento y los datos fueron obtenidos de los resultados de las calificaciones de 10 semanas.

Se obtuvieron 61 características de los estudiantes las cuales se muestran en la tabla 15, representando con ellas los datos de entrada. Para obtener esas características, el sistema trata con problemas de lógica, que consisten en la solución de laberintos de un juego llamado Pac-Man. En este juego, los estudiantes programan la inteligencia artificial como un personaje de Pac-Man, usando una base de conocimientos de Prolog. Para cada laberinto, los estudiantes deben programar un conjunto de reglas para que el personaje pueda obtener “comer todos los puntos”, esquivando los peligros.

Se realizaron dos experimentos, en el primero de ellos fueron utilizadas las 61 características y en el segundo sólo 23 de ellas.

En el segundo experimento, para seleccionar las 21 características se ha introducido un modelo de correlación lineal entre cada una y el nivel final, de modo que se han seleccionado las características más correlacionadas.

Tabla 15. Características de entrada del artículo

Característica	Valores
Número de visitas a la primera etapa	1 valor
Número de descargas de laberintos	1 valor
Número de finalizaciones por etapa	6 valores (uno por cada etapa)
Puntuación acumulada	1 valor
Puntuaciones promedio (porcentaje) por etapa	6 valores (uno por cada etapa)
Puntuación (porcentaje) por laberinto y etapa	15 valores (1 para cada laberinto de cada etapa)
Tiempo (segundos) para terminar cada etapa	6 valores (1 para cada etapa)
Tiempo (segundos) para terminar cada uno laberinto y etapa	15 valores (1 para cada laberinto de cada etapa)
Dificultades seleccionadas por laberinto y etapa	10 valores (1 para cada laberinto de cada etapa pero la primera)
Total	61 valores

Fuente: (Villagr  Arendo, y otros, 2016)

El estudio presenta algunos consejos para dise ar sistemas de predicci n significativos:

- Los clasificadores multiclase son preferibles para espacios de datos continuos.
- Es necesario seleccionar un n mero adecuado de clases dependiendo del tama o de la muestra.
- Es pertinente seleccionar l mites apropiados para las clases.
- La clasificaci n probabil stica es m s expresiva que la clasificaci n pura.
- El tiempo de implementaci n es un factor a considerar.

Se ha prestado especial atenci n al dise o de los experimentos, incluyendo aspectos tales como la definici n de los datos a recopilar, el algoritmo que se utilizar  para la clasificaci n, el n mero y el alcance de las clases, la producci n que se va a obtener, etc. Adem s, se ha propuesto un conjunto de herramientas gr ficas para proporcionar informaci n rica de varios tipos, que permiten detectar tendencias y patrones de comportamiento.

De esta investigaci n, se puede deducir que los mejores resultados son obtenidos en el experimento 1 donde todas las caracter sticas son usadas en la predicci n, aunque ambos resultados son muy similares, es el experimento 1 en el que se observa menor varianza. Los resultados son mostrados en la tabla 16 donde se expresa al porcentaje de efectividad en cada experimento durante cada semana de aplicaci n (Villagr  Arendo, y otros, 2016).

Tabla 16. Resultados de precisi n de ambos experimentos

Semana	Resultados de precisi�n con el experimento 1 (61 caracter�sticas)	Resultados de precisi�n con el experimento 2 (23 caracter�sticas)
1	0.46429	0.44345
2	0.47619	0.44643
3	0.51786	0.54464
4	0.55357	0.54762

5	0.55655	0.56350
6	0.60417	0.54464
7	0.63691	0.59524
8	0.66071	0.62798
9	0.67560	0.66964
10	0.74107	0.72619

Fuente: (Villagr  Arendo, y otros, 2016)

Hacia la integraci n de m ltiples clasificadores pertenecientes a la predicci n del desempe o del estudiante

Los autores de este art culo coinciden en que las predicciones exactas del rendimiento acad mico de los estudiantes en las primeras etapas del programa educativo, ayudan a identificar a los estudiantes d biles y permiten a la autoridad educativa tomar las acciones correctivas para evitar que deserten o bien reprueben.

En esta investigaci n se presenta un marco heterog neo basado en un clasificador m ltiple, el cual integra tres clasificadores: agregaci n de estimadores de una dependencia, k-vecinos m s cercanos y  rbol de decisi n, utilizando la metodolog a de votaci n y propone un  nico modelo compuesto. Este modelo integrado fue construido y probado contra tres conjuntos de colecciones de datos de los estudiantes y resultados reflejados como el comportamiento consistente y la precisi n de rendimiento.

Sin embargo, el modelo se ha propuesto para predecir el desempe o acad mico de los estudiantes, particularmente en la disciplina de ingenier a, pero esto tambi n puede ser aplicable para otros dominios de aplicaciones de *aprendizaje m quina* como un trabajo futuro. Tambi n se puede utilizar para el desarrollo del sistema de apoyo a la decisi n (Pandey & Taruna, 2016).

Evaluaci n de la efectividad de las t cnicas de aprendizaje m quina para la predicci n temprana del fracaso acad mico de los estudiantes en cursos de Introducci n a la Programaci n

Presenta un estudio comparativo sobre la efectividad de las t cnicas educativas de *aprendizaje m quina* para predecir tempranamente a los estudiantes que pueden

fallar en cursos de programación introductoria, basa la investigación en dos apartados:

- Investigación de la efectividad de tales técnicas para identificar a los estudiantes que fracasan en una etapa suficientemente temprana para tomar medidas para reducir la tasa.
- Análisis del impacto del preprocesamiento de datos y los algoritmos de ajuste de tareas, sobre la eficacia de las técnicas mencionadas.

Para realizarlo se utilizaron dos fuentes de datos:

- Información de estudiantes que tomaron el curso a distancia de Introducción a la Programación con datos como: edad, sexo, estado civil, ciudad, ingreso, matrícula, período, clase, semestre, campus, frecuencia de acceso de los estudiantes en el sistema, participación en el foro de discusión, archivos recibidos y vistos, el uso de las herramientas educativas proporcionadas por el sistema como blogs, glosario, quiz, wiki, mensaje, año de inscripción en el curso, estado de disciplina y desempeño de los estudiantes en las actividades y exámenes semanales.
- Información de estudiantes que tomaron el mismo curso en la modalidad presencial, en este caso los datos fueron: edad, sexo, estado civil, ciudad, ingreso, matrícula del estudiante, período, clase, semestre, campus, año de inscripción en el curso, estado en la disciplina, cantidad de ejercicio realizado por el estudiante, número de ejercicios correctos y desempeño de los estudiantes en las actividades y exámenes semanales.

