

DOI: [10.24275/uama.5813.9684](https://doi.org/10.24275/uama.5813.9684)

**Universidad  
Autónoma  
Metropolitana**  
Casa abierta al tiempo



DIVISIÓN DE CIENCIAS Y ARTES PARA EL DISEÑO  
Especialización, Maestría y Doctorado en Diseño

**INTELIGENCIA ARTIFICIAL, COMO BASE DE UN  
MODELO DE CURRICULUM LEARNING PARA  
EL DESARROLLO DE COMPETENCIAS  
DIGITALES EN E-LEARNING**

**María Elena Chávez Solís**

Tesis para obtener el grado de Doctora en Diseño  
Posgrado en Diseño y Visualización de la Información

**Miembros del jurado**

**Dra. Yadira Alatríste Martínez**  
Directora de tesis

Dr. Luis Miguel De la Cruz Salas  
Co-Director

Dra. Rosa Elena Álvarez Martínez

Dra. Marcela Esperanza Buitrón de la Torre

Dr. Héctor Jesús Torres Lima

Ciudad de México: 1-Noviembre-2022

ORCID-0000-0001-5743-3008



## Resumen

El uso acelerado de la tecnología y la transformación digital demanda profesionales cualificados que hagan frente a la realidad de las necesidades laborales, centrados en la capacidad de respuesta inmediata y bajo un pensamiento sistémico. En el sector educativo se requiere diseñar estrategias que fortalezcan las competencias digitales, necesarias para la vida diaria y las aptitudes laborales, que vayan más allá de su uso; desarrollando una propuesta de valor acorde a los cambios para lograr aportaciones significativas enfocadas en una gestión de talento mediante una visión de un sistema dinámico. Diversos organismos internacionales promueven la cooperación a nivel mundial en el uso de la Inteligencia Artificial, por las aportaciones que ha presentado, mediante modelos predictivos que permiten aproximaciones precisas con márgenes de error muy pequeños.

Esta investigación tiene por objetivo, identificar los factores que impactan en el aprovechamiento de los estudiantes mediante e-learning para proponer un modelo de Inteligencia Artificial que fortalezca el desarrollo de competencias digitales. El estudio presenta un análisis basado en el modelo de investigación mixto bajo la complementariedad para incrementar la pertinencia y la validez de los conceptos y resultados; a través del enfoque cualitativo y cuantitativo durante el ciclo escolar 2020-2021 en estudiantes de nivel superior y posgrado. El cualitativo considera las dimensiones de la actividad y desarrollo del docente; evaluando 6 dimensiones: el apoyo institucional, la calidad de la plataforma, la calidad del sistema de aprendizaje, la calidad del docente, la calidad del aprovechamiento del estudiante y la calidad en la mejora continua. La intención en este enfoque es identificar las principales dificultades profesionales. El cuantitativo se desarrolló a través de la experiencia del estudiante con el diseño y la aplicación de un instrumento de medición dividido en 3 ejes: trayectoria escolar, actitud en las clases en línea y nivel de aprendizaje, con el objetivo de identificar los factores que influyeron en el aprendizaje mediante e-learning.

La propuesta de diseño experimental presenta un modelo de Inteligencia Artificial mediante una técnica inspirada en la forma en que los seres humanos adquieren conocimiento y un

algoritmo que considera un plan curricular a través de métricas: primero dominando conceptos simples y progresando a un nivel de dificultad mayor; para que los educandos desarrollen gradualmente las competencias digitales. Los resultados confirman la relación existente entre la modalidad de estudio y el aprovechamiento del estudiante.

El panorama presentado desde perspectivas distintas (docente-alumno) promueve una amplia discusión por la disrupción en el proceso de aprendizaje durante la pandemia, el uso de datos, la transformación vertiginosa de la tecnología que vincula a la actualización y fortalecimiento constante de competencias digitales tanto de docentes como de alumnos y al imprescindible uso de forma ética de modelos de Inteligencia Artificial que incrementen el aprendizaje. La investigación nos permite concluir que la IA no desplaza ni sustituye la actividad docente, por el contrario, la complementa, siendo que el ejercicio educativo requiere de estrategias para dinamizar la educación acorde a los cambios tecnológicos.

## Agradecimientos

### **A mis padres:**

Agradezco todas sus enseñanzas, sus consejos, su amor y dedicación para ser feliz y principalmente porque siguen a mi lado, como cuando era pequeña. Mi eterno agradecimiento y admiración por toda su paciencia.

### **A mis otros papás:**

Luis Javier y Karen, gracias por formar parte de mi vida, por sus pláticas, sus risas, su amor, por escucharme, por motivarme, por enseñarme otros caminos para seguir adelante. Los quiero mucho.

### **A mis hermanos:**

Gracias por su cariño.

### **Hasta el cielo:**

A Dios, a mi hermano y a mi gran amigo Leo.

### **A mi Directora de Tesis:**

#### **Dra. Yadira Alatraste Martínez:**

Quiero agradecer la confianza depositada en mí, su apoyo, seguimiento y orientación, un gran ejemplo de perseverancia, proactividad, objetividad y empeño por sacar las cosas adelante. Valoro infinitamente las horas extras, desvelos y malpasadas para revisar y mejorar mi trabajo. Mil gracias

#### **Dra. Rosa Elena Álvarez Martínez:**

Gracias por compartir tantas experiencias y conocimiento; sencillo no ha sido el proceso, pero gracias a las ganas de formar una investigación de calidad y dedicación que los ha regido, he logrado importantes objetivos como la culminación de este trabajo.

#### **Dr. Luis Miguel de la Cruz:**

Gracias.

#### **Dra. Marcela Esperanza Buitrón de la Torre**

Gracias por impregnar la sabiduría en mi trabajo a través de sus constructivas recomendaciones.

#### **Dr. Héctor Jesús Torres Lima:**

Gracias por aportar la grandeza de su conocimiento, el detalle del significado en la forma y vislumbrar el camino de los objetivos.

#### **Dra. Esther Labrada Martínez**

Un pilar en mi aprendizaje, mil gracias.

#### **Dr. José Gustavo Iván Garmendia Ramírez.**

¡Mil gracias!

## Índice

Resumen	ii
Agradecimientos	iv
Índice	v
Índice de Figuras	xi
Índice de Tablas	xv
Introducción	xvii
Esquema Conceptual	xxvi

### Capítulo 1 Metodología de la Investigación.

1.	Metodología de la Investigación	2
1.1.	Diseño y Propuesta Metodológica	3
1.2.	Método Mixto de Investigación	4
1.2.1.	Método Cualitativo	5
1.2.1.1.	Diseño de Investigación, Sitio y Participantes.	6
1.2.2.	Caso 1. Universidades en Modalidad Presencial Transferidas en Línea.	8
1.2.3.	Caso 2. Instituciones Modalidad en Línea antes de la Pandemia.	9
1.2.4.	Caso 3. Microsoft México, Nivel Superior en Modalidad en Línea.	10
1.2.4.1.	Recogida y Análisis de Datos	11
1.2.5.	Método Cuantitativo	11
1.2.5.1.	Etapas del Diseño de la Investigación	12
1.2.6.	Fase 1. Conceptualización de la Idea.	13
1.2.7.	Fase 2: Planteamiento del Problema.	14
1.2.8.	Fase 3: Inmersión Inicial en el Campo.	15
1.2.9.	Fase 4: Concepción del Diseño del Estudio.	17
1.2.9.1.	Objetivo:	17
1.2.9.2.	Preguntas de Investigación	17
1.2.9.3.	Hipótesis	17
1.2.10.	Fase 5. Definición de la Muestra Inicial del Estudio.	18
1.2.11.	Fase 6. Recolección de Datos.	19
1.2.12.	Fase 7. Análisis de Datos.	19
1.2.13.	Fase 8. Interpretación de Datos.	20

## **Capítulo 2 Inteligencia Artificial**

2.	Inteligencia Artificial	26
2.1	La concepción de la Inteligencia Artificial	26
2.2	Historia de la Inteligencia Artificial	28
2.3	La Prueba de Turing	30
	2.3.1. La Inteligencia Artificial y su comportamiento	32
	2.3.2. Sistemas basados en el comportamiento	33
2.4	Los Métodos Inductivo y Sintético.	35
	2.4.1. Método inductivo	35
	2.4.2. Método sintético	35
2.5	Predicción y adaptación	37
	2.5.1. Características de la Inteligencia Artificial.	40
	2.5.2. IA como ciencia	41
	2.5.3. IA como Ingeniería	41
	2.5.4. IA débil	43
	2.5.5. IA fuerte	46
	2.5.6. Inteligencia Artificial como Búsqueda	48
2.6	Aportaciones de la Inteligencia Artificial	50
	2.6.1. Inteligencia Artificial en el Sector Educativo.	50
	2.6.2. Aplicaciones de IA en Canadá	53
	2.6.3. Aplicaciones de IA en China	54

## **Capítulo 3 Educación basada en competencias.**

3.	Antecedentes de la educación basada en competencias.	57
3.1.	Educación basada en competencias	58
3.2.	Principales teorías	60
3.3.	Aprendizaje basado en competencias	62
3.4.	Bases, fundamentos y fuentes del currículo	63
	3.4.1. Bases	63
	3.4.2. Fundamentos	64
	3.4.3. Fuentes del Currículo	66
3.5.	Programación de competencias	72
3.6.	Competencias Digitales	73
	3.6.1. Competencias Digitales del Docente	74
	3.6.2. La Evaluación de Competencia Digital	76

3.6.3.	Propuesta de evaluación de competencias digitales del docente.	77
3.7.	Tendencias Educativas Relacionadas con las Competencias Digitales	90
3.7.1.	Inteligencia Artificial en la Educación	90
3.7.2.	Las Redes Sociales en la Educación	90
3.7.3.	Realidad Virtual en la educación	92
3.7.4.	Realidad Aumentada en la educación	94
3.7.5.	Internet de las Cosas en la Educación	98
3.7.6.	Metaverso en la Educación	99

## **Capítulo 4 E-learning**

4.	El Sector Educativo antes de la Pandemia	103
4.1.	La Crisis del Sector Educativo	103
4.2.	Características del e-learning	110
4.3.	Evolución Tecnológica del e-learning	111
4.4.	La tecnopedagogía en el e-learning	113
4.4.1.	Modelo TPACK	115
4.4.2.	Modelo SAMR	116
4.5.	Innovación en el e-learning	120
4.6.	Calidad en el Ecosistema del e-learning	121
4.6.1.	Calidad de la Institución	122
4.6.2.	Calidad Docente	123
4.6.3.	Calidad del Sistema de Aprendizaje o Plataforma	123
4.6.4.	Calidad de la Evaluación del Programa	124
4.6.5.	Calidad del Aprovechamiento del Alumno	124
4.6.6.	Calidad en la Mejora Continua	124
4.7.	Aportaciones del e-learning	125

## **Capítulo 5 Machine Learning.**

5.	Machine Learning	128
5.1.	Historia del Machine Learning	128
5.2.	Clasificación de los datos de ML	131
5.2.1.	Conceptos y Definiciones de Datos	132
5.2.2.	Conceptos sobre Aprendizaje para Machine Learning.	133
5.3.	Tipos de Problemas	134
5.4.	Tipos de Datos	135

5.5.	Tipos de Aprendizaje de Machine Learning	135
5.5.1.	Aprendizaje Supervisado	135
5.5.2.	Aprendizaje No Supervisado	137
5.5.3.	Algoritmo Semi-Supervisado.	140
5.5.4.	Algoritmos por refuerzo	141
5.6.	Etapas de Implementación del ML	143

## **Capítulo 6 Deep Learning y Curriculum Learning.**

6.	Fundamento Teórico	146
6.1.	Red Neuronal	146
6.2.	Red Neuronal Artificial	149
6.3.	Deep Learning	152
6.3.1.	Clasificación de Redes Neuronales	164
6.3.1.1.	Red Monocapa	164
6.3.1.2.	Red Multicapa	165
6.3.1.3.	Red Neuronal Convolutacional	166
6.3.1.4.	Red Neuronal Concurrente	167
6.3.1.5.	Red Neuronal Base Radial	167
6.3.2.	Entrenamiento de una red neuronal	169
6.3.2.1.	Regla de propagación	169
6.3.2.2.	Forward Propagation	169
6.3.2.3.	Backpropagation	170
6.3.2.4.	Pesos y Sesgo (bias)	171
6.3.2.5.	El descenso de gradiente	173
6.3.3.	Tipos de Neuronas Artificiales	173
6.3.4.	Aprendizaje de las Redes Neuronales	174
6.3.5.	Tipos de Aprendizaje	174
6.4.	Deep Reinforcement Learning	176
6.5.	Curriculum Learning	178
6.5.1.	Estilos de CL por Refuerzo	179
6.5.1.1.	Plan de estudios guiado por el maestro	180
6.5.1.2.	Plan de estudios a través del juego personal	182
6.5.1.3.	Plan de estudios por Generación Automática de Objetivos	184
6.5.1.4.	Currículo Basado en Habilidades	187
6.5.1.5.	Plan de Estudios a través de la Destilación	189



6.5.2.	Clasificación de Dificultad de las Funciones de Puntuación	191
6.5.3.	Aportaciones del Curriculum Learning	192
6.5.3.1.	Minecraft basado en Curriculum Learning	192
6.5.3.2.	Resolviendo El Cubo de Rubik	194

## **Capítulo 7 Propuesta del Diseño Experimental**

7.	Propuesta de Diseño del Modelo Experimental de CL	197
7.1.	Minería de Datos	197
7.1.1.	Fases de la Minería de Datos para el modelo	198
7.2.	Propuesta del modelo experimental	202
7.3.	Estructura del modelo de CL basado en el plan de estudios	203
7.4.	Diseño de la Cédula Inicial de Datos	205
7.5.	Asignación de valores al Modelo Curriculum Learning	210
7.6.	Diseño del plan de estudios para el desarrollo de competencias digitales	217
7.6.1.	Algoritmo de CL utilizado	221
7.6.1.1.	Criterio Curricular (metodología)	221

## **Capítulo 8 Resultados de la Investigación**

8.	Resultados de la Investigación	228
8.1.	Resultados bajo el Enfoque Cualitativo	229
8.1.1.	Resultados de la Recolección de Datos.	229
8.1.2.	Resultados del Análisis de Datos.	230
8.1.3.	Resultados del Análisis de las Instituciones Educativas de Nivel Superior.	230
8.1.4.	Modalidad Presencial: Fortalezas y Oportunidades.	231
8.1.5.	Modalidad en línea: Fortalezas y Oportunidades.	233
8.1.6.	Resultados del Análisis Cualitativo	235
8.2.	Resultados bajo el Enfoque Cuantitativo	249
8.2.1.	Resultados e Interpretación de los Datos.	252
8.2.2.	Reporte de Resultados de la Prueba Ji-Cuadrado.	254

## **Conclusión y discusión.**

9.	Conclusión	256
9.1.	Conclusión del Marco Contextual y el Marco Teórico	256
9.2.	Conclusión de la Metodología de la Investigación	257

9.2.1.	Conclusión del Enfoque Cualitativo	258
9.2.2.	Conclusión del Enfoque Cuantitativo	258
9.3.	Aportaciones del Diseño Experimental	259
9.4.	Discusión	261
<b>Bibliografía</b>		265
<b>Curriculum Vitae</b>		282

## Índice de Figuras

Figura 1.1	Metodología de la Investigación Cuantitativa .....	13
Figura 1.2	Tasa de abandono escolar por nivel educativo .....	16
Figura 1.3	Esquema de Experimentos y Variables .....	18
Figura 1.4	Secuencia Habitual de Análisis en Investigaciones mixtas.....	23
Figura 2.1	La Prueba de Turing .....	31
Figura 2.2	Evolución de la Inteligencia Artificial .....	34
Figura 2.3	Métodos Inductivo y Sintético .....	36
Figura 2.4	Tipo de inteligencia y su método.....	36
Figura 2.5	Procesos de Predicción y Adaptación .....	38
Figura 2.6	Formalización de las metas de un sistema .....	38
Figura 2.7	Problemas estáticos y dinámicos .....	39
Figura 2.8	IA como Ciencia e Inteligencia Artificial como Ingeniería .....	40
Figura 2.9	Esquema Cualitativo de la IA baso como Ingeniería.....	43
Figura 2.10	IA y sus subramas.....	46
Figura 2.11	Adaptación por Tipo de Escala Temporal.....	49
Figura 2.12	Clasificación de Adaptación y Técnica de Aprendizaje .....	49
Figura 3.1	Ejes de la Organización en la Programación de la Enseñanza .....	59
Figura 3.2	Principales Teorías Basadas en el Eje de la Acción .....	60
Figura 3.3	Pilares de la educación.....	62
Figura 3.4	Capacidades Integradas en las Competencias Clave .....	65
Figura 3.5	Competencias Clave .....	66
Figura 3.6	Enseñanza Estratégica Centrada en Actividades Cognitivas.....	72
Figura 3.7	Competencias Digitales .....	74
Figura 3.8	Tasa de Penetración de Redes Sociales.....	91
Figura 3.9	Uso de la Realidad Virtual en Medicina .....	93

Figura 3.10 Representación geométrica con RA.....	95
Figura 3.11 Animación de dibujos mediante RA.....	96
Figura 3.12 Foro Thinglink.....	97
Figura 4.1 Cierre de Escuelas a Nivel Mundial durante el COVID-19.....	104
Figura 4.2 Estudiantes Afectados por el Cierre de Escuelas.....	105
Figura 4.3 Distribución Porcentual Inscrita que Concluyó el Ciclo Escolar.....	106
Figura 4.4 Distribución Porcentual del Nivel Superior por Tipo de Sostenimiento.....	106
Figura 4.5 Inscritos por Tipo de Sostenimiento y su Condición Escolar.....	107
Figura 4.6 Distribución Porcentual Motivo de No conclusión del Ciclo.....	107
Figura 4.7 Características del e-learning.....	110
Figura 4.8 Recursos Tecnológicos para el Aprendizaje.....	114
Figura 4.9 Modelo TPACK.....	116
Figura 4.10 Modelo SAMR.....	117
Figura 4.11 Recursos Tecnopedagógicos.....	119
Figura 5.1 Aprendizaje Supervisado.....	137
Figura 5.2 Aprendizaje No supervisado.....	138
Figura 5.3 Aprendizaje Semi supervisado.....	141
Figura 5.4 Algoritmo por Refuerzo.....	142
Figura 6.1 Estructura de una Neurona.....	148
Figura 6.2 La IA, Subramas y Ejemplos.....	152
Figura 6.3 Capas de la Red Neuronal Artificial.....	154
Figura 6.4 Representación Matemática de una Red Neuronal Artificial.....	155
Figura 6.5 Función Sigmoide.....	159
Figura 6.6 Capas de la red neuronal artificial.....	159
Figura 6.7 Representación de Aprendizaje de una Red Neuronal Artificial.....	160
Figura 6.8 Representación de Capas en una Red Convolutiva.....	161
Figura 6.9 Detección de Múltiples Objetos.....	161

Figura 6.10	Categorización de los Rostros (Masculino/Femenino) .....	162
Figura 6.11	Red Neuronal y sus Funciones de Activación .....	163
Figura 6.12	Fórmulas de la función de activación .....	164
Figura 6.13	Red Monocapa.....	165
Figura 6.14	Red Multicapa .....	165
Figura 6.15	Red Neuronal Convolutacional .....	166
Figura 6.16	Red Neuronal Base Radial .....	167
Figura 6.17	Clasificación de las Redes Neuronales .....	168
Figura 6.18	Forward Propagation .....	170
Figura 6.19	Back Propagation.....	171
Figura 6.20	Pesos de la Red Neuronal y Cálculo del Error .....	172
Figura 6.21	Estilos de Curriculum Learning por Refuerzo.....	180
Figura 6.22	Algoritmo de Progreso Absoluto de Aprendizaje (ALP) .....	182
Figura 6.23.	Plan de estudios a través del juego personal .....	183
Figura 6.24	Algoritmo de Aprendizaje por Generación de Objetivos .....	187
Figura 6.25	Currículo por Meta Refuerzo de Aprendizaje No Supervisado.....	188
Figura 6.26	Arquitectura de la Red Neuronal Progresiva.....	190
Figura 6.27	Predicción del Número en Minecraft mediante una RNA .....	193
Figura 6.28	Mano Robótica Resolviendo el Cubo de Rubik .....	194
Figura 7.1	Línea del Tiempo en la Minería de Datos .....	198
Figura 7.2	Propuesta del modelo experimental .....	202
Figura 7.3	CL basado en el Plan de Estudios.....	204
Figura 7.4	Representación de la RNA .....	211
Figura 7.5	Asignación de Valores a la Representación Algebraica de la RNA .....	213
Figura 7.6	Función de Activación .....	216
Figura 7.7	Función Tangente Hiperbólica para la Frontera de Decisión .....	217
Figura 7.8	Nivel de Desempeño.....	222

Figura 7.9	Algoritmo para el Curriculum Learning .....	223
Figura 8.1	Proceso del Método Mixto de Investigación.....	229
Figura 8.2	Caso 1. Evaluación de la Calidad Institucional .....	236
Figura 8.3	Caso 1. Evaluación de la Calidad Docente .....	237
Figura 8.4.	Caso 1. Calidad en el Sistema de Aprendizaje o Plataforma .....	238
Figura 8.5	Caso 1. Calidad de la Evaluación del Programa (Contenidos).....	239
Figura 8.6	Caso 1. Calidad del Aprovechamiento del Alumno.....	240
Figura 8.7	Caso 1. Evaluación de la Calidad de la Mejora Continua .....	241
Figura 8.8	Caso 2. Calidad de la Institución .....	242
Figura 8.9	Caso 2. Calidad del Docente .....	243
Figura 8.10	Caso 2. Calidad en el Sistema de Aprendizaje o Plataforma. ....	244
Figura 8.11	Caso 2 y 3. Calidad del Programa (Contenidos).....	245
Figura 8.12	Caso 2 y 3. Calidad del Aprovechamiento del Estudiante. ....	246
Figura 8.13	Caso 2 y 3. Calidad en la Mejora Continua.....	247
Figura 8.14	Caso 1, 2 y 3. Evaluación final.....	248

## Índice de Tablas

Tabla 1.1	Análisis de la educación en modalidad presencial .....	9
Tabla 1.2	Instituciones de Estudios Superior de modalidad en línea.....	10
Tabla 1.3	Análisis de Microsoft México en modalidad en línea. ....	10
Tabla 1.4	Ejemplos de análisis e interpretación de los datos. ....	20
Tabla 2.1	Enfoques de la Inteligencia Artificial.....	32
Tabla 2.2	Aplicaciones de la IA y el Big Data .....	54
Tabla 3.1	Plano práctico de la actividad .....	61
Tabla 3.2	Relación de los pilares con el aprendizaje .....	63
Tabla 3.3	Competencias clave.....	67
Tabla 3.4	Propuesta de Evaluación de Competencia Digital Docente.....	78
Tabla 3.5	Conocimiento de las Competencias Digitales del Docente .....	79
Tabla 3.6	Conocimiento Competencias Digitales del Estudiante.....	86
Tabla 3.7	Casos de estudio aplicando RA.....	96
Tabla 4.1	Índice de reprobación y recursamiento durante 2018.....	109
Tabla 4.2	Evolución tecnológica del e-learning .....	111
Tabla 4.3.	Evolución tecnológica del e-learning García y Seoane (2015).....	112
Tabla 5.1	Conceptos y definición de los datos para Machine Learning .....	132
Tabla 5.2	Conceptos sobre aprendizaje para Machine Learning .....	133
Tabla 5.3	Tipos de problemas .....	134
Tabla 5.4	Conceptos sobre aprendizaje para Machine Learning .....	135
Tabla 5.5	Etapas de un modelo machine learning .....	143
Tabla 5.6	Criterios para seleccionar el tipo de algoritmo de ML .....	144
Tabla 6.1	Principios de las redes neuronales artificiales.....	151
Tabla 6.2	Conceptos básicos de la Red Neuronal Artificial.....	154
Tabla 6.3	Tipos de Aprendizaje.....	175
Tabla 7.1	Cédula de Evaluación Inicial del Estudiante.Conjunto de datos .....	205
Tabla 7.2	Asignación de pesos en la RNA.....	212
Tabla 7.3	Pesos asignados en la Red Neuronal .....	214
Tabla 7.4	Competencias Digitales del Estudiante .....	218
Tabla 8.1	Fortalezas y Oportunidades Modalidad Presencial .....	231
Tabla 8.2	Fortalezas y Oportunidades Modalidad en línea. ....	234
Tabla 8.3	Resultados del instrumento de medición .....	249

Tabla 8.4	Resumen del desempeño académico .....	252
Tabla 8.5	Contingencia para el cálculo de Ji-Cuadrado.....	252
Tabla 8.6	Frecuencia porcentual o de probabilidad.....	253
Tabla 8.7	Frecuencia esperada para el cálculo de Ji-Cuadrado.....	253
Tabla 8.8	Cálculo estadístico Ji-Cuadrado.....	253



## Introducción

La pandemia de la COVID-19, declarada en marzo de 2020 y la implementación de la emergencia sanitaria, así como el distanciamiento social, provocó una modificación de las actividades. Existió mucha incertidumbre, prácticamente el mundo se paralizó; siendo la educación en línea la única opción para el aprendizaje en el nivel superior.

En el sector educativo la transferencia de la modalidad presencial a la modalidad en línea, no necesariamente implicó transferencia de recursos tecnológicos, sino adaptación y acciones rápidas para la continuidad del aprendizaje; situación que implicaba el uso de tecnología y el dominio de algunas competencias digitales tanto de los docentes como de los educandos.

El e-learning tomó gran relevancia, e incrementó vertiginosamente el número de educandos, las redes sociales y las plataformas de videoconferencias fueron los medios de mayor demanda para la transmisión de clases y recursos como tareas, archivos, entre otros. Los hogares, se convirtieron en centro de trabajo, de esparcimiento, lugares de convivencia familiar o en el peor de los casos de violencia familiar; además de presentarse situaciones como incrementos en los contagios de la COVID-19 en familias enteras y factores económicos por el alto índice de desempleo; situación que generó angustia, incertidumbre, soledad, violencia y hasta depresión en la sociedad.

A nivel mundial, organismos internacionales habían alertado de la crisis en el sector educativo y la pandemia aumentó las tasas de deserción escolar; el cierre de escuelas a nivel mundial generó una transformación en los procesos de enseñanza-aprendizaje.

Con el paso del tiempo se ha incrementado la necesidad de utilizar sistemas inteligentes, dado que vivimos en un mundo interconectado de información y su crecimiento conlleva a la demanda de un mejor rendimiento, de la resolución de problemas complejos y el entendimiento de patrones basados en la analítica de datos.

Dadas las aportaciones que considera conocer la evolución de la Inteligencia Artificial (IA), resulta interesante el conocimiento y la abstracción que los iniciadores tuvieron para dar paso al Machine Learning (sub-rama de la Inteligencia Artificial), ya que permite realizar modelos predictivos a través del análisis masivo de datos. Dado que el sector educativo había sufrido una transformación digital impactando a sus estudiantes, se identifican recursos e información en la IA que agregan valor a la toma de decisiones.

Siendo estos hechos los que conllevan a varias interrogantes y motivaron el desarrollo de la presente investigación. El objetivo planteado es identificar los factores que impactan en el aprendizaje de los estudiantes en línea a nivel superior durante el ciclo escolar 2020-2021 y diseñar un modelo de Inteligencia Artificial como medida predictiva para fortalecer las competencias digitales. Apoyada en la siguiente hipótesis planteada: si nuestra misión es identificar los factores que impactan en el aprendizaje de los estudiantes en la modalidad en línea a nivel superior, entonces resulta viable diseñar un modelo adaptativo que fortalezca sus competencias digitales mediante el uso de Inteligencia Artificial, esta nace de las siguientes

preguntas planteadas: ¿Si identificamos los factores que impactan en los estudiantes de modalidad en línea de nivel superior podemos reducir los riesgos de deserción escolar?, ¿Es posible evaluar las competencias digitales a través de un modelo de Inteligencia Artificial para mejorar el aprendizaje?

Los retos y perspectivas de cambio en este siglo, y la consecuente evolución de la IA, nos enfrenta a avanzar en el cumplimiento y la responsabilidad de plantear proyectos como el que se presenta, en situaciones críticas e innovadoras, tanto en términos de conocimiento como de competencias y actitudes. La modernización, el cambio, la globalización y sus repercusiones en los diversos órdenes de la vida social impulsan a la utilización de estos recursos.

El procedimiento para identificar los elementos, relaciones y el sistema propiamente dicho, para proponer el uso y aplicación de la IA como procesamiento de información aplicada al e-learning y el desarrollo de competencias digitales, se justifica la forma de trabajo y se definen los métodos y formas de análisis, base de la investigación. La cual consta de las siguientes fases:

1. Identificación de la problemática a la que el proyecto refiere y metodología de investigación.
2. Análisis de las características de la IA, el desarrollo de competencias, el estudio del ecosistema del e-learning, el análisis, características y aplicaciones del machine learning.
3. Presentación de la propuesta de diseño, resultados y conclusión.

La presente investigación se lleva a cabo a través del método mixto, representado por un conjunto de procesos sistemáticos, empíricos y críticos de investigación e implica la recolección y el análisis de datos cualitativos y cuantitativos, así como su integración y discusión conjunta para realizar inferencias producto de toda la información recabada (metainferencias) y lograr un mayor entendimiento del fenómeno bajo estudio (Hernández Sampieri et al., 2014).

La investigación científica planteada a partir del enfoque cualitativo es enunciada por M.A. Rothery y R. (Grinnell, 1977) y Creswell (1977), para explorar como afrontaron los estudiantes de nivel superior la educación en línea durante el ciclo escolar 2020-2021.

Nuevamente citando al mismo autor, para generar conocimiento el enfoque cuantitativo se fundamenta en el método hipotético-deductivo presentando el desarrollo y fundamento de las fases del enfoque basado en la metodología de la investigación de Hernández Sampieri et al. (2014).

Para cubrir los objetivos de esta investigación se generaron 9 capítulos, que exponen en primer lugar el marco metodológico de la investigación bajo el enfoque mixto; en segundo término el marco contextual, tendiente a ubicar al lector en los temas de influencia inmediata al caso de estudio; posteriormente se describe el marco teórico, este presenta la recopilación de antecedentes, investigaciones previas y consideraciones teóricas en las que se sustenta la investigación; la cuarta parte se refiere a los resultados obtenidos, que dan cuenta de la situación vivida y del impacto generado en docentes y estudiantes a través de los métodos de

recolección de datos utilizados y por último se presenta la conclusión y discusión. A continuación, se da una semblanza de cada parte:

## **Marco Metodológico**

**Capítulo 1, “Metodología de la Investigación”**, se centra en el estudio de la investigación mediante el método mixto, a través del elemento de fusión para integrar los ángulos de análisis tanto del modelo cualitativo, como del cuantitativo. Por un lado, mediante el enfoque cualitativo es relevante analizar el trabajo de los docentes durante el fenómeno de la pandemia y las competencias digitales desarrolladas, y por el otro, el modelo cuantitativo como complemento de la investigación sobre los factores que influyeron en el aprovechamiento y en particular determinar si la modalidad de aprendizaje ya sea presencial o en línea está vinculada con el desempeño de los estudiantes.

## **Marco Contextual**

**Capítulo 2. “Inteligencia Artificial”**, se presenta el estado del arte considerado en el cual vislumbra el avance tecnológico de lo que refiere la automatización del proceso humano representado por una máquina, el desarrollo histórico y su fortalecimiento por diferentes organizaciones internacionales; presentando también el uso y aplicaciones que se han hecho a nivel internacional dando énfasis al sector educativo.

## **Marco Teórico**

**Capítulo 3. “Educación Basada en Competencias”**, se describen las bases y fundamentos de estas, haciendo énfasis en las competencias digitales, imprescindibles en la transformación tecnológica, dado el manejo de los entornos virtuales y los recursos tecnológicos, como factores de cambio en la evolución digital; considerados impulsores para el logro de los objetivos del aprendizaje. Se abordan las técnicas de aprendizaje; necesarias para aprender a aprender dado que permiten organizar la información, seleccionar los conceptos relevantes o establecer relaciones entre diferentes partes de la información.

**Capítulo 4. “E-learning”**, se aborda su uso y aplicaciones como epicentro del aprendizaje durante la pandemia; considerando la perspectiva del ecosistema de la modalidad en línea integrada en un escenario complejo, evaluando los factores que impactan su uso, como son la plataforma, el contenido curricular, el uso de recursos tecnológicos, entre otros.

**Capítulo 5. “Machine learning”** se presentan sus algoritmos desde la perspectiva de aproximar un fenómeno a partir de la observación y/o entendimiento de los datos, su conceptualización y aportación; que también puede verse desde un enfoque general; se profundiza en los conceptos, tipos de datos, sus características y clasificación de modelos, recorriendo de esta forma la base teórica para la propuesta del modelo que proporcione una mejora en el aprendizaje.

**Capítulo 6 “Deep Learning y Curriculum Learning”**, se describen las definiciones, aportaciones y modelos desarrollados en la subrama del aprendizaje profundo, desde la óptica

de la emulación del cerebro humano, las redes neuronales biológicas y las artificiales para comprender el funcionamiento de la máquina y las similitudes.

## **Propuesta del Diseño Experimental**

**Capítulo 7 “Propuesta del Diseño Experimental”**, se presenta la aportación a la investigación mediante el diseño de un modelo Curriculum Learning basado en Inteligencia Artificial que permite emular una red neuronal artificial para el fortalecimiento de las competencias que va de lo fácil (nivel básico) a lo difícil (nivel experto), tal como sucede en un video juego o cuando una mano robótica logra armar el cubo de Rubik de forma autónoma.

**Capítulo 8 “Resultados”**, proporciona las aportaciones de los saberes obtenidos refiriendo tanto al enfoque cualitativo como al enfoque cuantitativo, por la complementariedad que aporta a la investigación basados en una propuesta de diseño para desarrollar un modelo curriculum learning, con la principal directriz orientada hacia el desarrollo de competencias digitales.

**Conclusión y discusión**, describen la forma en que se dio respuesta a las preguntas de investigación, así como el cumplimiento al objetivo planteado y la prueba de la hipótesis descrita en el apartado de “Metodología de la Investigación”.

El panorama presentado desde perspectivas distintas (docente-alumno) promueve una amplia discusión por la disrupción en el proceso de aprendizaje durante la pandemia, el uso de datos, la transformación acelerada de la tecnología que vincula a la actualización y fortalecimiento

constante de competencias digitales tanto de docentes y alumnos y al imprescindible uso de forma ética de modelos de Inteligencia Artificial que incrementen el aprendizaje.

El resultado obtenido analizado bajo el enfoque cualitativo del trabajo de los docentes mostró evidencia de las situaciones presentadas en la pandemia y los factores involucrados para la ejecución de su función, ya que en ellos recae el valor del aprendizaje adquirido por los estudiantes. Se identificó la importancia que tiene el apoyo institucional, la colaboración y el trabajo en equipo para la elaboración, integración y diseño de contenido obteniendo como resultado del enfoque cuantitativo los factores que influyen en el aprovechamiento de los estudiantes.

En su plan heurístico, la investigación permitió describir la naturaleza del fenómeno evaluado desde el ecosistema del e-learning en el docente y los factores que impactan en el aprovechamiento de los estudiantes. Siendo así que, los resultados de ambos saberes fueron integrados en una propuesta de diseño de un modelo de ML que fortalezca las competencias digitales.