El estudio se llevó a cabo mediante la realización de un estudio comparativo sobre la eficacia de cuatro técnicas de *aprendizaje máquina* (Árbol de decisión, máquina vector de soporte, red neural y el clasificador Naive Bayes). Estas técnicas fueron evaluadas en dos fuentes de datos diferentes e independientes sobre cursos.

Los resultados del estudio permiten sacar una conclusión importante, indicando que

las técnicas de *aprendizaje máquina* analizadas son lo suficientemente efectivas para identificar tempranamente los fracasos académicos de los estudiantes y, proporcionan a los docentes información relevante para ayudar a sus decisiones.

Se puede concluir que el ajuste fino de las técnicas educativas de *aprendizaje máquina* fue capaz de aumentar su eficacia cuando se aplican en los datos preprocesados de educación a distancia, pero sólo dos técnicas afinadas (Naive Bayes y *máquina vectorial de soporte*) aumentaron la eficacia cuando se aplican en los datos preprocesados en el campus. En otras palabras, las técnicas de *máquina vectorial de soporte* perfeccionadas son capaces de identificar con al menos el 92% y el 83% de efectividad que los estudiantes probablemente fracasarán cuando hayan realizado al menos el 50% y el 25% de sus cursos, ambos porcentajes para la educación a distancia y presencial, respectivamente. (Costa, Fonseca, Almeida Santana, Ferrera de Araújo, & Rego, 2017).

Rendimiento académico del estudiante utilizando Inteligencia Artificial

La población objetivo de este estudio son los estudiantes de primer año en los programas de Ingeniería Civil, Eléctrica, Mecánica, Arquitectónica, Software, Recursos Hídricos y Geología en la Universidad de Salahaddin-Erbil, Kurdistán, Irak. En la investigación participaron 500 estudiantes de seis departamentos del Colegio de Ingeniería.

La tabla 17 muestra los factores socioeconómicos, académicos y otros relacionados que se considera que tienen influencia en el rendimiento de los estudiantes universitarios y que han sido considerados en la investigación.

Tabla 17. Factores considerados para determinar el rendimiento escolar

Factor
Género
Edad
Dirección del estudiante

Nivel educativo del padre
Nivel educativo de la madre
Dirección de la escuela del nivel académico anterior
Tipo de escuela del nivel académico anterior
Idioma de la escuela del nivel académico anterior
Puntaje en el examen nacional
Puntaje en el examen nacional de ingles
Puntaje en el examen departamental de ingles
Tipo de tutor (inglés nativo, título de inglés local, título de inglés foráneo)
Resultado del curso previo
Resultado del curso posterior

Fuente: (Rashid & Aziz, 2016)

Para resolver el problema, en esta investigación se utiliza una red neuronal artificial supervisada, debido a que el desempeño de los estudiantes al final del curso es conocido. Los datos con los que se cuenta son divididos en tres categorías: el 60% de los datos para el entrenamiento de la red, el 10% para la validación y el 30% para las pruebas. Para lo cual se implementa una red neuronal con una capa oculta de 2, 3, 4 y 5 neuronas, siendo la de 4 la que presenta mejor resultado.

La salida de la red neuronal está señalada únicamente por dos valores, aprobado y reprobado. En el primer intento la red logro una efectividad global del 80.952% mientras que en el segundo intento un 83.333%. Se concluye que los factores que tienen mayor impacto en el desempeño escolar del estudiante, de los 14 que formaron parte de la entrada de la red, son el departamento y el tipo de tutor, tal como se indica en la tabla 18, que también muestra factores con un peso de cero lo cual indica que no tienen impacto en la salida de la red neuronal.

Tabla 18. *Peso de los factores en el desempeño académico de los estudiantes*

Factor	Peso
Puntaje en el examen departamental de ingles	0.262777
Tipo de tutor	0.1692
Dirección de la escuela del nivel académico anterior	0.054411
Resultado del curso previo	0.048016
Puntaje en el examen departamental de ingles	0.045399

Dirección	0.040788
Idioma de la escuela del nivel académico anterior	0.016512
Resultado posterior al curso	0.003552
Tipo de escuela del nivel académico anterior	0.000694
Edad	0
Género	0
Nivel educativo de la madre	0
Puntaje en el examen nacional	0
Nivel educativo de la padre	0

Fuente: (Rashid & Aziz, 2016)

Predicción del rendimiento anual de los estudiantes mediante redes neuronales: un estudio de caso de la Universidad de Ciencia y Tecnología Bangabandhu Sheikh Mujibur Rahman

Para llevar a cabo esta investigación se llevaron a cabo varias actividades, la primera de ellas fue realizar la recolección de datos, a continuación, los datos fueron procesados con un paquete con herramientas de minería de datos, MATLAB en este caso.

Fueron recolectados por medio de una encuesta en línea datos de 120 estudiantes, correspondientes a 14 factores dentro de los cuales no solo se considera información académica, sino también algunos datos de educación familiar, condiciones del área de residencia, interacción social, adicciones a drogas, etc., el conjunto de factores se muestran en la tabla 19.

Tabla 19. Factores considerados dentro del conjunto de datos de entrada

Factor
Calificaciones durante la clase
Rendimiento en la clase
Asistencia a clases
Medición de comprensión y formulación de ideas
Rendimiento en laboratorios
Resultados del semestre anterior
Tiempo de estudio
Nivel educativo familiar
Sector de residencia

Interacción social
Actividades extracurriculares
Adicción a las drogas
Relación con compañeros
Resultado final

Fuente: (Sikder, Uddin, & Halder, 2016)

Para implementar la red neuronal supervisada, se diseñó una red neuronal con 10 capas ocultas, empleado el algoritmo de retropropagación *Levenberg-Marquardt* de MATLAB.

La figura 13, muestra el histograma de error de la red en sus etapas de entrenamiento, validación y prueba, por lo que el rendimiento de la red es alrededor del 97%.




Figura 13. Histograma de error de la red neuronal de Skider, Uddin y Halder

Fuente: (Sikder, Uddin, & Halder, 2016)

En la tabla 20 se muestra la comparación entre el promedio académico acumulativo real de 7 estudiantes seleccionados de manera aleatoria y los obtenidos por la red neuronal, donde se observa la precisión con el valor más alto es de 99.986% mientras que la más baja del 91.547%.