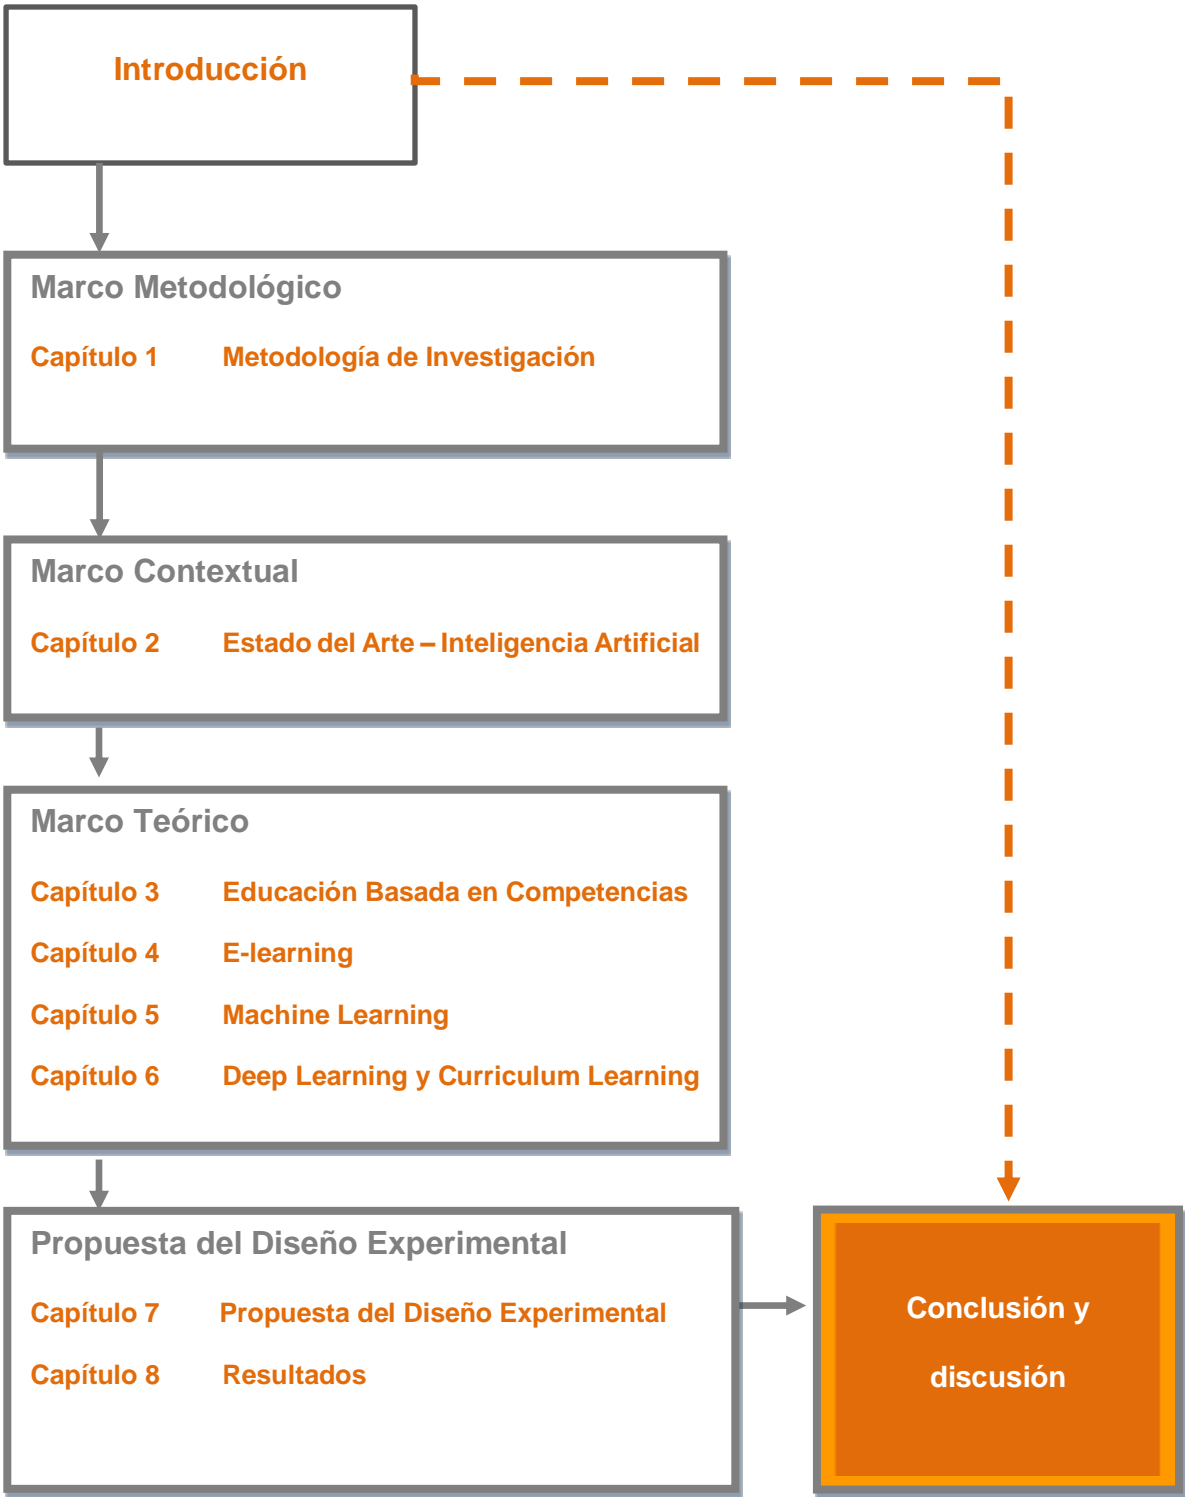
Es relevante considerar que la Inteligencia Artificial en el sector educativo proporciona grandes aportaciones que no desplazan ni sustituyen la actividad docente, por el contrario, complementan su actividad para mejorar el conocimiento.



Lo que conduce a tomar acciones que den atención prioritaria al fortalecimiento de las competencias digitales tanto a docentes para la formación eficaz como a educandos para la inmersión en un mercado laboral en el que la tecnología es la principal herramienta, aún en carreras profesionales que no están relacionadas con la Tecnología, Información y Comunicación.

Como toda propuesta académica está sujeta a la crítica, los comentarios, sugerencias que llevan tanto a la autora como a la comunidad científica, a cuestionar las vertientes analizadas, la perspectiva o los resultados obtenidos, con el fin de lograr las mejores decisiones que direccionarán el futuro de las investigaciones, a continuación se presenta en la Figura 1 de forma gráfica el esquema conceptual del trabajo desarrollado.

**Esquema Conceptual**





## Capítulo 1 Metodología de la Investigación

## Capítulo 1 Metodología de la Investigación.

### 1. Metodología de la Investigación

En este apartado se plantea la estrategia que se siguió en la investigación. Se justifica la forma de trabajo y se definen los métodos y procedimientos de análisis, base de la investigación. Para dar fundamento al marco científico, se consideró el estado del arte en el capítulo 2. Inteligencia Artificial (IA), el cual vislumbra el avance tecnológico de lo que refiere la automatización del proceso humano representado por una máquina, el desarrollo histórico y su fortalecimiento por diferentes organizaciones internacionales. Lo anterior permite ubicar el contexto actual de la información y conocimiento que sustenta la problemática identificada en el aprendizaje durante la pandemia, es decir, es el marco de referencia del conocimiento científico en esta investigación.

Posteriormente, como parte del marco teórico, el capítulo 3, presenta un análisis de las principales teorías en educación basada en competencias haciendo énfasis en las competencias digitales, las bases, fundamentos y fuentes del currículo entre otros aspectos que se consideran importantes para la investigación; en el capítulo 4, se analiza la funcionalidad, evolución, innovación, calidad y aportaciones del e-learning durante la pandemia, ya que tomó gran relevancia; representó el pilar para el aprendizaje y la columna vertebral de la investigación, como medio o canal de comunicación entre el docente y el estudiante; en el capítulo 5, se definió y profundizó en las aportaciones que puede realizar el machine learning en la educación, los conceptos, tipos de modelos, características y avances,

haciendo énfasis en el Deep Learning (DL) y Curriculum Learning (CL) para proponer un modelo que fortalezca las competencias digitales a fin de mejorar el aprendizaje de los estudiantes mediante e-learning.

Por tratarse de un proceso disruptivo ocasionado durante la pandemia al sector educativo y en particular a la educación presencial, se retoma el caso de estudio respecto a la educación basada en competencias digitales, necesarias tanto en docentes como alumnos para llevar a cabo el proceso de enseñanza aprendizaje mediante e-learning. En seguida, se describen las diferentes etapas metodológicas y cómo se abordaron.

### 1.1. Diseño y Propuesta Metodológica

La propuesta de investigación descrita en este apartado, permite plantear las inquietudes, observaciones y preguntas de forma estructurada, convirtiéndose en la esencia del desarrollo de la investigación, en particular es la manera de concluir con nuestro proceso. La metodología empleada se lleva a cabo a través del método mixto, representado por un conjunto de procesos sistemáticos, empíricos y críticos de investigación e implica la recolección y el análisis de datos cualitativos y cuantitativos, así como su integración y discusión conjunta, para realizar inferencias producto de toda la información recabada (metainferencias) y lograr un mayor entendimiento del fenómeno bajo estudio (Hernández Sampieri et al., 2014).

Mediante la metodología se define la forma en la que se desarrolla esta investigación; el estudio comprendió dos vertientes: el enfoque cualitativo y el cuantitativo.

### 1.2. Método Mixto de Investigación

En el campo de la educación durante la pandemia se efectuaron múltiples investigaciones mixtas como muestra tenemos el estudio “Educación a distancia en tiempos de COVID-19: Análisis desde la perspectiva de los estudiantes universitarios” (Pérez-López et al., 2021) y “Evaluación de los aprendizajes en tiempos de COVID-19: el caso del estado de Chihuahua” (Guevara-Araiza & Guevara-Araiza, 2021).

Se considera relevante la investigación bajo el enfoque cualitativo: enseñanza-aprendizaje, ya que durante el distanciamiento social era necesario contar con algunos recursos tecnológicos como computadora, internet y en algunos casos también consideraban necesario tener cámara y micrófono.

La investigación científica con enfoque cualitativo es enunciada por M.A. Rothery y R. (Grinnell, 1977) y Creswell (1977) como estudios con las siguientes características:

- Que se conducen básicamente en ambientes naturales, donde los participantes se comportan como lo hacen en su vida cotidiana.

- Donde las variables no se definen con el propósito de manipularse ni de controlarse experimentalmente (desde luego, se observan los cambios en diferentes variables y sus relaciones).
- En los cuales las preguntas de investigación no siempre se han conceptualizado ni definido por completo; es decir, se define la manera de ser medidas o evaluarse (aunque a veces si es posible).
- En que la recolección de los datos está fuertemente influida por las experiencias y las prioridades de los participantes en la investigación, más que por la aplicación de un instrumento de medición estandarizado, estructurado y predeterminado.
- Donde los significados se extraen de los datos y se presentan a otros, y no necesitan reducirse a números ni necesariamente deben analizarse de forma estadística (aunque el conteo, el análisis de contenido y el tratamiento de la información utilicen expresiones numéricas para analizarse después).

### 1.2.1. Método Cualitativo

La transferencia emergente de la educación presencial modificó el proceso de enseñanza aprendizaje y los continuos avances en la tecnología digital han obligado a desarrollar competencias digitales en los docentes y en los estudiantes. Los principales cuestionamientos que guiaron este trabajo son:

1. ¿Cómo los docentes dieron continuidad al proceso de enseñanza aprendizaje?
2. ¿Cómo han integrado los recursos tecnológicos en la función docente?
3. ¿Los docentes manifestaban situaciones de estrés, angustia, ansiedad o temor?

El método cualitativo nos permite indagar sobre las repercusiones de la COVID-19 en el sector educativo a nivel superior. El análisis cualitativo se centra en la observación de la adopción del e-learning durante el ciclo escolar 2020-2021 de Instituciones Educativas de Nivel Superior, Posgrado y la empresa Microsoft que impartió cursos a estudiantes de nivel superior de escuelas públicas (educación abierta), segmentado en los siguientes 3 casos:

- Caso 1. Universidades en modalidad presencial transferida a la modalidad en línea,
- Caso 2. Universidades que proporcionaban clases en modalidad en línea.
- Caso 3. Empresa (Microsoft) modalidad en línea nivel superior de universidades públicas.

Creswell (2007) señala: “El concepto de muestreo intencional se utiliza en la investigación cualitativa. Esto significa que el investigador selecciona individuos y sitios para el estudio porque pueden informar a propósito una comprensión de los problemas de investigación...” (p. 125). En un estudio cualitativo, tanto la recopilación como el análisis de datos se influyen mutuamente (Creswell, 2007; Mukminin, 2012).

### 1.2.1.1. Diseño de Investigación, Sitio y Participantes.

En esta fase la principal pregunta es ¿cómo identificar los factores que impactan en el aprovechamiento de los estudiantes mediante e-learning durante el ciclo escolar 2020-2021?; observando aquellas barreras presentadas tanto para los docentes como para los alumnos



que representen un bajo aprovechamiento y un incremento en los índices de deserción escolar; centrados únicamente en la ausencia de competencias digitales.

Esta investigación hace uso de un muestreo intencional con una estrategia de caso de conveniencia. Creswell (2007) definió, “casos de conveniencia”, que representan sitios o individuos desde los cuales los investigadores pueden acceder y recolectar datos fácilmente” (p. 126). Los casos analizados fueron considerados, debido a que se contaba con acceso a las clases y a los sitios de investigación. Los resultados de este estudio presentados en el capítulo 8, no deben generalizarse, porque son una muestra de la situación vivida con la transferencia de modalidad abrupta y la investigación considera ante cualquier circunstancia el bienestar tanto de los estudiantes como de los docentes.

Los parámetros analizados en los docentes en cada institución fueron los siguientes:

- Competencias digitales del docente.
- Uso de alguna plataforma para administrar y controlar los recursos.
- Guías electrónicas de estudio.
- Planeación electrónicas del curso presentada al alumno.
- Material electrónico de estudio.
- Referencias electrónicas.
- Medios de comunicación electrónicos con los alumnos.

Derivado de los cambios sufridos en la pandemia, los docentes y estudiantes pueden sentirse sobrecargados de información o de actividades a desarrollar y en consecuencia afectar el

aprovechamiento, con el estrés que conlleva la sobrecarga del contenido en los materiales presentados en los cursos en línea y por la obligatoriedad de desarrollar competencias digitales paralelamente tanto con la enseñanza como en el aprendizaje de cada materia.

El Informe Horizon 2017 sobre Enseñanza Superior (NMC, 2017) remarca la idea de que la competencia digital no es solamente entender cómo usar las tecnologías, sino que es necesario comprender el profundo impacto de las tecnologías en un mundo digital y promover la colaboración para integrarlas de modo efectivo.

Asimismo, es importante considerar la progresiva implantación de los distintos modelos de enseñanza (blended-learning, e-learning, m-learning, adaptative learning, TPACK, SMART, entre otros) y recursos tecnológicos que enriquecen el sistema de enseñanza superior y destacan la importancia de la formación permanente como modelo que ha de sustentar la continua capacitación del profesorado y el enfoque de la formación del alumnado para ser competitivo laboralmente. La exploración considera los siguientes casos:

### 1.2.2. Caso 1. Universidades en Modalidad Presencial Transferidas en Línea.

Estudio realizado en 3 Instituciones de Estudios Superior públicas y 1 Institución de nivel posgrado pública, presentado en la Tabla 1.1. Análisis de la educación presencial transferida a la modalidad en línea:

- Instituto de Estudios Superiores Rosario Castellanos (IESRC), nivel superior se analizaron 5 docentes y nivel posgrado (modalidad híbrida), 2 docentes.
- Instituto Politécnico Nacional (IPN), nivel superior se analizaron 10 docentes.
- Universidad Autónoma Metropolitana (UAM), nivel posgrado, se analizaron 2 docentes.
- Universidad Nacional Autónoma de México (UNAM), nivel superior, 10 docentes.

**Tabla 1.1**

*Análisis de la educación en modalidad presencial transferida a la modalidad en línea.*

Nombre	Características														
	Pre-requisito	Planificación			Consulta		Comunicación					Seguimiento			
	Competencias Digitales	Guía de estudio	Plan de trabajo	Presentación de módulos	Material de estudio	Referencias	Chat	correo	foro	Tablón de profesor	Grupos de trabajo	Asistencia	Rendimiento	Apoyo	
 Superior				✓				✓				✓	✓*		
 Posgrado					✓	✓	✓	✓	✓	✓	✓				
 Superior			✓			✓							✓		
 Posgrado			✓	✓	✓	✓						✓	✓	✓	
 Superior			✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	

*Fuente: Elaboración propia adaptada de Barberá 2008.*

### 1.2.3. Caso 2. Instituciones Modalidad en Línea antes de la Pandemia.

Estudio realizado a 2 Instituciones de Estudios Superior públicas con experiencia en la modalidad en línea se muestra en la Tabla 1.2.

- Instituto de Estudios Superiores Rosario Castellanos (IESRC), nivel superior, se analizaron 28 docentes,
- Instituto Politécnico Nacional (IPN), nivel superior se analizaron 20 docentes.

**Tabla 1.2**

*Análisis de Instituciones de Estudios Superior de Modalidad en Línea antes de la Pandemia.*

Nombre	Características													
	Pre-requisito	Planificación			Consulta		Comunicación					Seguimiento		
	Competencias Digitales	Guía de estudio	Plan de trabajo	Presentación de módulos	Material de estudio	Referencias	Chat	correo	foro	Tablón de profesor	Grupos de trabajo	Asistencia	Rendimiento	Apoyo
 Superior	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓*	✓
 Superior	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓

Fuente: Elaboración propia adaptada de Barberá 2008.

### 1.2.4. Caso 3. Microsoft México, Nivel Superior en Modalidad en Línea.

La Tabla 1.3., muestra el estudio de Microsoft México que proporcionó cursos de programación en línea a estudiantes de nivel superior de diferentes carreras, se analizaron 3 docentes.

**Tabla 1.3**

*Análisis de Microsoft México en modalidad en línea.*

Nombre	Características													
	Pre-requisito	Planificación			Consulta		Comunicación					Seguimiento		
	Competencias Digitales	Guía de estudio	Plan de trabajo	Presentación de módulos	Material de estudio	Referencias	Chat	correo	foro	Tablón de profesor	Grupos de trabajo	Asistencia	Rendimiento	Apoyo
 Superior	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓

Fuente: Elaboración propia adaptada de Barberá 2008.

### 1.2.4.1. Recogida y Análisis de Datos

El estudio analiza el ciclo escolar 2020-2021 recopilando datos respecto a cómo el docente integra las tecnologías para lograr las competencias digitales en las siguientes áreas:

Área 1. Conocimiento de las Competencias Digitales del Docente.

Área 2. Comunicación y colaboración.

Área 3. Crear contenidos digitales

Área 4. Seguridad

Área 5. Solución de problemas.

Área 6. Usos y aplicaciones.

La observación de las clases permitió indagar sobre el uso y dominio de los recursos tecnológicos utilizados, las actividades de enseñanza y aprendizaje que incorporan los docentes, ¿cómo motivan la participación de los estudiantes?, ¿cuáles son las situaciones innovadoras que incorporan? ¿Cómo evalúan el progreso del aprendizaje de los estudiantes? y ¿cuáles son los controles para detectar que un estudiante tiene alta probabilidad de reprobar o deserción del curso? Los resultados detallados del análisis cualitativo se muestran en el Capítulo 8. Resultados de la Investigación.

### 1.2.5. Método Cuantitativo

La segunda vertiente utiliza el enfoque cuantitativo para explorar como afrontaron los estudiantes de nivel superior la educación en línea durante el ciclo escolar 2020-2021.

De acuerdo con M. A. Rothery (citado por Grinnell, 1997), para generar conocimiento el enfoque cuantitativo se fundamenta en el método hipotético-deductivo, considerando las siguientes premisas:

- Se delinearón las teorías y de ellas se plantean las hipótesis.
- Las hipótesis se someten a prueba utilizando los diseños de investigación apropiados, de acuerdo con la metodología de investigación de Hernández et. Al (2014).
- Si los resultados corroboran las hipótesis, se aporta evidencia a su favor, si se refutan, se descartan en busca de mejores hipótesis.

Los estudios cuantitativos se asocian con los experimentos, las encuestas con preguntas cerradas o los estudios que emplean instrumentos de medición estandarizados.

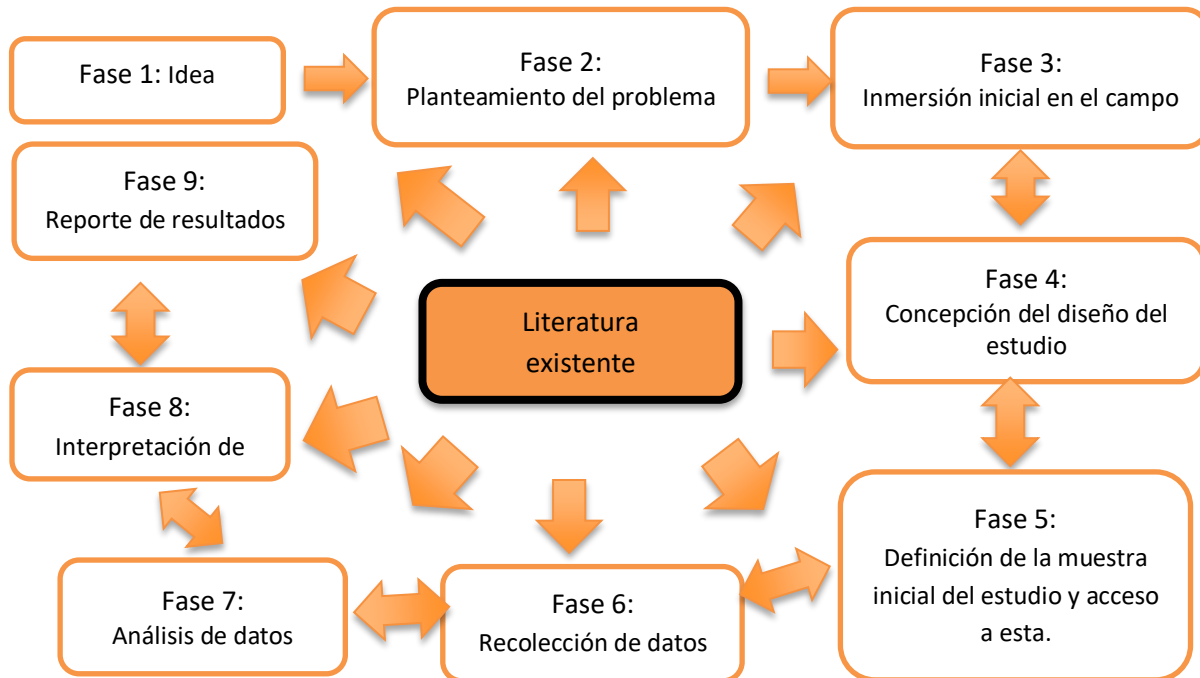
### 1.2.5.1. Etapas del Diseño de la Investigación

Según Kerlinger y Lee (2002) citado por Hernández (2014), los criterios para plantear un problema de este caso, son:

- El problema debe expresar una relación entre dos o más conceptos o variables (características, atributos de personas, fenómenos, organismos, materiales, eventos, hechos, sistemas, etc.) pueden ser medidos con puntuaciones numéricas).
- El problema debe estar formulado como pregunta, claramente y sin ambigüedades; por ejemplo: ¿qué efecto?, ¿en qué condiciones?, ¿cuál es la probabilidad de...? y ¿cómo se relaciona con...?

La metodología de la investigación cuantitativa de acuerdo con Hernández (2014) considera las fases mostradas en la Figura 1.1.

**Figura 1.1**  
*Metodología de la Investigación Cuantitativa*



Fuente: Hernández, Fernández y Baptista, 2014: 7.

### 1.2.6. Fase 1. Conceptualización de la Idea.

La investigación surge ante la incertidumbre durante la pandemia y el cambio abrupto en la educación presencial a la modalidad en línea, la adaptación por parte de docentes como alumnos, no era solamente cambiar el pizarrón por la computadora, además existió resiliencia a la educación en línea, en la que muchos estudiantes ante la propuesta del cierre de escuelas prefirieron no dar continuidad a su educación, tal vez por recursos, por falta de capacitación,

competencias digitales o simplemente no fue de su interés la propuesta de estudiar a través de una computadora e internet; situación que incrementó la deserción escolar.

En palabras de Alemany-Arrebola et. al (2020), la autoeficacia académica se relacionó con el rendimiento e influyó indirectamente en las aspiraciones académicas (Ahmadi, 2020). Además, el estrés generado por el contexto académico (sobrecarga de tareas, presión por el trabajo, evaluaciones frecuentes, situación de pandemia, entre otros) podría disminuir las expectativas de autoeficacia.

### 1.2.7. Fase 2: Planteamiento del Problema.

Ante el escenario descrito los estudiantes que fueron transferidos de la educación presencial a la modalidad en línea presentaron menor dominio en las competencias digitales y en la resolución de conflictos técnicos durante las clases en línea, además de muchos otros factores como estrés, ansiedad, angustia, desempleo, sobre carga de material, factores de salud, socio económicos, de agresión familiar, ausencia de un espacio privado para tomar las clases en línea, y por supuesto el no contar con el equipo tecnológico que de un día a otro era necesario para dar continuidad a la educación.

El cúmulo de factores presentados durante la pandemia incrementó la deserción escolar lo cual repercute en el crecimiento y desarrollo económico del país y principalmente en la



economía de cada persona, limitándola a mejores oportunidades, por lo que resulta imprescindible la definición de estrategias que permitan, en la medida de lo posible, reducir la deserción escolar y fortalecer el aprendizaje mediante el uso de la tecnología.

### 1.2.8. Fase 3: Inmersión Inicial en el Campo.

En el conversatorio “Transformación digital de la educación superior para contribuir en la disminución del abandono escolar” efectuado el 6 de noviembre de 2020, la titular de la Secretaría de Educación, Ciencia, Tecnología e Innovación (SECTEI) en México, la doctora Rosaura Ruiz Gutiérrez y un grupo de expertos de escuelas públicas y privadas analizaron las condiciones y factores en torno a la deserción escolar y establecieron que la mayoría de los estudiantes de todos los niveles no tienen las condiciones para convertirse en alumnos en línea, y externaron su preocupación pues, según cifras oficiales en educación superior, se registran 245 mil jóvenes por deserción escolar.

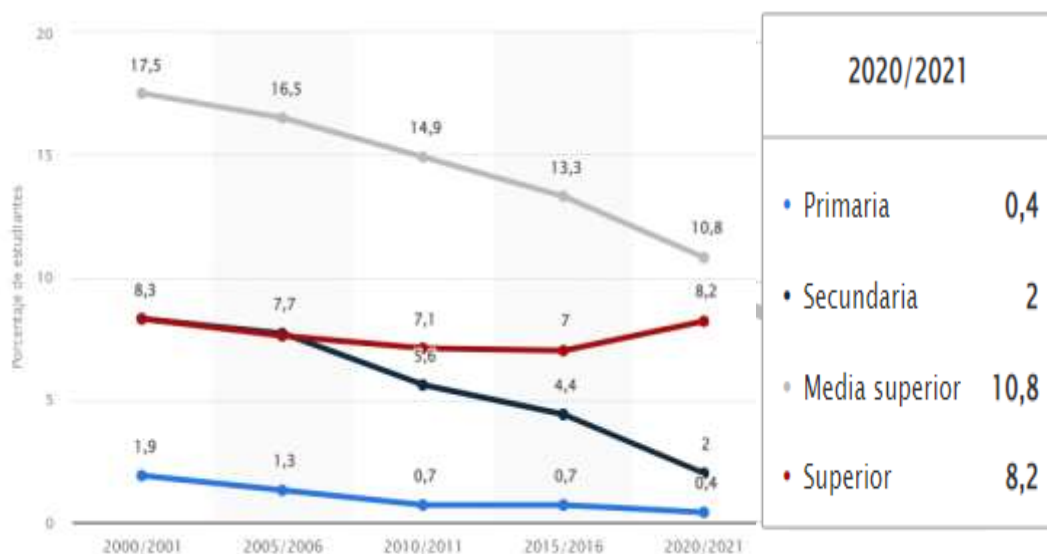
El Dr. Eduardo Peñalosa Castro, rector general de la Universidad Autónoma Metropolitana (2021) y coordinador del grupo de Innovación Educativa de la Red, externó que el abandono escolar es un proceso generado por causas vinculadas a la integración social y académica, así como a razones familiares, personales, emocionales y económicas, subrayó que la transformación digital en educación superior es un proceso complejo que puede contribuir de manera significativa a contrarrestar la deserción.

En el mismo evento, el doctor Jorge Toro González, secretario académico del Instituto Politécnico Nacional (IPN), detalló que se trata de un fenómeno multifactorial con orígenes de índole económico, familiar y emocional, reafirmando que de acuerdo a la Secretaría de Educación Pública (SEP), este fenómeno en el nivel superior alcanza el 7% de una matrícula conformada por tres millones y medio, lo que equivale a 245 mil jóvenes desertores; puntualizó que la deserción virtual, se debe principalmente a falta de insumos tecnológicos, como computadoras e internet.

Hilda Patiño Domínguez, directora del Departamento de Educación de la Universidad Iberoamericana, citó que en posgrado hubo una baja del 30 por ciento por temas económicos, identificando además en el nivel superior una tasa de abandono del 8.2% durante el ciclo escolar 2020-2021, presentado en la Figura 1.2.

**Figura 1.2**

*Tasa de abandono escolar durante el ciclo 2020-2021 por nivel educativo*



Fuente: Statista 2022

### 1.2.9. Fase 4: Concepción del Diseño del Estudio.

#### 1.2.9.1. Objetivo:

El objetivo es identificar los factores que impactan en el aprendizaje de los estudiantes en línea a nivel superior durante el ciclo escolar 2020-2021 y proponer un modelo de Inteligencia Artificial como medida predictiva para fortalecer las competencias digitales.

#### Objetivos específicos:

- Identificar los factores que impactan en el aprendizaje de los estudiantes en modalidad en línea a nivel superior.
- Evaluar las competencias digitales para diseñar un modelo de IA, que mejore el conocimiento.

#### 1.2.9.2. Preguntas de Investigación

- ¿Es posible identificar los factores que impactan en el aprendizaje de los estudiantes en e-learning (modalidad en línea) de nivel superior?
- ¿Es posible evaluar las competencias digitales a través de un modelo de Inteligencia Artificial para mejorar el aprendizaje?

#### 1.2.9.3. Hipótesis

##### **Hipótesis General:**

Si nuestra misión es identificar los factores que impactan en el aprendizaje de los estudiantes en línea a nivel superior, entonces resulta viable diseñar un modelo adaptativo que fortalezca sus competencias digitales mediante el uso de Inteligencia Artificial.

### Hipótesis específicas:


- Si identificamos los factores que impactan en el aprendizaje de los estudiantes en el e-learning (modalidad en línea) de nivel superior podemos definir estrategias que mejoren su aprovechamiento.
- Si evaluamos las competencias digitales es posible diseñar un modelo de IA que incremente su conocimiento.

### Variables:

La identificación de variables nos permite establecer la relación que existe entre la causa y el efecto de la investigación, como se muestra en la Figura 1.3.

**Figura 1.3**

*Esquema de experimentos y variables*



### 1.2.10. Fase 5. Definición de la Muestra Inicial del Estudio.

Se elabora y aplica el instrumento de medición a 258 estudiantes de nivel superior que tomaron clases en línea en la pandemia, la cual incluye 19 preguntas divididas en 3 ejes: Trayectoria Escolar, Actitud en las Clases en Línea y Percepción del Aprendizaje en Línea. El

objetivo es identificar el aprovechamiento de los estudiantes de nivel superior en este periodo bajo la modalidad en línea.

### 1.2.11. Fase 6. Recolección de Datos.

En esta fase se analizan los diferentes recursos para aplicar el instrumento de medición seleccionado, en la actualidad y dado el distanciamiento social, las encuestas en línea ofrecen una gran alternativa en tiempo y recursos. Existen diversos proveedores del servicio tanto gratuitos como de paga como son Microsoft Forms, Google Forms, Survey Monkey, Zoho Survey, .Typeform, Polldaddy, Survey Planet, Eval & Go y QuestionPro. Solamente hay que crear la cuenta y verificar el rango de encuestados que ofrece gratuitamente por que en algunos casos, una vez desarrollada la encuesta te solicita subir el nivel para aplicarla y entonces genera un costo o solicita que cedas los derechos de la información, lo que imposibilita el uso de la información obtenida por el investigador o creador de la encuesta.

### 1.2.12. Fase 7. Análisis de Datos.

Posterior a la recolección de los datos es necesario realizar un análisis de estos y someter los datos a la realización de operaciones, esto se hace con la finalidad de obtener conclusiones precisas que nos ayudarán a alcanzar nuestros objetivos, dichas operaciones no pueden definirse previamente ya que la recolección de datos puede revelar ciertas dificultades.

Para analizar los datos, en los métodos mixtos según Hernández-Sampieri y Mendoza, C. (2018, p. 657), el investigador confía en los procedimientos estandarizados y cuantitativos

(estadística descriptiva e inferencial), así como en los cualitativos (codificación y evaluación temática), además de análisis combinados. La selección de técnicas y modelos de análisis también se relaciona con el planteamiento del problema, el tipo de diseño y estrategias elegidas para los procedimientos; y tal como hemos comentado, el análisis puede ser sobre los datos originales (datos directos) o puede requerir de su transformación. La diversidad de posibilidades de análisis es considerable en los métodos mixtos, además de las opciones conocidas que ofrecen la estadística y el análisis temático.

### 1.2.13. Fase 8. Interpretación de Datos.

La interpretación de los datos permite validar que los datos obtenidos mediante el enfoque de investigación mixto (basado en el método cualitativo y cuantitativo), es información utilizable y que los datos se han convertido en información que permitirá la toma de decisiones. En la Tabla 1.4 se presentan algunos ejemplos referidos a los diseños mixtos y su procedimiento de análisis e interpretación de datos.

**Tabla 1.4**

*Ejemplos de análisis e interpretación de los datos.*

Diseños	Ejemplos de procedimientos analíticos
Concurrentes (triangulación, anidados, transformativos)	Cuantificar datos cualitativos: se codifican datos cualitativos, se les asignan números a los códigos y se registra su incidencia o frecuencia (las categorías emergentes se consideran variables o categorías cuantitativas), se efectúa análisis estadístico descriptivo de frecuencias. Asimismo, la presencia de categorías puede establecerse en grados dicotómicos (presencia-ausencia) u ordinales y estas pueden ser analizadas mediante estadística no paramétrica

### Diseños

#### Ejemplos de procedimientos analíticos

(incluso, trabajarse como variables). También se pueden comparar o relacionar los dos conjuntos de datos (cualitativo y cuantitativo).

Cualificar datos cuantitativos: los datos numéricos son examinados y se considera su significado y sentido (lo que nos “dicen”); de este significado se conciben temas que pudieran reflejar tales datos y se visualizan como categorías. Posteriormente, se toman en cuenta para los análisis temáticos y de patrones correspondientes.

Comparar directamente resultados provenientes de la recolección de datos cuantitativos con resultados de la recolección de datos cualitativos (soportar el análisis estadístico de tendencias en los temas cualitativos o viceversa).

Consolidar datos: combinar datos cuantitativos y cualitativos para formar nuevas variables o conjuntos de datos (por ejemplo, comparar las variables cuantitativas originales con los temas cualitativos y así generar nuevas variables cuantitativas).

Crear una matriz: combinar datos cuantitativos y cualitativos en una misma matriz. Los ejes horizontales pueden ser variables cuantitativas categóricas [por ejemplo, en una investigación sobre el cuidado que se brinda a los pacientes en un hospital: proveedor del servicio (variable): medico, enfermera, administrativo, asistente medico (categorías)]; y los ejes verticales, categorías o temas emergentes sobre dicho cuidado —CUAL— (por ejemplo: empatía, compasión, interés por el paciente, trato humanitario, etc.). La información en las celdas pueden ser tanto pasajes o citas como códigos de categorías (CUAL) y se puede agregar la frecuencia de incidencia de los códigos (CUAN). La matriz combina datos cualitativos y cuantitativos, y pueden usarse diferentes programas para el análisis (por ejemplo, interfaces de servicio en línea como Atlas.ti® y SPSS®). También, matrices con variables cuantitativas y categorías cualitativas cuantificadas (transformadas a variables nominales u ordinales).

#### Secuenciales (exploratorio, explicativo, transformativos)

Explicar resultados (profundizar): llevar a cabo una encuesta (CUAN) y efectuar comparaciones entre grupos de la muestra; y posteriormente conducir entrevistas para explorar las razones de las diferencias o no diferencias encontradas entre estos.

Desarrollo de tipologías: el análisis de un tipo de datos produce una tipología (un conjunto de categorías sustantivas), que luego es usada como marco de referencia para aplicarlo en el análisis de contraste de datos. Por ejemplo, realizar una encuesta (CUAN) y generar dimensiones mediante el análisis de factores, las cuales se utilizan como tipologías para identificar temas en datos cualitativos producto, digamos, de observaciones y entrevistas.

Localizar instrumentos de recolección de los datos: recolectar datos cualitativos e identificar temas y categorías. Posteriormente, estas se usan como base para ubicar instrumentos estandarizados que contienen conceptos o variables paralelas a las categorías cualitativas.

Formar datos categóricos: situar y contextualizar características obtenidas en una inducción etnográfica (por ejemplo, grupo étnico, ocupación, etc.) y estas se convierten en variables categóricas durante una fase cuantitativa posterior.

Examinar multiniveles secuencialmente. Por ejemplo, para analizar el involucramiento e identificación por parte de estudiantes con su universidad: efectuar una encuesta (CUAN) con ellos, reunir datos CUAL mediante grupos de enfoque al nivel de la clase, analizar indicadores CUAN al nivel de la escuela y recolectar datos cualitativos mediante entrevistas con directivos. Los resultados obtenidos de un nivel nos ayudan a desarrollar la recolección y análisis del siguiente.

Analizar casos extremos: los casos de este tipo identificados a través de una clase de análisis (CUAN o CUAL) son vueltos a analizar vía el otro método (CUAL o CUAN) con la finalidad de profundizar la explicación inicial de estos, e incluso pueden recolectarse datos adicionales para refinar el análisis. Por ejemplo, los casos que son extremos en un análisis cualitativo comparativo se agrupan y se les efectúan mediciones para ahondar en las diferencias.

Fuente: Adaptado de Hernández-Sampieri y Mendoza, C. (2018). Metodología de la investigación. Las rutas cuantitativa, cualitativa y Mixta, pp. 657-658.