Tabla 20. *Comparación de la clasificación real con los obtenidos por la red neuronal*

Estudiante	Resultado original	Resultado de la red	Porcentaje de precisión
1	2.125	2.116	99.555%
2	3	3.192	93.973%
3	3.83	3.506	91.547%
4	3.43	3.358	97.9%
5	3.535	3.604	98.064%
6	2.5	3.479	99.416%
7	2.7	2.664	99.986%

Fuente: (Sikder, Uddin, & Halder, 2016)

III. Criterios metodológicos

Enfoque

El enfoque de la investigación fue mixta ya que en algunos de los apartados el enfoque que se utilizó fue cuantitativo al asignarse valores numéricos a los indicadores utilizados con la finalidad de manejarlos estadísticamente, mientras que en otros de los apartados el enfoque que se utilizó fue cualitativo, ya que se interpretaron aspectos subjetivos desde el punto de vista del investigador.

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, sea más completo y cuente con aspectos del ciclo escolar agosto – diciembre y enero – junio, en donde las condiciones de los estudiantes son totalmente distintas.

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.

Variables e indicadores

Las variables del estudio que se evaluó fueron:

- Variables independientes
 - Resultados del Test Psicométrico Multidimensional
 - Datos académicos de ingreso de los estudiantes
- Variable dependiente
 - 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.

Metodología

Para la obtención de los datos del Test Psicológico Multidimensional, fue utilizado Lenguaje de Consulta Estructurado, SQL por sus siglas en inglés, que proporciona acceso a la información contenida en una base de datos relacional, caso de la información del Test.

La población considerada en el estudio fueron estudiantes de las Áreas Económico – Administrativas que ingresaron durante los ciclos agosto-diciembre de 2014 y enero-junio de 2015.

La unidad de análisis para la investigación fueron 922 estudiantes del Área Económico – Administrativa que ingresaron durante los ciclos agosto-diciembre de 2014 y enero-junio de 2015, que representan el 100% de los estudiantes que cuentan con información íntegra en el Test Psicométrico Multidimensional y se podía realizar un cálculo de su trayectoria escolar por contar con los datos académicos necesario (año 2016).

El tipo de muestreo fue a través de censo (muestreo total), ya que se consideraron los datos de todos los alumnos que en la base de datos cumplían con las características de la unidad de análisis.

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

IV. Resultados y discusión

Para la obtención de los datos del Test Psicológico Multidimensional, fue utilizado el Lenguaje de Consulta Estructurado, SQL por sus siglas en inglés, que proporciona acceso a la información contenida en una base de datos relacional, de donde se obtuvieron 7,376 tests de diferentes estudiantes. Se realizó la depuración de los datos del Test Psicométrico Multidimensional, de manera que no hubiera elementos con datos fuera de los rangos establecidos para cada variable y que hubiera concordancia entre los resultados de cada alumno, la base de datos original se redujo a 7,285 registros; dicha depuración se llevó a cabo con el Paquete Estadístico para Ciencias Sociales, SPSS por sus siglas en inglés.

Se calculó la trayectoria escolar de los 7,285 alumnos, sin embargo, esto fue posible solo en 5,987 casos ya que el resto de los estudiantes se habían dado de baja, no realizaron inscripción a primer semestre o no contaban aún con materias cursadas que permitieran realizar el cálculo, para ello se implementó en el Sistema Estratégico de Gestión Académica (SEGA) de la Universidad Autónoma de Chihuahua los procesos correspondientes y fueron obtenidos de nueva cuenta con el lenguaje SQL.

Posteriormente, utilizando de nueva cuenta SQL, se dividieron los 5,987 datos por área de conocimientos quedando de la siguiente manera:

- 448 para el área Agropecuaria
- 969 para el área de Ingenierías
- 922 para el área Económico – Administrativas
- 1,350 para el área de Ciencias Sociales
- 288 para el área de Humanidades
- 2,010 para el área de la Salud

Se realizó, en SPSS, un estudio estadístico con 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, cada uno de los

grupos fue formado con los factores contenidos por cada dimensión del Test Psicométrico Multidimensional.

Utilizando el paquete Microsoft Excel, se graficaron los resultados del análisis estadístico para cada una de las dimensiones. Con base en el análisis estadístico del método *k-medias*, realizado en SPSS, se determinaron los datos para elaborar redes neuronales en el área Económico - Administrativa, resultando seleccionados los de los grupos de: competencias intelectuales, competencias académicas y habilidades mentales.

Para realizar la selección de los datos de entrada se llevó a cabo una comparación entre el comportamiento de los grupos formados por cada una de las dimensiones, y aquellas en los que había más alumnos colocados del lado izquierdo de la gráfica, es decir, con los valores más bajos fueron seleccionadas como entradas de la red neuronal, esto debido a que requieren más atención y mejoramiento para un mejor desempeño escolar.

Tabla 21. *Conversión a valor numérico de la Trayectoria Escolar*

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

Fuente: Propia del autor

Una vez determinados los datos de entrada, tantos estos como las salidas, fueron configurados de manera que pudieran ser introducidos en la red neuronal; en los datos de entrada se configuró la información de manera que cada columna correspondiera a un estudiante, lo mismo para el vector de salida; en este último caso, fue necesario realizar una conversión a valor numérico de la clasificación de la trayectoria escolar, quedando como se indica en la tabla 21.

Se elaboró una red neuronal con el algoritmo *trainlm* de tres capas para los datos seleccionados para el área Económico – Administrativa de 15 neuronas por capa logrando una eficiencia del 89.2%. Los pasos anteriores se muestran de manera resumida en la figura 14.



Figura 14. Flujograma de actividades
Fuente: Propia del autor

Análisis de las dimensiones del Test Psicométrico Multidimensional

De acuerdo a la información obtenida por el Test Psicométrico Multidimensional, fue necesario analizarla 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 15.



Figura 15. Dimensiones del Test Psicométrico Multidimensional

Fuente: Propia del autor

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 se muestra la conglomeración de datos en 5 grupos, donde cada uno de ellos corresponde a las clasificaciones *bajo*, *intermedio-bajo*, *intermedio*, *intermedio-alto* y *alto*. Por lo que posterior a la generación de los grupos, se evaluó cada uno de ellos para determinar, con base en sus valores, a que categoría corresponde. Acto seguido, se determinó la cantidad de estudiantes de cada uno de estos grupos y se ubicaron del mismo modo en la categoría que les correspondía.

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.

Coefficiente Intelectual. Esta dimensión estuvo conformada por los siguientes factores:

- Coeficiente intelectual
- Inteligencia emocional
- Hemisferio izquierdo
- Hemisferio derecho
- Cerebro reptílico
- Corteza cerebral
- Cerebro límbico

La tabla 22 muestra los valores de los datos de los centroides de los factores para cada uno de los 5 grupos generados, ordenados de los valores más bajos hasta los más altos de acuerdo a las categorías previamente expuestas. Haciendo una correspondencia con las personas que están ubicadas en cada uno de los grupos se obtiene la gráfica de la figura 16.