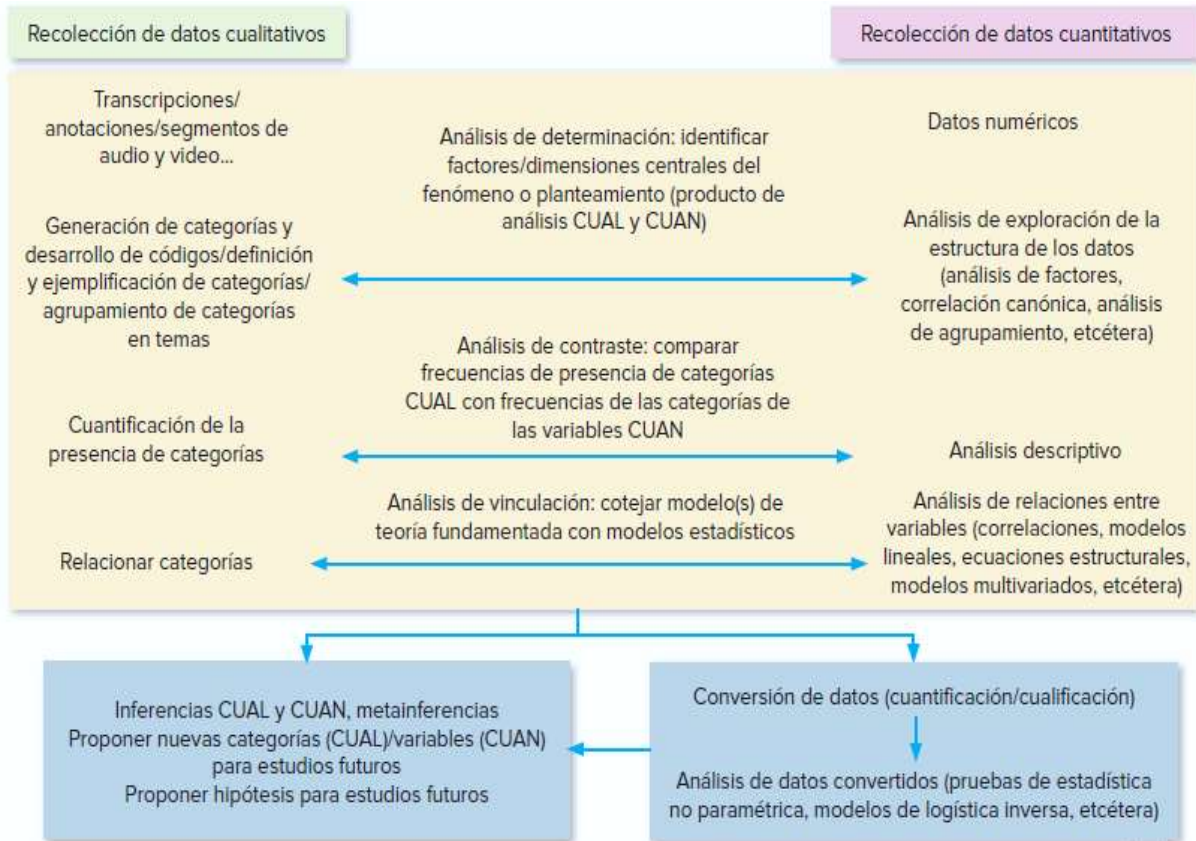
### Fase 9. Reporte de Resultados.

De acuerdo con Hernández-Sampieri y Mendoza, C. (2018) citan a Tashakkori y Teddlie (2008b), señalando que las inferencias deben alcanzar consistencia interpretativa congruencia entre sí y entre estas y los resultados del análisis de los datos. Un ejemplo de inconsistencia en la parte cuantitativa sería inferir causalidad sobre la base de resultados únicamente correlacionales; o bien, para la vertiente cualitativa, inferir que una categoría es la central en un esquema de teoría fundamentada, cuando no resultó que era la que más se vinculaba al resto de categorías. Las inferencias tendrán que ser congruentes con el tipo de evidencia presentado, y el nivel de intensidad reportado debe corresponder con la magnitud de los eventos o los efectos descubiertos, en la Figura 1.4 se muestra la secuencia habitual de análisis de estudios mixtos para la obtención y presentación de resultados.



**Figura 1.4**

*Secuencia habitual de análisis en investigaciones mixtas*



Fuente: Hernández-Sampieri y Mendoza, C. (2018), citado por Hernández-Sampieri y Mendoza (2012) con ideas de Lieber y Weisner (2010) y Onswuegbuzie y Combs (2010).

La metodología empleada se lleva a cabo a través del método mixto, representado por un conjunto de procesos sistemáticos, empíricos y críticos de investigación e implica la recolección y el análisis de datos cualitativos y cuantitativos, así como su integración y discusión conjunta, para realizar inferencias producto de toda la información recabada (metainferencias) y lograr un mayor entendimiento del fenómeno bajo estudio (Hernández Sampieri et al., 2014). Se ha dejado planteado el enfoque cualitativo y cuantitativo que fundamenta la hipótesis producto de este trabajo, definiendo además los métodos de

recolección de datos para el análisis y la obtención de conocimiento nuevo. Seguidamente estos saberes serán integrados en el capítulo 8 Resultados. Estos datos, ya evaluados proporcionarán certidumbre a la conjunción del marco metodológico, contextual, y teórico.

La propuesta de investigación descrita en este apartado, permite plantear las inquietudes, observaciones y preguntas de forma estructurada, convirtiéndose en la esencia del desarrollo de la investigación y dando apertura al estado del arte presentado en el siguiente apartado.



## Capítulo 2 **Inteligencia Artificial**

## Capítulo 2 Inteligencia Artificial

### 2. Inteligencia Artificial

#### 2.1 La concepción de la Inteligencia Artificial

La Inteligencia Artificial (IA) ha tomado gran relevancia en las últimas décadas, si bien su aceptación ha sido difícil, por la concepción que implica y la resiliencia a la sustitución de tareas propias del ser humano, González, M., y Martínez, D. (2020) refieren dilemas éticos en la manipulación de los datos y riesgos políticos derivados de usos mal intencionados, aun cuando sus aportaciones han sido de gran utilidad, esta se relaciona con el análisis y diseño de sistemas artificiales autónomos capaces de exhibir un comportamiento inteligente. Se asume que, para que un agente actúe inteligentemente, debe poder percibir su entorno, determinar y consecuentemente planificar y actuar hacia la consecución de estos; aplicando algún principio de racionalidad e interactuar con otros agentes inteligentes, sean estos artificiales o humanos. Palma, J. T., y Marín, R., (2008, p. 3) consideran que los objetivos de la IA son: modelar, formalizar, programar e implementar máquinas soporte capaz de interactuar de forma no trivial con el medio.

Con el paso del tiempo se ha incrementado la necesidad de utilizar sistemas inteligentes, vivimos en un mundo interconectado de información y su crecimiento conlleva a la demanda de un mejor rendimiento, resolución de problemas complejos y entendimiento del comportamiento de datos masivos.

En consecuencia y dada la presentación de problemas complejos, es pertinente cuestionar ¿cómo determinar que un problema es complejo? y ¿por qué su solución debe de exigir

procesamiento simbólico? Palma, J. T., y Marín, R., (2008, p. 4) consideran dos de las formas posibles de contestar a esta pregunta y han dado lugar a las dos aproximaciones dominantes en IA: es simbólica o representacional y la del conexionismo situado. La primera hace énfasis en la vía descendente y en el uso de conceptos del lenguaje natural (hechos y reglas) para representar el conocimiento necesario para resolver problemas de decisión que no necesitan un robot como componente imprescindible en su implementación. La segunda considera la vía ascendente y el uso de conceptos de más bajo nivel semántico.

Alonso et al. (2004) señala que cada vez son más fuertes las restricciones temporales impuestas en la toma de decisiones, y el conocimiento se ha convertido en un recurso estratégico importante para ayudar a los humanos a manejar la complejidad de la información.

En el mundo de los negocios, se necesitan sistemas inteligentes para gestionar competidores, mercados y clientes. En el campo de la fabricación, los sistemas inteligentes se necesitan para la optimización de los procesos y sistemas relacionados con la monitorización, control, diagnóstico y reparación de problemas. En el sector educativo, permiten el desarrollo de modelos predictivos. En la salud durante la pandemia fueron de gran utilidad en la determinación de contagios, analizando millones de datos y con una precisión mayor en los resultados que los del ser humano y son muchos más los campos de aplicación, algunos de los cuales se detallarán más adelante. Dadas las aportaciones que considera, conocer la evolución de la IA resulta interesante por el entendimiento y abstracción que tuvieron durante esas épocas los iniciadores.

### 2.2 Historia de la Inteligencia Artificial

La tecnología avanza cada vez más rápido y en la actualidad son menos asombrosos los descubrimientos, dado que forma parte de nuestra cotidianidad, las actualizaciones de software, de teléfonos móviles, aparatos inteligentes, y muchos otros más. Los inicios de la IA se remontan a la Edad Media y el Renacimiento, época en la que se desarrollaron autómatas con funcionalidad limitada. Posteriormente, George Boole, a quién debemos el álgebra de Boole, desarrollada en 1854, argumentó que el comportamiento lógico podía ser representado y expresado de forma matemática como un sistema de ecuaciones. Estos argumentos le permitieron ser considerado como el precursor de las ciencias computacionales, sentando las bases del lenguaje informático y la idea de crear máquinas a partir de su capacidad de sintetizar el pensamiento y conducta humana a través de la representación de ecuaciones complejas.

Bajo el enfoque del pensamiento y la conducta humana, Russell concibió la idea de las operaciones mentales, haciendo énfasis en la existencia independiente de seres lógico-matemáticos, y se tiene conocimiento que Piaget, finalmente, es quien propone una teoría del desarrollo cognitivo acreditado sobre las operaciones lógicas del pensamiento en cada etapa evolutiva. Esta conjunción lógica, evolutiva y psicológica, puede ser complementada con el enfoque del procesamiento de la información, sobre la base del manejo de estrategias y el aumento del conocimiento, en conjunto con el auxilio lingüístico para promover la comprensión suficiente de la base lógica y psicológica del pensamiento (Rivero, 2000).

Los antecedentes de los autómatas datan de la edad de piedra cuando los seres humanos diseñaron los primeros dispositivos automáticos como trampas para la caza, las primeras evidencias se encuentran en los sistemas de regadíos de Babilonia por el 2000 a.C. de los cuales conocemos por las leyes grabadas en el código Hammurabi (Brunete et al., 2020).

En Egipto se tiene evidencia de dos estatuas parlantes con mandíbulas móviles usadas en ceremonias religiosas (Moñux, 2001). En Grecia, también se identificaron importantes hallazgos relacionados con los autómatas. Platón (427-347 a.C.) inventó el primer reloj despertador; que producía el sonido, de forma similar al producido por el vapor de agua en las teteras (Brunete et al., 2020).

China se posicionó con el desarrollo de autómatas, uno de los más importantes fue el llamado Didong Yi, elaborado en el siglo II por Zhang Heng, desarrolló un detector que señalaba la dirección del epicentro, su funcionamiento tenía un recipiente en el cual en la parte superior había ocho salidas con forma de dragón, dentro había un péndulo invertido en posición vertical. Cuando había una onda sísmica la punta del péndulo era desplazada y accionaba uno de los ocho deslizantes que a su vez desplazaba una bola, la cual caía por defecto de la gravedad, según por donde había salido la bola (uno de los 8 caminos) se detectaba la dirección del epicentro (Escrig, 2014).

En el siglo XVIII el mundo de los autómatas se emancipa por completo del ambiente preferentemente cortesano en el que hasta entonces se había desenvuelto. Los nombres de

constructores como Vaucanson o los Jaquet-Droz son los centrales y fueron reconocidos por la construcción de autómatas. Ellos elevaron la idea de la construcción de autómatas al nivel de una “técnica biomecánica” (Leiva, 2017).

En 1818 se publicó “Frankenstein o el moderno Prometeo”, de Mary Shelley, simulando al ser humano y a mediados del siglo XX se presentaron las primeras computadoras electrónicas y la posibilidad de construir máquinas pensantes. En 1921, surge la idea de un robot, siendo el creador el dramaturgo Karek Apek sería el primero en utilizar a un Robot en su obra de teatro R.U.R. (palabra de origen eslavo “trabajo duro”).

Durante 1941 Isaac Asimov escribió el cuento “Círculo Vicioso”, en él dejaría un legado para la literatura y para la nueva ciencia de la informática, a partir de esta obra nacerían las leyes de la robótica. Mientras que, en la cibernética, se estudió la comunicación y el control, tanto en animales como en máquinas. Durante 1943, Julian Bigelow, Wiener y Arturo Rosenblueth escribieron el ensayo “Comportamiento, Propósito y Teleología”, este documento fue considerado como el primer documento de la cibernética.

### 2.3 La Prueba de Turing

En la Segunda Guerra Mundial, el británico Alan Turing pasó a la historia por haber definido funciones computables que descifraban a las máquinas Enigma de los Nazis y en 1950, publicó en la revista Mind (uno de los artículos más relevantes en su carrera) el artículo “Maquinaria computacional e inteligencia”; preguntándose si una máquina podría pensar y



definió lo que se conoce como la Prueba de Turing, basada en el juego de la imitación. Esta prueba consiste en que la máquina imita el comportamiento del humano a una serie de preguntas, siendo el evaluador el responsable de identificar si las respuestas corresponden al humano o a la máquina. La conversación se limitaría a un canal de solo texto, utilizando un teclado y una pantalla de computadora, como se muestra en la Figura 2.1.

**Figura 2.1**

*La Prueba de Turing*



Nota: Adaptado de Inteligencia Artificial por Álvarez Cruz, L. P. (2008). Revista de Información, Tecnología y Sociedad. No. 54.

En 1936, Alan Turing publicó un artículo en el que introdujo por primera vez el concepto de “algoritmo”, para la actualidad resulta un tema común en análisis de procesos, programación y muchas áreas que incorporan el término para el desarrollo de actividades, pero hace casi 100 años, era realmente una estructuración increíble. Posteriormente, en 1950 (Ángel, 2012), publica el artículo “Computing Machinery and Intelligence” en el cual describe como las computadoras pueden o no pensar o comportarse como un cerebro humano.

### 2.3.1. La Inteligencia Artificial y su comportamiento

Durante 1943 McCulloch y Pitts desarrollaron el llamado conexionismo, que propone que las acciones de la mente y del comportamiento surgen de redes formadas por unidades que están interconectadas, continuando con la abstracción de neuronas y eso llevó a lo que se conoció como “redes neuronales”. El término de IA fue acuñado por el informático John McCarthy en el año de 1956, definido como la ciencia y la ingeniería de hacer máquinas inteligentes. Las aplicaciones de IA en esta época se hicieron al razonamiento automatizado, prueba de teoremas, juegos, procesamiento de lenguaje natural y algunos robots. El enfoque dado a la IA descritas por Russell et. al (2004) son presentadas en la Tabla 2.1

**Tabla 2.1**

*Enfoques de la Inteligencia Artificial*

Enfoque	Definición
<b>Sistemas que piensan como humanos</b>	El nuevo y excitante esfuerzo de hacer que los computadores piensen, máquinas con mentes, en el más amplio sentido literal. (Haugeland, 1985).
	La automatización de actividades que vinculamos con procesos de pensamiento humano, actividades como la toma de decisiones, resolución de problemas y aprendizaje. (Bellman, 1978).
<b>Sistemas que actúan como humanos</b>	El arte de desarrollar máquinas con capacidad para realizar funciones que cuando son realizadas por personas requieren de inteligencia. (Kurzweil, 1990).
	El estudio de cómo lograr que los computadores realicen tareas que, por el momento, los humanos hacen mejor. (Rich y Knight, 1991).
<b>Sistemas que piensan racionalmente</b>	El estudio de las facultades mentales mediante el uso de modelos computacionales. (Charniak y McDermott, 1985).
	El estudio de los cálculos que hacen posible percibir, razonar y actuar. (Winston, 1992).

Enfoque	Definición
<b>Sistemas que actúan racionalmente</b>	La Inteligencia Computacional es el estudio del diseño de agentes inteligentes. (Poole et al., 1998). IA está relacionada con conductas inteligentes en artefactos. (Nilsson, 1998).

Nota: Adaptado de Inteligencia artificial escrito por Russell, S. J., Norvig, P., y Rodríguez, J. M. C. (2004). Pearson Educación.

### 2.3.2. Sistemas basados en el comportamiento

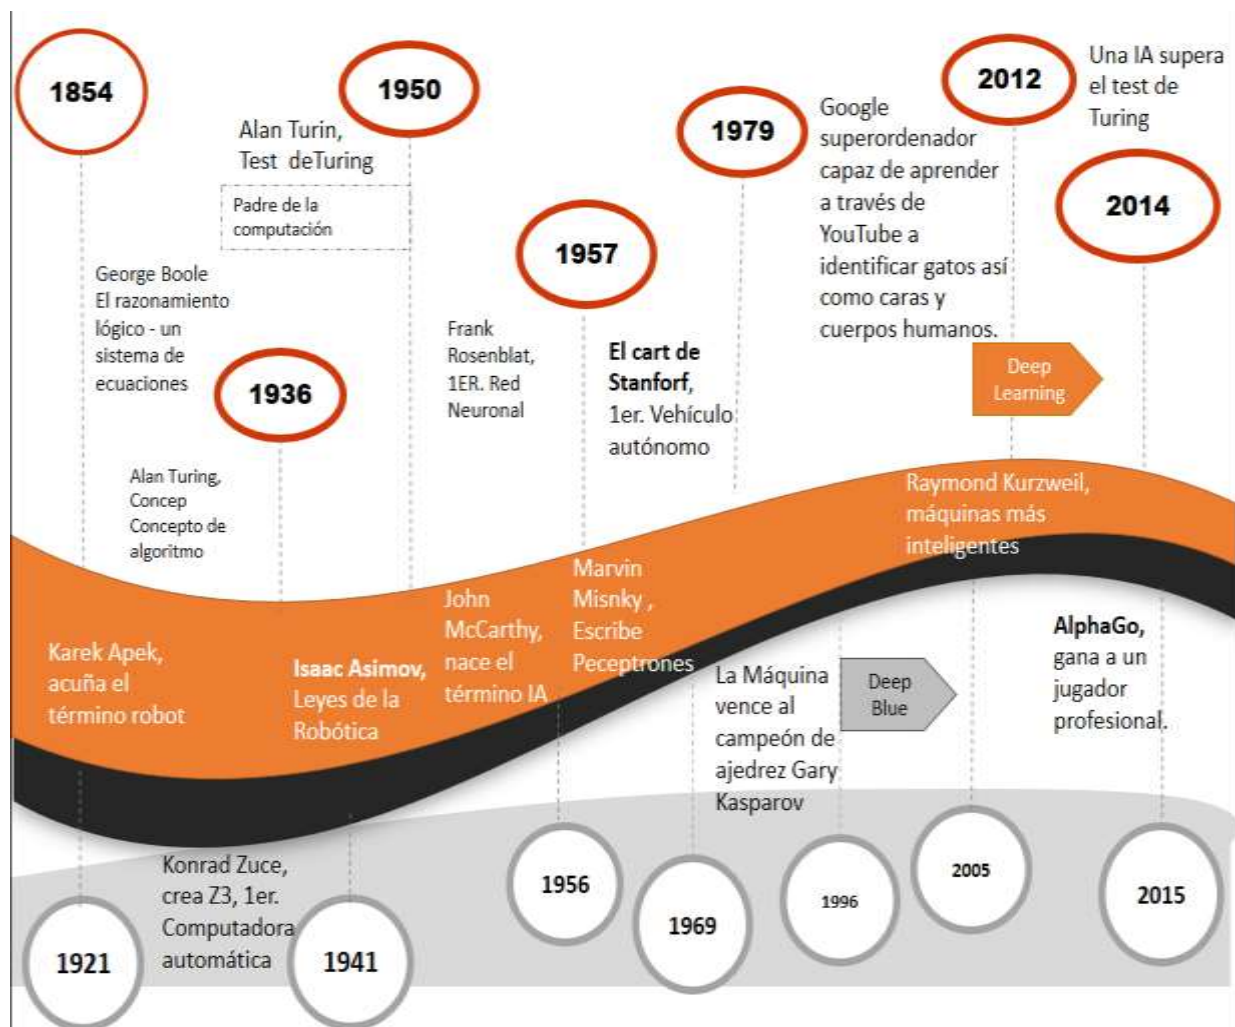
A mediados de los años 70's existieron muchas expectativas en torno a la IA, pero como no fueron cumplidas, se le conoció este tiempo como el "invierno de la IA", y se caracterizó por la reducción de fondos. Se dio inicio a la traducción de lenguajes, presentando grandes fallas.

En 1979 como menciona Mondragón (2021), el Cart de Stanford se convirtió en el precursor de los vehículos autónomos y en 1996 el programa Deep Blue de IBM logró vencer al entonces campeón mundial de ajedrez.

Durante 1982, Japón lanzó el proyecto de la "Quinta generación", implicó el desarrollo de sistemas expertos con diversas aplicaciones en varios sectores, como en el área médica, por ejemplo. Por otro lado, a finales de los 80's David Rumelhart, James McClelland y John Hopfield revivieron el conexionismo y se dieron algunos avances en redes neuronales artificiales. Asimismo, Rodney Brooks, entonces futuro director del Laboratorio de IA en MIT, desarrolló una nueva IA con sistemas basados en el comportamiento, a diferencia de los basados en el conocimiento.

En los 90's, tanto en la IA clásica, basada en la manipulación de símbolos, como en los nuevos sistemas basados en el comportamiento, se propuso el concepto de agente inteligente adaptativo y autónomo. Un agente es una entidad que puede actuar en su entorno, los agentes inteligentes son guiados por reglas. La síntesis de su evolución se presenta en la Figura 2.2.

**Figura 2.2**  
*Evolución de la Inteligencia Artificial*



### 2.4 Los Métodos Inductivo y Sintético.

Mediante la observación de los fenómenos y la implementación de métodos que permiten su explicación la ciencia ha desarrollado diferentes técnicas en este apartado abordaremos el inductivo y sintético.

#### 2.4.1. Método inductivo

El método inductivo se caracteriza por la observación de hechos, a partir de los cuales se hace una generalización o abstracción; y con esto, se genera una teoría, que permite hacer predicciones, y observaciones para validarla o invalidarla. En contraste, la IA utiliza el método sintético; también existen métodos para explicar la psicología humana a través de métodos computacionales, pero en este capítulo se detalla principalmente el método sintético.

#### 2.4.2. Método sintético

Para tener una mejor idea del método sintético, se basa en observaciones de un fenómeno natural que, a través de la abstracción o generalización, mismas que conducen a una teoría; con esta, se construye un sistema artificial mediante la ingeniería. Este sistema artificial produce cierto comportamiento, que se debe observar para medir su desempeño posteriormente, lo que conduce a validar o invalidar la teoría presentada en la Figura 2.3.

**Figura 2.3**

*Métodos Inductivo y Sintético*



La construcción de la inteligencia natural está basada en el método inductivo y la IA tiene su fundamento en el método sintético, algunas de sus características se describen en la Figura 2.4. Tipo de Inteligencia y su método.

**Figura 2.4**

*Tipo de inteligencia y su método*



### 2.5 Predicción y adaptación

En la actualidad se generan grandes volúmenes de datos, lo que se conoce como Big Data, estos datos son analizados de forma masiva por desarrollos tecnológicos de IA, que permiten crear sistemas inteligentes e independientes que simulan capacidades y funciones de las personas.

En opinión del autor de este trabajo, la evolución y la transformación tecnológica requieren del ser humano una adaptación, es decir modificar su comportamiento ante algún evento, proceso o sistema. La UNAM (2020) considera que, si el cambio de comportamiento perjudica al sistema, sería una mala adaptación; pero normalmente se busca que el cambio sea en beneficio del sistema y que le permita alcanzar sus metas. Según González, R. y Tobar, F., (2018) la IA pretende una adaptación basada en el método.

La IA débil se ha traslapado con la fuerte, gracias al aprendizaje de máquinas y su trabajo, y que como Turing lo pondría, resulta cuestionable, desde un punto de vista práctico, negar inteligencia y estados mentales a algoritmos capaces de aprender y reemplazar al ser humano sintético, en respuesta a los fenómenos presentados creando modelos del mismo nombre.

En la medida que el mundo evoluciona, se presenta una adaptación o en algunos casos es posible predecir ciertos eventos. La Figura 2.5 esquematiza los procesos de predicción y adaptación. La predicción es similar, en el sentido que también se usa para alcanzar las metas

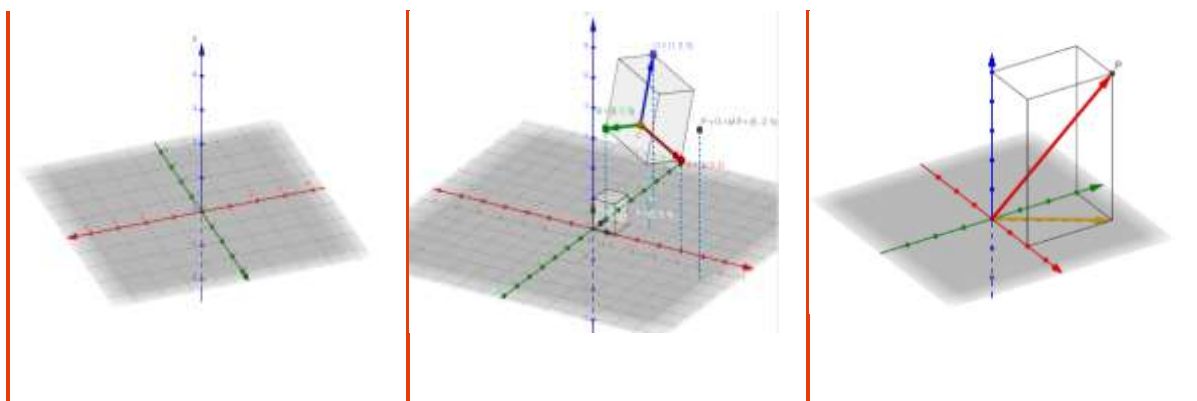
de un sistema; sin embargo, se busca que el cambio de comportamiento se dé antes de que se presente una perturbación.

**Figura 2.5**  
*Procesos de Predicción y Adaptación*



Existen diversas maneras de formalizar las metas de un sistema; la Figura 2.6 representa un ejemplo usando un espacio de parámetros, considerando todas las variables relevantes como una dimensión cartesiana, y observando la relación que tienen las entradas con las salidas.

**Figura 2.6**  
*Formalización de las metas de un sistema*



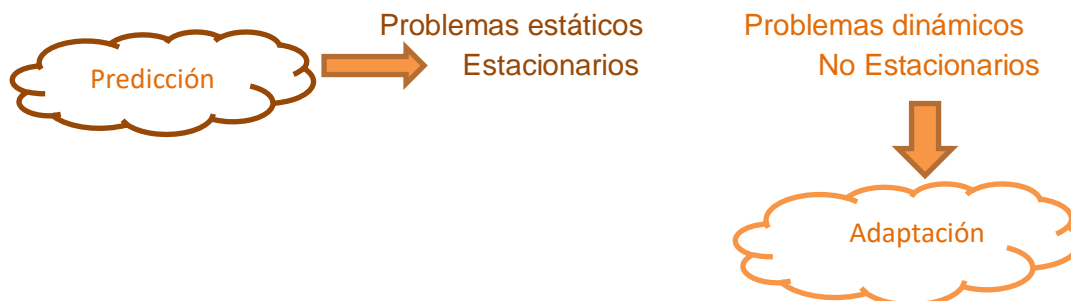
Nota: Imágenes tomadas de Geogebra



Evidentemente la base de todos estos desarrollos son las matemáticas. En problemas de optimización, el objetivo es encontrar el mejor valor entre todos los parámetros, que produzca valores máximos o mínimos de una o más variables de salida, en función de las variables de entrada. Por ejemplo, si tenemos dos variables X, Y de entrada y una de salida, de tal manera que Z es igual a una función de X y de Y, podemos representar su relación en tres dimensiones: X, Y Z. (conocido como "Paisaje de aptitud"), en este escenario podemos encontrar picos y valles, donde la altura de cada conjunto de coordenadas de entrada nos determina qué tan buena es la salida y, para resolver un problema, sólo tenemos que encontrar el valor óptimo de las variables de entrada, de ahí su nombre de problemas de optimización; una vez que se identifica una solución suficientemente buena, es posible predecir qué decisión tomar y en qué momento, para lograr el mejor desempeño posible.

Por otro lado, es importante considerar la dinámica de los problemas, es decir si cambian o permanecen igual; dado un tipo de problema estático o dinámico obtendremos espacios estacionarios o no estacionarios respectivamente como se muestra en la Figura 2.7.

**Figura 2.7**  
*Problemas estáticos y dinámicos*

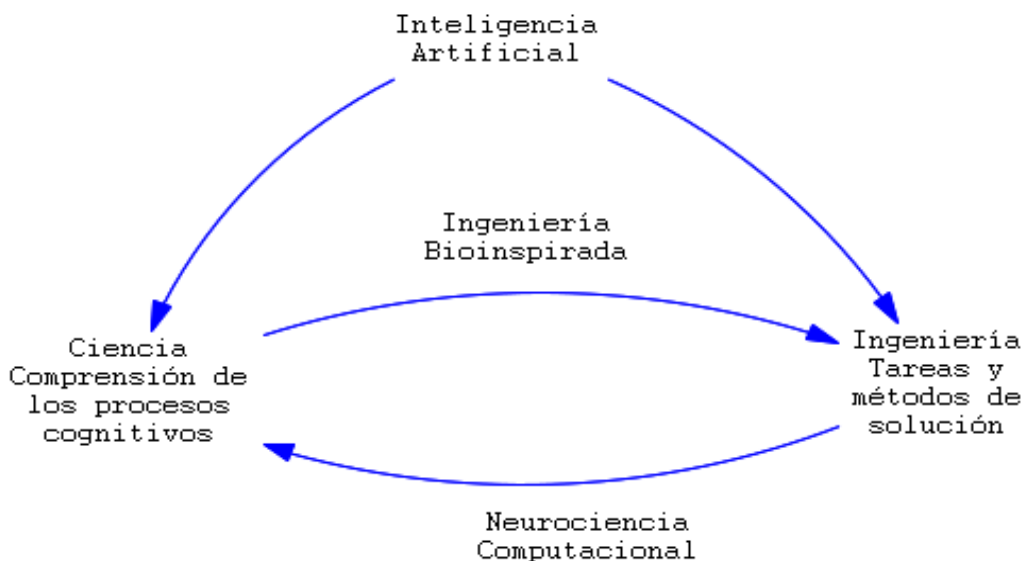


### 2.5.1. Características de la Inteligencia Artificial.

La Inteligencia Artificial es considerada bajo dos perspectivas como Ciencia e Ingeniería, refiere Palma, J. T., y Marín, R. (2008), a fin de no mezclar estos conceptos cognitivos y del lenguaje natural (intención, propósito, ontología, semántica, emoción, memoria, aprendizaje, etc.) con otros computacionales (modelos, inferencias, roles, entidades abstractas y operadores lógico-matemáticos, tablas, autómatas<sup>1</sup>, programas, entre otros); los objetivos que persigue cada una de estas ramas de la IA se describen en la Figura 2.8.

**Figura 2.8**

*Inteligencia Artificial como Ciencia e Inteligencia Artificial como Ingeniería*



Nota. Retomado de Inteligencia Artificial. Técnicas, métodos y aplicaciones, escrito por Palma, J. T., & Marín, R. (2008). McGraw Hill.

<sup>1</sup> La definición de la Real Academia de la Lengua Española de autómatas es: del pl. lat. *autómata*, y este del pl. gr. αὐτόματα *autómata* 'ingenios mecánicos'; propiamente 'espontáneos, que obran por sí mismos'.

### 2.5.2. IA como ciencia

Desde una perspectiva más ontológica la IA puede ser comprendida como la ciencia que mediante el diseño de modelos computacionales tiene como objetivo último la construcción de un ente casi humano capaz de comunicarse en la misma lengua y con la misma competencia de sus interlocutores humanos (Herrera y Muñoz, 2017, p. 157 citado por Aqueveque, 2022). Su fenomenología engloba el conjunto de hechos asociados a la neurología y la cognición, desde los niveles subcelular y neuronal a los mecanismos y organizaciones superpuestas de las que emergen las funciones globales de percepción, memoria, lenguaje, decisión, emoción y acción que han dado lugar a lo que llamamos comportamiento inteligente en humanos (Palma, J. T., y Marín, R., 2008).

La función de la IA en particular es dotar de herramientas conceptuales y formales a la Neurofisiología y la Ciencia Cognitiva. Es decir, potenciar la “Neurociencia Computacional” y todos los procedimientos experimentales de estimulación, clasificación e interpretación y predicción de resultados.

### 2.5.3. IA como Ingeniería

El enfoque centrado en el comportamiento humano debe ser una ciencia empírica, que incluya hipótesis y confirmaciones de experimentos. El enfoque racional implica una combinación de matemáticas e ingeniería (Russell et al., 2004, p.2).

La rama aplicada de la IA, conocida como Ingeniería del Conocimiento, tiene unos objetivos más claros y alcanzables a corto y medio plazo. El conocimiento es ahora objeto de la observación, modelado, formalización y transformación por procesos de su mismo nivel o de metaniveles superiores (aprendizaje).

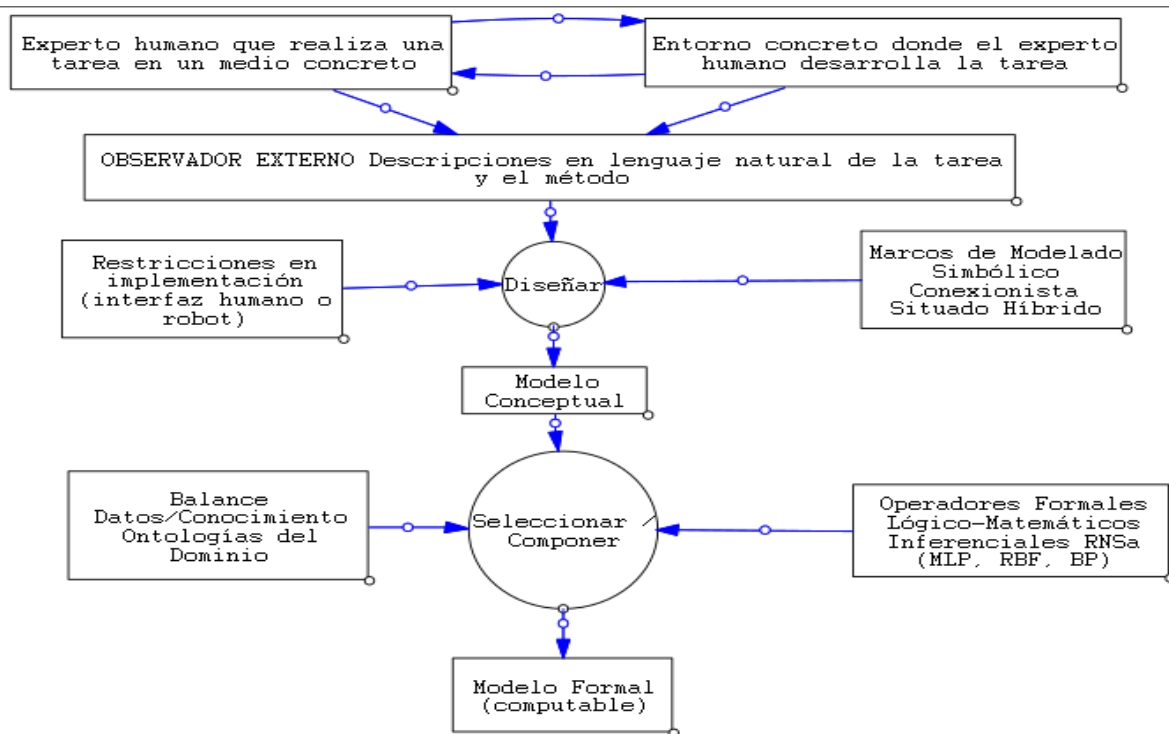
Un ingeniero del conocimiento es alguien que investiga un dominio concreto, aprende qué conceptos son los importantes en ese dominio, y crea una representación formal de los objetos y relaciones del dominio (Russell et al., 2004, p. 295).

En la mayoría de los desarrollos de la IA como Ingeniería se modela un esquema cualitativo como se muestra en la Figura 2.9, a partir de descripciones en lenguaje natural, considerando los pasos de los Sistemas Basados en el Conocimiento (SBCs), el cual permite identificar la interacción entre las fases para lograr el objetivo del modelo.

Fundamentado en la tesis de Turing respecto al enfoque de las máquinas programadas para que piensen, en el siglo XX el trabajo de Schank y Abelson sigue estas directrices: consiste en un programa, SAM (Script Applier Mechanism), que reduce el entendimiento lingüístico a la aplicación de libretos (scripts) a historias nuevas, y a la inferencia de información novedosa a partir de dichos libretos. Por supuesto, esta propuesta causó tanta polémica como lo planteado por Babbage, ya que el entendimiento del lenguaje es un proceso complejo, y mecanizar el mismo a través de la programación no fue recibido como una solución novedosa por algunos.

**Figura 2.9**

*Esquema Cualitativo de la IA como Ingeniería*



Nota: Se modela a partir de descripciones en lenguaje natural del procedimiento usado por un humano para resolver una tarea. Adaptado de *Inteligencia Artificial, Técnicas, métodos y aplicaciones* (p. 9), por Palma, J. y Marín, R. (2008). McGraw-Hill.

Entre ellos, Searle quien propuso una distinción entre dos tipos de IA: la fuerte y la débil. En palabras de González, R. y Tobar, F. (2018) la tesis de Turing dio lugar a un enfoque en IA, considerándolo evidencia suficiente para que se sostenga que una máquina programada piensa.