Tabla 22. Agrupamiento de los factores que integran el coeficiente intelectual.

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 del autor

La mayor parte de los estudiantes, tienen un coeficiente intelectual *intermedio-alto*, de acuerdo a lo señalado en la figura 16, sin embargo, 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.




Figura 16. Clasificación del coeficiente intelectual de los estudiantes

Fuente: Propia del autor

Inteligencias Múltiples. Esta dimensión se integró por los siguientes factores:

- Inteligencia lingüística
- Inteligencia lógica – matemática
- Inteligencia espacial
- Inteligencia musical
- Inteligencia corporal
- Inteligencia interpersonal
- Inteligencia intrapersonal

Tabla 23. 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 del autor




Figura 17. Clasificación de las inteligencias múltiples de los estudiantes

Fuente: Propia del autor

Para el caso de las *inteligencias múltiples*, también se elaboraron 5 grupos cuyos centroides ordenados de menor a mayor se muestran en la tabla 23, de lo anterior se obtiene la gráfica de la figura 17, en donde se muestra la cantidad de estudiantes pertenecientes a cada uno de los 5 grupos.

La figura 17, resalta que, si bien la categoría con la frecuencia más alta es la de *intermedio-alto*, 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 que el coeficiente intelectual respecto al impacto que pudiera tener en la trayectoria escolar de los estudiantes.

Competencias Intelectuales. Este rubro estuvo integrado por los siguientes factores:

- Percepción
- Análisis
- Síntesis
- Razonamiento abstracto
- Comprensión
- Aprendizaje
- Memoria
- Adaptabilidad
- Creatividad
- Adaptación
- Persuasión
- Planeación y toma de decisiones
- Velocidad intelectual

Previo a realizar el análisis, es importante recordar que el modelo educativo de la Universidad Autónoma de Chihuahua, está basado en el desarrollo en competencias y centrado en el aprendizaje, así mismo, los planes de estudio contemplan el desarrollo de algunas competencias contenidas en esta dimensión y

algunas de ellas representan habilidades que cualquier profesionista debe trabajar y mejorar para un buen desempeño profesional.

Tabla 24. *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
Compresión	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 del autor

En este caso, hubo mayor complejidad a la hora de obtener el orden de cada uno de los 5 grupos generados, y esto se debe a que los valores tienden a estar un poco menos dispersos, finalmente se determina que el orden de los centroides establecido en la tabla 24 es el más adecuado y preciso, gráficamente la distribución de los estudiantes se observa en la figura 18.

Para las *competencias intelectuales*, la propensión de los estudiantes apunta a un nivel *intermedio-bajo*, que es la categoría con mayor frecuencia, inclusive un simple vistazo a la gráfica de la figura 18, resalta una tendencia hacia el lado izquierdo, inclusive los estudiantes ubicados en nivel *bajo* supera a los ubicados en nivel *alto*; lo anterior se conjugó con el hecho de que estas competencias son básicas para un desempeño exitoso en los estudios, por lo que esta dimensión resulta amenazante en la trayectoria escolar.




Figura 18. Clasificación de las competencias intelectuales de los estudiantes

Fuente: Propia del autor

Programación Mental. Esta dimensión estuvo integrada por los siguientes factores:

- Mentalidad propositiva (optimista)
- Auto-programación subconsciente
- Sinergia emocional-intelectual
- Aprovechamiento de su capacidad de mentalización
- Capacidad de automotivación

Tabla 25. 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 del autor

Para el caso de los centroides de cada grupo generados para la *programación mental*, el ordenamiento es más simple, y es que, tal como se muestra en la tabla 25, los valores permiten identificar a simple vista la ubicación de cada uno de los

grupos. En la figura 19 se desglosan la cantidad de alumnos que integran cada uno de ellos.




Figura 19. Clasificación de la programación mental de los estudiantes

Fuente: Propia del autor

Observando la información presentada en la figura 19 es posible determinar simplemente que la mayor parte de los alumnos están ubicados en las categorías de *intermedio*, *intermedio-alto* y *alto*, con una diferencia muy considerable al respecto de los que se encuentran ubicados en *bajo* e *intermedio-bajo*; por lo que esta dimensión no representa un riesgo para los estudiantes.

Mapa Académico. Se encuentra integrado por los siguientes factores:

- Aptitud académica
- Actitud académica
- Dinámica interpersonal
- Disposición a la autoridad
- Interrelación con los maestros
- Interrelación con los compañeros

Al momento de generar 5 grupos con el método de *k-medias* de SPSS, se obtiene la información de la tabla 26, donde se puede notar que los grupos *bajo*, *intermedio-alto* y *alto* son claramente identificables, en el caso de *intermedio-bajo* e *intermedio* puede haber más duda en el orden debido a que los datos están más homogéneos sin embargo después del análisis se decide colocarlos en la posición que indica la tabla 26.

Tabla 26. 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 del autor

De dicha información se obtienen los datos presentados en la gráfica de la figura 20.

Al igual que en la *programación mental* mostrada en la gráfica de la figura 19, en el caso del mapa académico es notable una tendencia de la información hacia el lado derecho (figura 20), 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.




Figura 20. Clasificación del mapa académico de los estudiantes

Fuente: Propia del autor

Competencias Académicas. Aquí se encuentran otras tantas de las competencias que los planes de estudio de la Universidad Autónoma de Chihuahua y en particular del Área Económico-Administrativa pretende desarrollar en sus estudiantes:

- Inclínación hacia el trabajo bien hecho
- Hábito de estudio
- Liderazgo positivo
- Trabajo en equipo
- Responsabilidad
- Adaptabilidad
- Liderazgo negativo

Para el caso de las *competencias académicas* establecidas en la tabla 27, el orden de acuerdo a los valores por grupo presenta un comportamiento distinto en *liderazgo negativo* que en el resto de los rasgos, sin embargo al analizar a todos ellos en conjunto se determina el orden establecido, por lo que la gráfica correspondiente (figura 21), 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 la *intermedio*, situación que no es tan deseable.

Tabla 27. 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 del autor

Lo anterior aunado al modelo educativo de la Universidad donde la base son las competencias, conllevar a prestar especial atención a esta dimensión.