#### 2.5.4. IA débil

Meseguer y López de Mantarás (2017) indican que la IA “débil” es la ciencia e ingeniería que permite diseñar y programar ordenadores de forma que realicen tareas que requieren inteligencia.

Se considera que los programas computacionales son sólo instrumentos para explorar la cognición humana. El desarrollo de algoritmos de alta complejidad, capaces de aprender y corregirse, genera dudas con relación a la debilidad de la IA débil. Pese a que esta no asume que las máquinas programadas piensan, la posibilidad surge desde un punto de vista práctico. Tal como Turing predijo en 1950, la gente educada no duda, en la práctica, si la IA es genuinamente inteligente. El aprendizaje de máquinas ha revolucionado la IA. El reconocimiento visual, los sistemas de recomendación, y el conteo de créditos son tareas que veladamente acercan la IA débil a la IA fuerte, porque dichas tareas son comunes y corrientes a la vida humana.

El hecho de que el aprendizaje de máquinas tenga consecuencias importantes para la sociedad, sugiere que el reemplazo del trabajo humano por máquinas hace que no sea adecuado negarles inteligencia a estas.

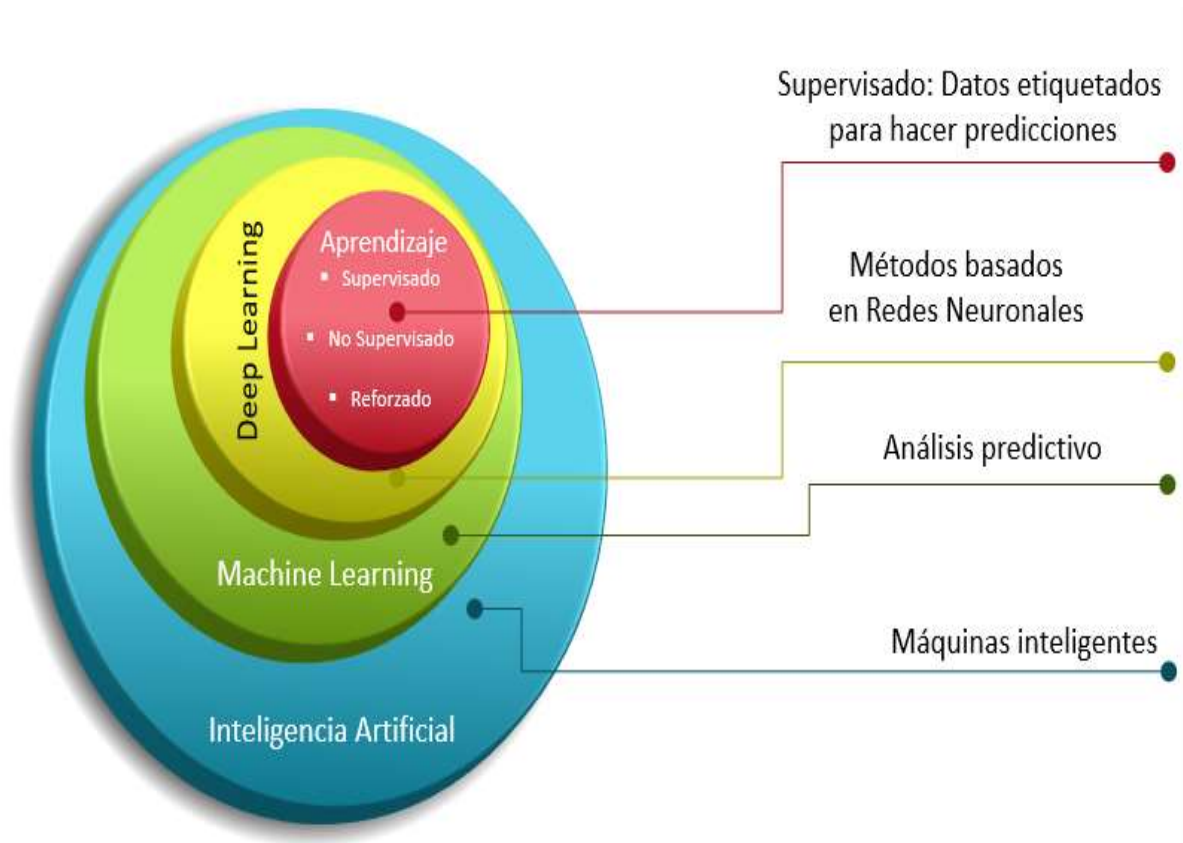
En síntesis, la IA débil se ha traslapado con la fuerte, gracias al aprendizaje de máquinas y su trabajo, y que como Turing lo pondría, resulta cuestionable, desde un punto de vista práctico, negar inteligencia y estados mentales a algoritmos capaces de aprender y reemplazar al ser humano.

Searle, J.R. (1980) citado por Flowers J.C. (2019) y González, R. y Tovar, F. (2018), refieren que el trabajo en inteligencia artificial y conciencia de máquina a menudo se analiza utilizando la distinción entre IA fuerte y débil. La IA débil presenta a la IA como una herramienta para

resolver problemas, mientras que la IA fuerte es la generación de una mente “real”. En opinión de Vázquez (2021), considera dentro de la IA débil las siguientes subramas:

- **Machine learning:** diseña algoritmos o modelos que son capaces de realizar una tarea específica, subrama de la IA representada en la Figura 2.10. IA y sus subramas.
- **Métodos probabilísticos en IA:** posibilitan el razonamiento bajo incertidumbre, además este razonamiento es necesario, ya que el conocimiento sobre el mundo es parcial, estos modelos también se entrenan y predicen.
- **Computación evolutiva:** le persigue la resolución de problemas de optimización inspirada en la propia evolución biológica, cuenta con un conjunto de individuos y todos estos codifican una solución al problema de optimización dado.
- **Teoría del caos:** es una rama de las matemáticas que estudia el comportamiento de sistemas dinámicos y deterministas y cuyo comportamiento se puede predecir.
- **Sistemas difusos:** se basan en la lógica difusa, aquella en la que la verdad no es exacta, sino que está definida en una región que recibe el nombre de región difusa.

**Figura 2.10**  
*IA y sus subramas*



### 2.5.5. IA fuerte

La IA “fuerte” algunos autores la definen como la ciencia e ingeniería que posibilita replicar la inteligencia humana a través de máquinas. De manera que, según esta versión, la transición de una IA “débil” a otra “fuerte” dependería del diseño de la máquina inteligente, en cuanto a que su forma de inteligencia debiera ser esencialmente humana. Conviene aclarar que, según esta hipótesis, la inteligencia que se espera pudiera especificar una máquina, ya sea en su fase “débil” o en su fase “fuerte”, “[...] debería tratarse de inteligencia de tipo general y no



especializada, ya que la inteligencia de los seres humanos es de tipo general” (Meseguer y López de Mantarás, 2017, p. 10).

Para los defensores de la IA fuerte un programa como SAM literalmente entiende las historias, mientras que para los de la IA débil el entendimiento lingüístico no se da literal sino sólo metafóricamente. La metáfora y no la adscripción de estados mentales sería la actitud indicada con relación a programas como SAM (González, R. y Tobar, F., 2018)

Algunos autores como Trillería (2022) y Torra (2011) consideran una versatilidad de la IA, la definen como una de las ramas de la informática con fuertes raíces en otras áreas, como la lógica y las ciencias cognitivas. Lo cardinal de su acercamiento parece ser la conexión de la identidad de la IA con otras dimensiones cognitivas. Es decir, incorpora a la idea de una IA como parte de la Informática, otras cuatro condiciones que la dotan de una complejidad y una heurística que permiten reconocer enseguida ese ente casi humano capaz de comunicarse en la misma lengua, descrito por Herrera y Muñoz (2017).

En efecto Torra (2011, p.2) describe que con base en el comportamiento humano la IA supondría:

- i) Actuar como personas (el modelo a seguir para la evaluación de los programas es el propio comportamiento humano).
- ii) Razonar racionalmente (ser parte de la premisa de que existe una forma racional de razonar: en este caso, la lógica y sus mecanismos de formalización del razonamiento).

- iii) Actuar racionalmente (el objetivo son los resultados evaluados de forma objetiva; para ello es indiferente la forma de calcular el resultado, por ejemplo, en una partida de ajedrez).

### 2.5.6. Inteligencia Artificial como Búsqueda

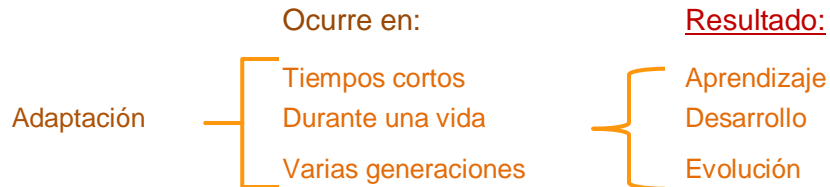
Un sistema de IA tiene una infinidad de opciones entre las cuales debe elegir al menos una opción, por lo cual se puede considerar como un problema de búsqueda; ya sea un robot, clasificador o reconocedor; es necesario que el sistema seleccione al menos una, haciendo este una búsqueda en todas las opciones, Downing (2015) hace una síntesis de distintas técnicas de IA en términos de búsqueda refiriendo que es posible clasificar a los espacios de búsqueda en estacionarios y no estacionarios, como sigue:

Los espacios estacionarios nos sirven para predecir a través de la optimización. En el área de investigación de operaciones, se han desarrollado técnicas de búsqueda heurísticas y meta-heurísticas, algunas de estas técnicas son analizadas en temas de resolución de problemas por búsqueda, y también de cómputo evolutivo; no necesariamente consideradas como IA.

Se clasifica como adaptación otras técnicas utilizadas, dependiendo de su escala temporal. La escala temporal determina el resultado de la adaptación, es decir, si la adaptación ocurre en tiempos cortos, entonces tenemos aprendizaje; si se da durante una vida, tenemos desarrollo y si ocurre durante varias generaciones, tenemos evolución, como se muestra en la Figura 2.11.

**Figura 2.11**


*Adaptación por tipo de escala temporal*



Dado que la adaptación es conceptualizada en su temporalidad, la Figura 2.12 presenta el tipo de adaptación y la técnica de aprendizaje utilizada.

**Figura 2.12**

*Clasificación de Adaptación y Técnica de Aprendizaje*



Además de lo anterior, existen ejemplos de sistemas donde se combinan diferentes escalas temporales de adaptación, como los sistemas evo-devo, pro-evolution and development, evolución y desarrollo.

### 2.6 Aportaciones de la Inteligencia Artificial

Organismos internacionales como el Consejo de Europa<sup>2</sup>, la Comisión Europea<sup>3</sup>, la Agencia de los Derechos Fundamentales de la Unión Europea<sup>4</sup>, la Organización para la Cooperación y el Desarrollo Económico<sup>5</sup> (OCDE), la Organización de las Naciones Unidas (ONU)<sup>6</sup>, la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO)<sup>7</sup>, el Grupo del Banco Mundial<sup>8</sup> y el Banco Interamericano de Desarrollo<sup>9</sup> (BID) promueven la cooperación mundial en materia de IA. El objetivo principal es ayudar a los formuladores de políticas y al público en general a navegar por el panorama de la gobernanza internacional de la IA (BID, 15 de septiembre de 2021).

#### 2.6.1. Inteligencia Artificial en el Sector Educativo.

La UNESCO, ha hecho un llamado para la inclusión de la IA en el aprendizaje; considerando lo siguiente: La IA tiene el potencial de abordar algunos de los mayores desafíos en la

---

<sup>2</sup> Define las orientaciones y prioridades políticas generales de la UE.

<sup>3</sup> Tiene como objetivo la investigación, la ciencia y la innovación ya que son el núcleo de la estrategia de la UE para generar conocimiento y empleo.

<sup>4</sup> Es el centro independiente de referencia y excelencia para la promoción y protección de los derechos humanos en la Unión Europea. Ayuda a hacer de Europa un lugar mejor para vivir y trabajar.

<sup>5</sup> Desarrolla políticas públicas en beneficio para el desarrollo económico mundial.

<sup>6</sup> Organismo encargado de promover mantener la paz y la seguridad internacional, fomentar entre las naciones relaciones de amistad y promover el progreso social

<sup>7</sup> Contribuye a la paz y a la seguridad estrechando la colaboración internacional a través de la educación, la ciencia y la cultura.

<sup>8</sup> El Laboratorio de Tecnología e Innovación del Grupo del Banco Mundial trabaja equipos operativos internos en varios sectores mediante la aplicación de tecnología emergente para resolver desafíos comerciales.

<sup>9</sup> Lidera una iniciativa, ' [fAIR LAC](#) ', la alianza en la región de América Latina y el Caribe (LAC) entre los sectores público y privado, la sociedad civil y la academia, para promover el uso responsable y ético de la IA

educación actual en las prácticas de enseñanza y aprendizaje. Sin embargo, estos rápidos desarrollos tecnológicos inevitablemente conllevan múltiples riesgos y desafíos.

El mandato de la UNESCO (2021a) exige inherentemente un enfoque de la IA centrado en el ser humano. La promesa de “IA para todos” debe ser que todos puedan aprovechar la revolución tecnológica en marcha y acceder a sus frutos, especialmente en términos de innovación y conocimiento.

La IA ha logrado incorporarse en los siguientes rubros para coadyuvar en el aprendizaje:

- Aprendizaje de una lengua.
- Traducción de textos.
- Boot de asistencia de información.
- Herramientas educacionales acorde a las necesidades que tienen los alumnos, por ejemplo, China está impartiendo clases con IA desde un nivel básico (fuente).
- Cursos de aprendizaje con IA: en estos cursos existe un aprendizaje de los alumnos y se proporciona realimentación respecto al material estudiado de forma automática, como por ejemplo: Thinkster Math, Brainly, Third Space Learning, Carnegie Learning.

En la práctica los docentes están enfocados en cumplir con un programa para el aprendizaje, los temarios son extensos y difícilmente se identifican en estos programas holguras por eventualidades presentadas, como terremotos, suspensión de labores o simplemente para dedicar mayor tiempo a algún tema.

En el área de matemáticas o redacción, los procesos de evaluación requieren mucha dedicación de los docentes para revisar largos procesos, pudiendo reducir la calidad en la evaluación por el desgaste en grupos con muchos estudiantes o en grupos que tienen un bajo desempeño y requieren mayor esfuerzo del docente para realimentar las actividades de los educandos.

En este orden de ideas, la tutoría de la IA coadyuva al docente para facilitar la demanda personalizada del estudiante, que podría representar mayor tiempo asignado.

La IA puede detectar y medir el estilo de aprendizaje de un estudiante y el conocimiento preexistente para brindar apoyo e instrucción personalizados; a continuación, se describen algunas aplicaciones en el sector educativo (Universidad de San Diego, 2021).

- **Calificación:** La IA puede ayudar a calificar los exámenes usando una clave de respuestas, recopilar datos sobre el desempeño de los estudiantes e incluso calificar evaluaciones más abstractas, como ensayos.
- **Comentarios sobre la calidad del curso:** Análisis de casos incorrectos, mediante su agrupación, por ejemplo, si muchos estudiantes responden una pregunta incorrectamente, "la IA puede concentrarse en la información o los conceptos específicos que los estudiantes no tienen, para que los educadores puedan ofrecer mejoras específicas en materiales y métodos".

- **Comentarios significativos e inmediatos para los estudiantes:** La IA permite identificar estilos de aprendizaje, análisis de sentimiento, (como actualmente se utiliza en el marketing en el análisis de las redes sociales). Algunos estudiantes pueden ser tímidos a la hora de tomar riesgos o recibir comentarios críticos en el aula, pero "con la IA, los estudiantes pueden sentirse cómodos para cometer los errores necesarios para aprender y recibir la información necesaria para mejorar".

### 2.6.2. Aplicaciones de IA en Canadá

Una startup<sup>10</sup> con sede en Toronto que utiliza un sistema de vigilancia mejorado por IA, parece haber sido la primera en detectar el brote epidémico, varias horas después de su insurgencia en el primer epicentro reportado de Wuhan, muy por delante de las autoridades chinas y otras instituciones y agencias internacionales (Bragazzi, N.L., 2020) y (McCall B. 2020).

En el estudio realizado por Bragazzi et al. (2020), respecto de "¿cómo el big data y la Inteligencia Artificial pueden ayudar a gestionar mejor la pandemia de la COVID-19?", se describe el uso de startups, técnicas de Big Data para analizar los contagios y el análisis comparativo de otros estudios que utilizaron las redes sociales para analizar y diagnosticar los posibles casos de contagio con un promedio de 6-9 días de anticipación, en la Tabla 2.2, se presenta la escala de tiempo, aplicación y el ejemplo de estas aplicaciones.

---

<sup>10</sup> *Startup* es el nombre en inglés que reciben las empresas jóvenes, que tienen poco tiempo en el mercado. Estos negocios tienen un fuerte componente tecnológico y grandes posibilidades de crecimiento partiendo de una idea innovadora.

**Tabla 2.2**

*Posibles aplicaciones de la Inteligencia Artificial del brote de COVID-19.*

Escala de tiempo	Aplicación	Ejemplo
Corto plazo (semanas)	Identificación rápida de un brote en curso.	La IA puede facilitar la recopilación de datos epidemiológicos en tiempo real, la evaluación de riesgos, los procesos de toma de decisiones y el diseño/ implementación de intervenciones de salud pública.
	Diagnóstico y pronóstico de casos de la COVID-19.	Reconocimiento de características diagnósticas y pronósticos específicos.
Mediano plazo (meses)	Identificación de una posible opción terapéutica	Identificar fármacos ya existentes. Descubrir nuevas moléculas.
A largo plazo (décadas)	Potenciar las ciudades y favorecer el desarrollo de ciudades sanas, inteligentes y resilientes	Diseñar nuevos protocolos estandarizados para compartir datos e información durante emergencias.

Fuente: Bragazzi, N et al. (2020). How Big Data and artificial intelligence can help better manage the COVID-19 pandemic. *International Journal of Environmental Research and Public Health*, 17(9), 3176.

### 2.6.3. Aplicaciones de IA en China

Liao, L., y Gu, F. (2022) realizaron una investigación para explorar la aplicación de la tecnología y la interacción con la inteligencia artificial en cursos de educación preescolar y la red inalámbrica con infantes de 6 años en China, en esta identificaron incremento de aprendizaje en los niños con un promedio de 3.56 antes de la introducción y 4.01 después de la introducción de la IA.

En materia legal, han desarrollado el uso de la IA en Tribunales para asistencia legal y temas administrativos en China (Wen, 2017), lo cual ha sido una ventaja dado que en México con la pandemia se vieron afectadas muchas personas al no dar continuidad a sus procesos, como por ejemplo custodia de los hijos, pensiones alimenticias, entre otros.