Figura 21. Clasificación de las competencias académicas de los estudiantes

Fuente: Propia del autor

Habilidades Mentales. El Test Psicométrico Multidimensional, genera en sus resultados un valor para las siguientes *habilidades mentales*:

- Razonamiento numérico
- Razonamiento verbal
- Razonamiento abstracto
- Razonamiento concreto
- Razonamiento lógico
- Razonamiento espacial
- Memoria
- Creatividad
- Lectura
- Concentración
- Comprensión
- Síntesis

Tabla 28. 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 del autor

En los 5 grupos generados para el análisis, expuestos en la tabla 28, se identifica que los grupos *intermedio* e *intermedio-alto* pueden parecer muy homogéneos, sin embargo de acuerdo a los valores en conjunto, los rasgos analizados y las frecuencias de cada grupo se determina el orden presentado como el más adecuado, de ahí, graficando las frecuencias de estudiantes de cada grupo (figura 22) 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 de la gráfica de la figura 22.




Figura 22. Clasificación de las habilidades mentales de los estudiantes

Fuente: Propia del autor

Estilos de Aprendizaje. Esta dimensión del Test Psicométrico Multidimensional corresponde a los siguientes factores:

- Teórico
- Experimental
- Kinestésico
- Auditivo
- Visual
- Memorizado
- Comprendido
- Concreto

- Abstracto
- Espontaneo
- Sistemático
- Textual
- Imágenes

Para esta dimensión, no fue posible la generación de cinco grupos por el método de *k-medias*, esto debido a que la mayor cantidad de la información se encuentra muy cerca de la media, por lo que se optó por generar únicamente tres grupos según la tabla 29, en los cuales, aunque es posible determinar cual corresponde al nivel *alto*, *intermedio* y *bajo*, la información sigue siendo muy uniforme.

La tabla 29 muestra los valores de los tres grupos para cada uno de los *estilos de aprendizaje*; al no haber mucha diferencia entre los valores, se considera que existe una uniformidad en los datos, aunque se pueden ubicar los estudiantes en cada uno de los grupos de acuerdo a la gráfica de la figura 23, no existe mucha diferencia entre los estudiantes de un grupo y otro, por lo que esta dimensión no tiene impacto en la trayectoria escolar de los estudiantes.

Tabla 29. 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 del autor




Figura 23. Clasificación del desarrollo de los estilos de aprendizaje de los estudiantes

Fuente: Propia del autor

Análisis de la situación de ingreso de los estudiantes del área económico-administrativa

Derivado del análisis que se llevó a cabo con las dimensiones y factores del Test Psicométrico Multidimensional, fue necesario realizar el mismo proceso con los datos académicos de ingreso de los estudiantes, aún y cuando esta información se integra como entrada a la red neuronal por defecto, fue interesante conocer cómo se encuentran distribuidos los alumnos en estos rubros.

Los datos académicos de ingreso de los estudiantes, tal como se mencionó con anterioridad están integrados por los resultados del Examen Nacional de Ingreso a la Educación Superior EXANI II del CENEVAL o bien el módulo introductorio de la Universidad Autónoma de Chihuahua 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.

Para clasificar los datos académicos de ingreso se realizaron cinco grupos según lo indica la tabla 30, el grupo que resultó clasificado como *bajo*, se debe a que, aunque el promedio del nivel medio superior es mayor al grupo *intermedio-bajo*, se le dio un

peso superior a la evaluación de ingreso debido a que ésta es la misma para todos los estudiantes, misma situación que ocurre con el grupo intermedio.

Tabla 30. 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 del autor

De lo anterior, la gráfica de la figura 24 muestra la frecuencia de estudiantes ubicados en las categorías determinadas por los grupos de la tabla 30.




Figura 24. Clasificación de los datos académicos de ingreso de los estudiantes

Fuente: Propia del autor

En la figura 24 se denota 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.

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 25 muestra la información en donde no fué incluida la dimensión *estilos de aprendizaje* por estar la distribución muy uniforme y dividida únicamente en tres grupos, cuando para el resto de las dimensiones se utilizaron cinco.




Figura 25. Comparativo de la frecuencia por grupo de las principales dimensiones del TPM

Fuente: Propia del autor

Para seleccionar los datos de entrada de la red, fue conveniente realizar un análisis tanto a la información de la figura 25, como al Modelo Educativo de la Universidad Autónoma de Chihuahua, en primera instancia, tanto *competencias académicas* como *competencias intelectuales* tienen un comportamiento preocupante, al tener muchos alumnos clasificados como *bajo* e *intermedio-bajo*, así mismo, conjugándolo con el principio de que el modelo educativo bajo el cual operan los planes de estudio del área Económico-Administrativa es el basado en competencias

y centrado en el aprendizaje, estas dos dimensiones serían las primeras seleccionadas para formar parte de la entrada de la red neuronal.

En segundo termino y revisando nuevamente la figura 25, se apreció que tanto el *coeficiente intelectual*, *mapa académico* y la *programación mental* tuvieron un comportamiento positivo, esto es, pocos alumnos ubicados en la parte izquierda de la gráfica, por lo que se deduce que la mayor parte de los estudiantes no tienen problema con estas dimensiones y lejos de perjudicarles, les benefician por sus buenos resultados en ellas, por lo que las 3 dimesiones quedan descartadas para formar parte de la entreda de la red.

Para finalizar quedaron dos dimensiones pendientes: *inteligencias multiples* y *habilidades mentales*, ambas podrían ser incluidas como entrada de la red, sin embargo, dado que cada una de ellas tiene varios factores que la integran, fue conveniente seleccionar sólo una, 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.

Con base en lo anterior, se optó por seleccionar *habilidades mentales*, esto debido a que, para estas dos dimensiones, es la que cuenta con menor número de estudiantes clasificados como *intermedio-alto* y *alto*, es decir, son menos los estudiantes que no se verían afectados por la factores de esta dimensión que en el caso de *inteligencias múltiples*, la cual queda descartada como datos de entrada para la red neuronal.

Por otro lado, la información académica de ingreso fue el primer y único parámetro de este tipo con el que se cuenta al momento en el que los estudiantes se integran a la Universidad, por lo que también formó parte de los datos de entrada de la red.

Así pues, las dimensiones con sus factores seleccionados para ser la entrada de la red son las enlistadas en la tabla 31.

Tabla 31. Dimensiones y factores seleccionados con datos de entrada de la red neuronal.

Competencias Intelectuales	Competencias Académicas	Habilidades Mentales	Datos Académicos de Ingreso
Percepción Análisis Síntesis Razonamiento Abstracto Comprensión Aprendizaje Memoria Adaptabilidad Creatividad Adaptación Persuasión Planeación y toma de decisiones Velocidad intelectual	Inclinación hacia el trabajo bien hecho Hábito de estudio Liderazgo positivo Trabajo en equipo Responsabilidad Adaptabilidad Liderazgo Negativo	Razonamiento numérico Razonamiento verbal Razonamiento abstracto Razonamiento concreto Razonamiento lógico Razonamiento espacial Memoria Creatividad Lectura Concentración Comprensión Síntesis	Evaluación de ingreso Promedio del nivel medio superior Promedio del primer ciclo escolar Índice de aprobación del primer ciclo escolar

Fuente: Propia del autor

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 26, indica la distribución del desempeño y la situación escolar de los estudiantes. Para el caso del *Desempeño Escolar* se encuentra que es donde hay más problema, ya que el 26% de los estudiantes se encuentran como 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.




Figura 26. Indicadores que integran la Trayectoria Escolar

Fuente: Propia del autor

Al conjuntar ambas gráficas de la figura 26, da como resultado la trayectoria escolar de los estudiantes, ubicándolos en alguna de las categorías indicadas en la figura 27, donde el 40% de los estudiantes presentan algún grado de riesgo.




Figura 27. Clasificación de la Trayectoria Escolar

Fuente: Propia del autor

Tal y como se señaló anteriormente, los datos de la clasificación de la trayectoria escolar representan los datos de salida de la red neuronal, clasificados numéricamente de acuerdo a la tabla 32.

Tabla 32. 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 del autor

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, y aunque requiere más memoria que otros, es altamente recomendable. 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 28 muestra mediante una imagen la arquitectura de la red neuronal, indicando la cantidad de entradas, salidas, capas ocultas, número de neuronas por capas e inclusive la función de activación en cada una de las capas.




Figura 28. Red neuronal de 3 capas ocultas de 15 neuronas por capa

Fuente: Propia del autor

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 se muestran en la tabla 31 y las cuales están representadas como *input* en la figura 28 y generando 4 salidas posibles tal como se indica en la tabla 32 y representadas como *output* en la figura 28; esto es posible gracias al siguiente código:



- 1) `net = patternnet([15, 15, 15], 'trainlm');`
- 2) `T = ind2vec(target);`
- 3) `targets = full(T);`
- 4) `net = train(net,x,targets);`
- 5) `y = net(x)`

La instrucción número 1 crea la red neuronal, indicándose el tipo (*patternnet* en este caso) y recibiendo por parámetros, primero el número de capas ocultas, así como la cantidad de neuronas contenidas en cada una de ellas y el algoritmo utilizado para el entrenamiento.

La instrucción 2 y 3 son utilizada para darle el formato correcto a las salidas (*targets*) de la red, en primer lugar es necesario convertirla en un vector, es decir, un solo renglón con las salidas para cada uno de los casos y, enseguida, completar esas salidas en tantos renglones como opciones posibles existan, en este caso fueron 4 (*riesgo alto*, *riesgo*, *riesgo bajo* y *sin riesgo*), los estudiantes con *riesgo alto* tendrán el valor 1 en el primer renglón y 0 en los otros 3, los de *riesgo* en el segundo renglón y así sucesivamente. Posteriormente, en la instrucción 4 se entrena la red para finalmente almacenar la salida en otra variable como lo indica la instrucción 5.

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 de entrenamiento. 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). Así mismo, 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 29, muestra la gráfica en la cual 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.




Figura 29. Desempeño del entrenamiento de la red neuronal

Fuente: Propia del autor

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 29, posterior a ello se observa que tanto en

validación como en pruebas el error comienza a no mostrar mejoría hasta la época 6 (6 épocas después) es en esta en donde se detienen el entrenamiento de la red.

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 30 muestra dicha información, en donde es notable 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 30. 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 31 presenta la matriz de confusión de la red neuronal en cuestión. 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 31. Matriz de confusión

Fuente: Propia del autor

En esta clasificación, la figura 31, muestra en el entrenamiento muestra que el 89.5% de los datos utilizados para esta fase, 646 de los 910 que representan el 70% del total, se encuentran clasificados de manera correcta. Para el caso de la validación, en donde se utilizaron 138 de los 910 datos, esto es el 15%, el 87% se

encuentran clasificados en la posición que les corresponde, mientras que, para la fase de pruebas, que de la misma forma se utilizaron 138 de los 910 datos, esto es el 15%, el 89.9% fueron ubicados en la categoría correcta. De manera general, el apartado del comportamiento global de la red de la figura 31 presenta de manera integrada 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, esto es, el elemento ubicado en la celda del renglón 1 y columna 4, 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 31 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.

Se podría hablar de cierta similitud con los trabajos presentados en la sección de Estado del Arte, los cuales representan una base importante para desarrollar la presente investigación, sin embargo, la semejanza es que la gran mayoría de ellos buscan tener la capacidad de predecir el desempeño académico del estudiante utilizando técnicas de inteligencia artificial, pero desde el método, los datos de entrada, el mecanismo de predicción utilizado, los parámetros de salida y el segmento de aplicación son totalmente distintos.

A continuación, se presenta una discusión de las diferencias de este trabajo de investigación con otros, los cuales representan un sustento para la esta investigación, sin embargo, se considera prudente hacer algunos señalamientos de semejanzas y diferencias.

En primer lugar, todos los autores estudiados buscan de alguna manera conseguir predecir la trayectoria escolar de los estudiantes con base a diversas

características, algunos de ellos sobre un tema específico, tal es el caso de los autores Costa, Fonseca, Almeida Santana, Ferrera de Araújo y Rego (2017), basan su estudio en la predicción escolar en el curso de Introducción a la Programación. Es importante señalar que el término trayectoria escolar, para efectos de la investigación, es sinónimo de comportamiento académico, resultado escolar, etc., términos utilizados por diversos autores.

En cada una de las publicaciones los datos de entrada que sirven como base para el modelo son distintos, esto independientemente de cuál sea el mecanismo seleccionado para llevar a cabo la predicción, Villagrà Arredondo, Gallego Durán, Llornes Largo, Compañ Rosique, Satorre Cuerda y Molina Carmona (2016) utilizan 61 características de lógica obtenidas de la solución de laberintos de un juego denominado Pac-Man. Costa, Fonseca, Almeida Santana, Ferrera de Araújo y Rego (2017) al igual Rashid y Aziz (2016) emplean datos muy generales tanto académicos como personales, los cuales se describen en la sección correspondiente. En ninguno de los casos se evidencia una selección de datos de entrada de aspectos de impacto, sino que se utilizan todos los datos con los que cuentan. Villagrà Arredondo, Gallego Durán, Llornes Largo, Compañ Rosique, Satorre Cuerda y Molina Carmona (2016) realizan un segundo experimento con 23 de las 61 características obteniendo menor efectividad.

Otro aspecto en el cual los autores difieren es en la técnica utilizada para desarrollar el modelo predictivo. Si bien todos ellos recurren a técnicas de aprendizaje máquina, en lo particular, difieren de unos trabajos a otros: Villagrà Arredondo, Gallego Durán, Llornes Largo, Compañ Rosique, Satorre Cuerda y Molina Carmona (2016) emplean una máquina vectorial de soporte, Padey y Taruna (2016) manejan 3 mecanismos: agregación de estimadores de una dependencia, k-vecinos más cercanos y árbol de decisión y Costa, Fonseca, Almeida Santana, Ferrera de Araújo y Rego (2017) emplean dos técnicas: Bayes y máquina vectorial de soporte.

De la literatura revisada, existen dos trabajos muy significativos por la semejanza que presentan con el actual trabajo de investigación debido a que ambos utilizan redes neuronales para lograr la predicción del rendimiento escolar, ellos son Rashid y Aziz (2016) y Sikder, Uddin y Halder (2016). Por lo anterior es conveniente mencionar las diferencias a un nivel de mayor profundidad que presentan con esta tesis.

En la publicación realizada por Rashid y Aziz (2016) se implementó una red neuronal con una capa oculta formada por 4 neuronas, empleando la siguiente división de los datos de entrada para las fases de construcción de la red, 60% para el entrenamiento, 10% para la validación y 30% para las pruebas. Sikder, Uddin y Halder (2016) diseñaron una red neuronal de 10 capas entrenada con el mismo algoritmo que el que emplea la red neuronal del presente trabajo (Levenberg-Marquardt) ocultas sin indicar en su publicación los porcentajes de los datos utilizados para las fases de construcción de la red; en la presente tesis se utilizaron 3 capas ocultas de 15 neuronas cada una dividiendo los datos de la siguiente manera: utiliza el 70% para el entrenamiento, 15% para la validación y 15% para las pruebas. Al respecto es preciso comentar que no es que una sea mejor que la otra, esto depende de las características de los datos de entrada con los que se cuente.

Sólo dos de los trabajos describen a manera de detalle los datos salidas del modelo, Villagrà Arredondo, Gallego Durán, Llornes Largo, Compañ Rosique, Satorre Cuerda y Molina Carmona (2016) usan tres categorías: rendimiento alto, medio y bajo. Rashid y Aziz (2016) utilizan dos: aprobado y reprobado. Para el segundo caso es evidente que estudiantes se encuentran ubicados en ellas, pero para el primero no se describe que se considera cada una de las categorías.

Por último, los dos trabajos descritos previamente obtienen distintos niveles de efectividad: Rashid y Aziz (2016) logran un 83.333% en este rubro y Sikder, Uddin y Halder (2016) un 97%, sin embargo ninguno de ellos muestran una matriz de confusión que asegure que la red no está generalizando los datos.



V. Conclusiones y recomendaciones

Conclusiones

En este punto de la investigación es pertinente realizar un contraste de las hipótesis tanto general como específicas que fueron planteadas como solución al problema de investigación con el análisis de resultados para determinar la aceptación o rechazo de las mismas.

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* permitió agrupar los valores de los factores por cada dimensión mostrando información clara y confiable de aquellas, en las cuales es necesario prestar más atención. Los resultados permitieron verificar cuales aspectos están catalogados como deficientes para una mayor cantidad de alumnos y que, por tanto, representan una amenaza de mayor índice de deserción escolar; estos datos conforman la entrada a la red neuronal. Se seleccionaron 3 de las 8 dimensiones que integran el Test Psicométrico Multidimensional.

El análisis estadístico por sí solo provee una gran cantidad de información que resultó muy útil para determinar acciones preventivas con los estudiantes, ya que permitió identificar los principales rasgos que requieren trabajar los alumnos para mejorar su desempeño académico; al conocer esta categorización, la actividad tutorial puede ser fortalecida de una manera muy positiva.

La segunda hipótesis específica que señala que una red neuronal de retropropagación diseñada y entrenada con base en los datos de entrada y salida previamente establecidas logrará una efectividad mínima del 85% en el entrenamiento, la cual también se acepta; al respecto se diseñaron varias redes neuronales tanto de una como de dos y 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 que los pesos de la red neuronal pudieron ser ajustados con los datos de entrada proporcionados para lograr generar los datos de salida correctos con un porcentaje de exactitud en los casos mayor al porcentaje establecido en la hipótesis.

Lo anterior, conlleva a analizar la tercera hipótesis específica que menciona 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, también 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 solo 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 recibir como datos de entrada estos nuevos parámetros.
- Resulta muy conveniente realizar un manual de seguimiento que permita, con base en los datos de entrada tomar acciones claramente documentadas y específicas para ayudar al mejoramiento de la trayectoria escolar de aquellos estudiantes que hayan sido clasificados por la red como una situación de riesgo, de manera que no exista duda alguna de cómo actuar en distintos escenarios.
- No contar con los datos de entrada señalados en esta investigación no significa que la técnica aquí empleada no pueda ser utilizada para un trabajo similar; el reto consistiría en seleccionar los datos de entrada de la manera más óptima posible para entrenar la red y estar en posibilidades de ser utilizada.
- 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

- Ahamed, S., Tanzeem Mahmood, N., & Rahman, R. M. (2017). An intelligent system to predict academic performance based on different factors during adolescence. *Journal of Information and Telecommunication*, 155.175.
- Ahmad, F., Ismail, N. H., & Aziz, A. A. (2015). The prediction of students' performance using clasification data mining techniques. *Applied Mathematical Sciences*, 6415-6426.
- Bertona, L. F. (2005). *Entrenamiento de redes neuronales basado en algoritmos evolutivos*. Buenos Aires, Argentina: Universidad de Buenos Aires. Retrieved from <http://laboratorios.fi.uba.ar/lsi/bertona-tesisingenieriainformatica.pdf>
- Centro Nacional de Evaluación para la Educación Superior. (1994). *Exámenes Nacionales de Ingreso*. Retrieved Mayo 21, 2017, from <http://www.ceneval.edu.mx/exani-ii>
- Chain Revuelta, R., & Jácome Ávila, N. (2007). *Perfil de ingreso y trayectoria escolar en la Universidad*. Xalapa, Ver.: Universidad Veracruzana, Instituto de Investigaciones en Educación.
- Choque Aspiazu, G. (2016, Septiembre 19). *Algoritmo Levenberg-Marquardt*. Retrieved from El diario, ciencia y computación: 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.
- Facultad de Contaduría y Administración de la UACH. (2014). *Programa de trayectoria escolar de la Facultad de Contaduría y Administración*. Chihuahua, Chih.: Facultad de Contaduría y Administración.
- Fernández Pérez, J. A., Peña Chumacero, A., & Vera Rodríguez, F. (2006). Los estudios de trayectoria escolar. Su aplicación en la educación media superior. *Graffylia Revisata de la Facultad de Filosofía y Letras*, 24-29.

- Flores Gutiérrez, H. (2013, Junio 11). *Redes neuronales con aprendizaje no supervisado*. Retrieved from 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.
- García Nieto, N. (2008). *La función tutorial de la Universidad en el actual contexto de la Educación Superior*. Retrieved from La función tutorial de la Universidad en el actual contexto de la Educación Superior: <https://dialnet.unirioja.es/servlet/articulo?codigo=2541038>
- Gestal, M., Rivero, D., Rabuñal, J., Dorado, J., & Pazos, A. (2010). *Introducción a los Algoritmos Genéticos y la Programación Genética*. La Coruña, España.: Universidade da Coruña, Servizo de Publicacións.
- González Penedo, M. F. (2009, Abril 24). *Aprendizaje y entrenamiento*. Retrieved from <http://www.varpa.org/~mgpenedo/cursos/scx/archivospdf/Tema2-0.pdf>
- González, A. (2014, Julio 30). *Conceptos básicos de Machine Learning*. Retrieved from 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).
- Hagan, M., Demuth, H., Hudson Beale, M., & de Jesús, O. (2014). *Neural Network Desing*. Oklahoma, EE.UU.: Universidad de Oklahoma.
- Hamsa, H., Indiradevi, S., & Kizhakkethottam, J. J. (2016). Student academic performance prediction model using decision tree and fuzzy genetic algorithm. *Global Colloquium in Recent Advancement and Effectual Researches in Engieneering, Science and Technology (RAEREST 2016)* (pp. 326-332). India: Elsevier.
- Hilera González, J., & Martínez Hernández, V. (1995). *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*. Madrid, España.: RA-MA.

- Huang, S., & Fang, N. (2012). Predicting student academic performance in an engineering dynamics course: A comparison of four types of predictive mathematical models. *Computers & Education*, 133-145.
- Khalid Yousif, M., & Shaout, A. (2016). Fuzzy logic computational model for performance evaluation of Sudanese Universities and academic staff. *Journal of King Saud University – Computer and Information Sciences*.
- Kinsumba , P. A., Becerra Alonso, M. J., & Lau Fernández, R. (2016). Predicción del éxito académico en la carrera de Ciencias de la Computación de la universidad “Agostinho Neto”. *Referencia pedagógica*, 139-154.
- Kotu, V., & Deshpande, B. (2015). *Predictive analytics and data mining*. Waltham, MA, EEUU.: Morgan Kaufmann.
- López Balanzátegui, M. E., Flores Herrera, J., Flores Nicolalde, B., & Flores Nicolalde, F. (2016). Predicción del rendimiento académico de los estudiantes de física a través de las redes bayesianas en la unidad de cantidad de movimiento lineal. *Latin-American Journal of Physics Education*.
- Mandelman, S. D., Barbot, B., & Grigorenko, E. I. (2015). Predicting academic performance and trajectories from a measure of successful intelligence. *Learning and Individual Differences*, 387-393.
- Marbouit, F., Diefes-Dux, H. A., & Madhavan, K. (2016). Model for early prediction of at-risk students in a course using standards-based grading. *Computers & Education*, 1-15.
- Marín Uribe, R. (2003). *El modelo educativo de la UACH*. Chihuahua, Chih.: Dirección de Extensión y Difusión Cultural.
- 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. (2016, Marzo). Student Academic Performance Using Artificial Intelligence. *Student Academic Performance Using Artificial Intelligence*, 56-69. Retrieved from https://www.researchgate.net/publication/291262353_Student_Academic_Performance_Using_Artificial_Intelligence
- Rich, E., & Knight, K. (1991). *Artificial Intelligence*. Singapore: McGraw-Hill, Inc.
- Rodríguez, A. (1997). *El análisis de las Trayectorias Escolares como Herramientas de Evaluación de la Actividad Académica Universitaria en ANUIES*. México: Asociación Nacional de Universidades e Instituciones de Educación Superior.
- Ruiz, C. A., & Basualdo, M. S. (2001). *Redes neuronales: conceptos básicos y aplicaciones*. Rosario, Santa Fe, Argentina: Universidad Tecnológica Nacional – Facultad Regional Rosario. Retrieved Junio 12, 2017, from https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograias/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)* (pp. 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.

- Taylan, O., & Karagözoglu, B. (2019). An adaptative neuro-fuzzy model for prediction os student's academic performance. *Computers & Industrial Engineering*, 732-741.
- The MathWorks, Inc. (2017). *MathWorks Documentation*. Natick, Massachusetts, E.U.A.: MathWorks. Retrieved Agosto 6, 2017, from <https://www.mathworks.com/help/>
- Tomas Mariano, V. T. (2011). *Aprendizaje no supervisado*. Huejutla, Hidalgo: Universidad Autónoma del Estado de Hidalgo. Retrieved from 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. (2008, Marzo 7). *Histroia de la Universidad Autónoma de Chihuahua*. Retrieved from Universidad Autónoma de Chihuahua: http://www.uach.mx/institucional_y_juridica/organizacion/2008/03/07/historia/
- Universidad Autónoma de Chihuahua. (2008b). *La UACH a 54 años de su fundación*. Chihuahua, Chih.: Universidad Autónoma de Chihuahua. Retrieved from http://www.uach.mx/noticias/2008/12/07/uach_54_aniversario/
- Universidad Autónoma de Chihuahua. (2014). *Manual de aprovechamiento del Test Psicométrico Multidimensional TPM*. Chihuahua, Chih.: Universidad Autónoma de Chihuahua.
- Universidad Autónoma de Chihuahua. (2016). *Estadística Básica - Universidad Autónoma de Chihuahua*.
- Universidad Autónoma de Chihuahua. (2016b). *Programa Institucional de Tutorías*. Chihuahua: Universidad Autónoma de Chihuahua.
- Universidad Autónoma de Chihuahua. (2017). *Estadística básica*. Chihuahua, Chih.: 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. Retrieved 2017
- Xing, W., Gou, R., Petakovic, E., & Goggins, S. (2015). Participation-based Student Final Performance Prediction Model through Interpretable Genetic Programming: Integrating Learning Analytics, Educational Data Mining and Theory. *Computers in Human Behavior*.