## Capítulo 2 Inteligencia Artificial.

---

Se ha concluido con el marco contextual indispensable para fundamentar la tendencia tecnológica mediante la indagación de su evolución, características y aportaciones de la Inteligencia Artificial que ha dado a la humanidad, centrados en el ámbito educativo, así como la referencia de los métodos inductivo y sintético los cuáles dictan las bases en la generación de conocimiento y muestran las diferencias entre la conceptualización de tareas del humano y la máquina, dando paso al marco teórico que da inicio con el Capítulo 3. Educación Basada en Competencias, en el que se describen las bases, fundamentos y fuentes del currículo para identificar y evaluar las competencias.



## Capítulo 3 Educación basada en competencias

## Capítulo 3 Educación basada en competencias.

### 3. Antecedentes de la educación basada en competencias.

En este capítulo se presentan los antecedentes e importancia de la educación basada en competencias, dado que durante la pandemia de la COVID-19, algunos organismos internacionales reafirmaron la importancia de la educación basada en competencias con énfasis en las competencias digitales, siempre que esto sea posible por los requerimientos tecnológicos que esto conlleva. La creciente evolución tecnológica demandante de la interconexión constante a diversos dispositivos y la información continua generada cada segundo requiere que los educandos y docentes estén inmersos en la transformación digital para lograr ser competitivos en el mundo laboral.

Se suele citar a McClellan, D.C. (1973) como precursor del concepto de competencia. Este autor estadounidense del ámbito de la psicología del trabajo y de las organizaciones plantea una crítica a la capacidad de predicción de la formación académica en el contexto laboral. Sobre la base de esta crítica y de su teoría de las necesidades, su estudio se centra en los rasgos de los emprendedores exitosos para establecer qué factores (además de los conocimientos, aptitudes y actitudes) inciden en el desempeño profesional.

### 3.1. Educación basada en competencias

La evolución constante, transformación de procesos y adaptación ha hecho que cada día el desarrollo de competencias sea clave en la educación. Así también, múltiples autores y organizaciones internacionales como la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO), la Organización para la Cooperación y el Desarrollo Económicos (OCDE) y la Organización Nacional de las Unidas (ONU) han abonado a la definición del concepto, y han recibido el embate de agudos críticos (Barnett y Ortiz, 2008).

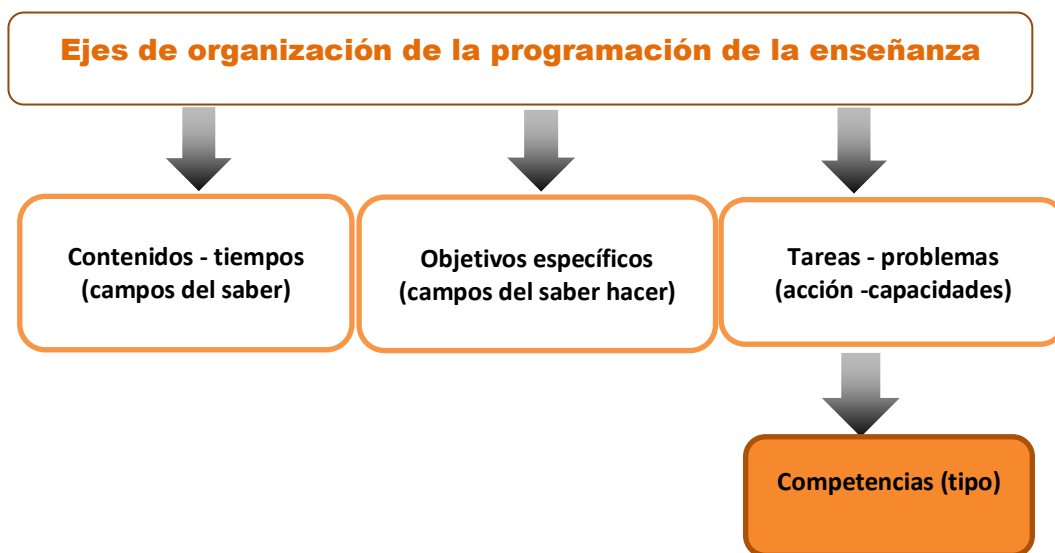
Braslavsky, C. en UNESCO (2017) a través de su presentación en la UNESCO titulada “Hay que educar por competencias” señala que el concepto de competencia es el pilar del desarrollo curricular y el incentivo tras el proceso de cambio. Se define como “el desarrollo de las capacidades complejas que permiten a los estudiantes pensar y actuar en diversos ámbitos [...]. Consiste en la adquisición de conocimiento a través de la acción, resultado de una cultura de base sólida que puede ponerse en práctica y utilizarse para explicar qué es lo que está sucediendo”.

La elección de la competencia como principio organizador del currículo es una forma de trasladar la vida real al aula, (Jonnaert, P. et al, Perspectivas, UNESCO, 2007, citado por UNESCO, 2017). Se trata, por tanto, de dejar atrás la idea de que el currículo se lleva a cabo cuando los estudiantes reproducen el conocimiento teórico y memorizan hechos (el enfoque convencional que se basa en el conocimiento). Asumir un enfoque basado en competencias, requiere modificar el eje del contenido y girar hacia el eje de la tarea, siendo indispensable

generar un ambiente participativo, en el que el estudiante promueva el estímulo de distintas situaciones que le permitan incrementar su conocimiento. Esa puesta en acción debe ser el eje de la planeación en un enfoque basado en competencias, una representación gráfica del paso de un eje a otro, se esquematiza en la Figura 3.1.

**Figura 3.1**

*Ejes de la organización en la programación de la enseñanza*



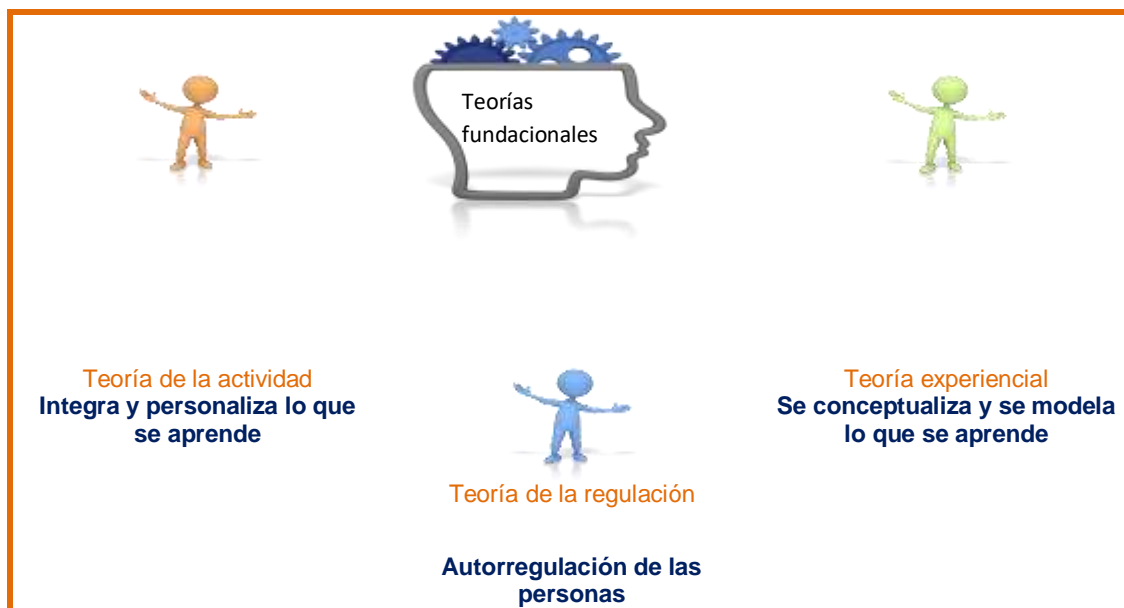
El aprendizaje mediante la acción prepara al estudiante para que pueda enfrentar los problemas o situaciones específicas para hacerlo capaz de resolver con una visión compleja, es decir interrelacionando más de una variable, y no únicamente simples respuestas puntuales del todo o nada, cómo se evalúa frecuentemente en matemáticas, dejando fuera todo el procedimiento y el planteamiento y centrándose únicamente en el resultado, situación que desvaloriza el esfuerzo realizado.

### 3.2. Principales teorías

Las teorías fundacionales que sustentan esta propuesta a partir de tomar la acción como eje de la planeación didáctica son: la teoría de la actividad, por su gran implicación en la forma en que se integra y personaliza lo que se aprende; la teoría de la regulación, por su gran implicación en cómo las personas se autorregulan y actúan meta-cognitivamente<sup>11</sup>, liberando con ello la acción de un simple utilitarismo y la teoría experiencial, con su gran implicación en cómo, a partir de las experiencias, se conceptualiza y modela lo que se aprende, para modificar actitudes y sobre todo, para ampliar el repertorio de habilidades que permitan al sujeto inventar o crear nuevas cosas en situaciones particulares al poner en acción el conocimiento a través de las acciones transferenciales<sup>12</sup>, descritas en la Figura 3.2.

**Figura 3.2**

*Principales teorías basadas en el eje de la acción*



<sup>11</sup> Meta cognición para John Flavell, (1970). Capacidad que de ser conscientes; consiste tanto en el conocimiento cognitivos y experiencias. (Monereo y Castelló. 1997, p.56).

<sup>12</sup> Referido a las acciones transferenciales de S. Freud.

La meta cognición puede lograrse a partir de unidades de información, situación que propicia también el logro y el establecimiento de comunidades de aprendizaje, donde la función cognitiva implica habilidades<sup>13</sup> y procesos de codificación. La acción, como eje de la programación, nos remite a la teoría de la actividad, de inspiración Vygotskiana<sup>14</sup> donde, a partir de las diferencias y relaciones entre acción y actividad se ofrece una fundamentación valiosa del aprendizaje en el ser humano.

La teoría de la actividad (Leontiev, 1981) permite realizar un análisis integral de la actividad humana, delimitando la estructura de la misma, es decir, sus componentes principales y las relaciones funcionales que entre ellos se producen, así como su desarrollo. Dentro del plano práctico de la actividad se considera lo presentado en la Tabla 3.1.

**Tabla 3.1**  
*Plano práctico de la actividad*

Medios	Condiciones	Productos
Instrumentos materiales que posee el sujeto y que emplea en la transformación del objeto: <ul style="list-style-type: none"><li>▪ Informativos</li><li>▪ Lingüísticos</li><li>▪ Psicológicos</li></ul>	Situaciones de naturaleza en que se efectúa la actividad: <ul style="list-style-type: none"><li>▪ Ambiental,</li><li>▪ Psicológica,</li><li>▪ Social</li></ul>	Resultados logrados mediante la actividad.  Transformaciones en: <ul style="list-style-type: none"><li>▪ El objeto,</li><li>▪ El sujeto,</li><li>▪ Los medios,</li><li>▪ Los procedimientos y</li><li>▪ Las condiciones.</li></ul>

Fuente: Leontiev, A. N. (1981)

Como se ha mencionado, cuando el eje de la programación es la acción, las propuestas en torno a los tratamientos de las mismas pueden diferir, pues no siempre este eje induce al

<sup>13</sup> En las habilidades cognitivas se tiene análisis, síntesis, clarificación, comparación y relación de abstracción. (Álvarez. 2002, 108 p.)

<sup>14</sup> La concepción *Vygotskiana* define la actividad humana como el proceso que media la relación entre el ser humano (sujeto) y aquella parte de la realidad que será transformada por el objeto de transformación.

aprendizaje a través de la experiencia o a través del descubrimiento, sino que las propuestas varían según la situación.

### 3.3. Aprendizaje basado en competencias

Las competencias son la clave en la formación de conocimientos, capacidades, habilidades y actitudes adecuadas de los individuos en una sociedad que está basada en el conocimiento. Creando un valor añadido, la cohesión social y el entorno en el que se desenvuelve el individuo, ofrecen flexibilidad y capacidad de adaptación, satisfacción y motivación. Los pilares de la educación (Delors, J. et. al 1998) se muestran en la Figura 3.3

**Figura 3.3**

*Pilares de la educación*



Fuente: Adaptado de Delors, J. et. al (1998)



La relación de los pilares (Delors, J. et. al 1998) con el aprendizaje basado en contenidos, conceptuales, procedimentales, actitudinales y de convivencia presentados en la Tabla 3.2 fortalecen las competencias del individuo.

**Tabla 3.2**

*Relación de los pilares con el aprendizaje*

Pilares <b>Saber</b>	Aprendizaje <b>Contenidos</b>
Conocer	Conceptuales
Hacer	Procedimentales
Ser	Actitudinales
Convivir	Convivencia

Fuente: Adaptada de Castellanos, 2012, p.17

El Aprendizaje Basado en Competencias (ABC), consiste en desarrollar las competencias genéricas o transversales (llamadas así por que atraviesan el contenido académico) necesarias, las competencias específicas (propias de cada profesión) con el propósito de capacitar a la persona sobre los conocimientos científicos y técnicos, su capacidad de aplicarlos en contextos diversos y complejos, integrándose con sus actitudes y valores en un modo propio de actuar personal, profesionalmente y digitalmente mediante las competencias digitales que integran el uso de la tecnología para interconectarse, transmitir información y comunicarnos.

### 3.4. Bases, fundamentos y fuentes del currículo

#### 3.4.1. Bases

El sector educativo, debe considerar la situación emergente de la pandemia para documentar las lecciones aprendidas, actuar en consecuencia y definir planes de emergencia o

contingencia. El regreso a la normalidad debe considerar la inclusión permanente de los recursos tecnológicos, ya sea en el sistema presencial o en línea, desarrollar un plan emergente con una visión del futuro y adaptado a las necesidades de las empresas para que los estudiantes logren incorporarse rápidamente al ámbito de su profesión.

Es necesario considerar como base modelos educativos emergentes y aprovechar la oportunidad para reflexionar sobre lo que han demandado los docentes y estudiantes en materia de aprendizaje durante la disrupción para llegar a una transformación educativa digital acorde al mercado laboral, creando las políticas necesarias que nos permitan esta transformación y den apertura a la innovación, al pensamiento creativo y a la facilitación de recursos tecnológicos y pedagógicos para el logro de los objetivos tanto de docentes como de educandos.

### 3.4.2. Fundamentos

Las recomendaciones de la Unión Europea, publicadas en el Diario Oficial del 22 de mayo de 2018, relativas a las competencias clave para el aprendizaje se insiste en la necesidad de la adquisición de las competencias clave por parte de la ciudadanía como condición indispensable para lograr que los individuos alcancen un pleno desarrollo personal, social y profesional que se ajuste a las demandas de un mundo globalizado (Unión Europea, 2018 p.4).

Se suele definir a las competencias como una combinación de conocimientos, capacidades y actitudes (educagob, s/f).

- Los **conocimientos** se componen de hechos y cifras, conceptos, ideas y teorías que ya están establecidos y apoyan la comprensión de un área o tema concretos.
- Las **capacidades** se definen como la habilidad para realizar procesos y utilizar los conocimientos existentes para obtener resultados.
- Las **actitudes** describen la mentalidad y la disposición para actuar o reaccionar ante las ideas, las personas o las situaciones.

En la Figura 3.4 se da muestra de las competencias clave definidas, en las que se consideran las capacidades interculturales, de comunicación y negociación y analíticas para lograr la resolución de problemas basados en el pensamiento crítico, dando gran importancia a la creatividad y el trabajo en equipo; de esta forma se proporciona a los estudiantes la base y el fundamento; imprescindibles para que el desarrollo del estudiante.

**Figura 3.4**

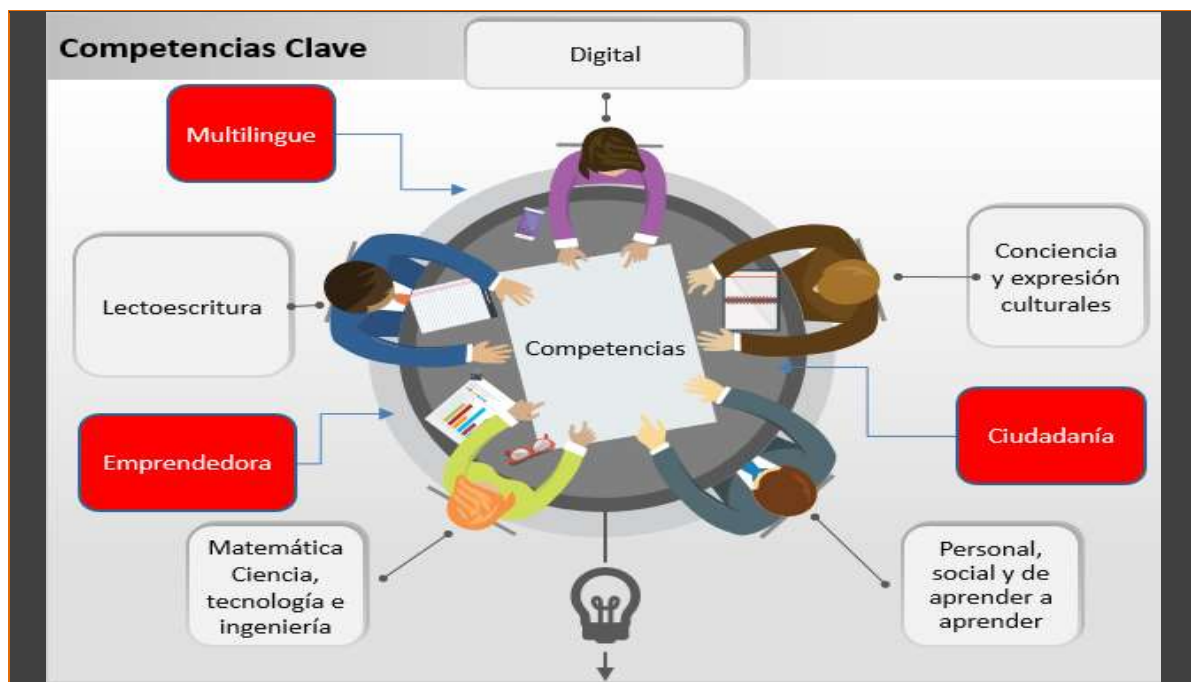
*Capacidades integradas en las competencias clave*



Fuente: basado en el Diario Oficial de la Unión Europea, 22 de mayo de 2018.

Dentro del marco de las competencias clave, es importante considerar una transformación constante y contar con bases sólidas, estas fortalecerán el aprendizaje permanente a través de la actualización y mejora continua. La Figura 3.5 señala como base del aprendizaje permanente: lecto escritura, matemática, ciencia, tecnología e ingeniería, personal, social y de aprender a aprender, conciencia y expresión culturales, digital y una cultura multilingüe, emprendedora y considera la ciudadanía.

**Figura 3.5**  
*Competencias Clave*



Nota: basado en el Diario Oficial de la Unión Europea, 22 de mayo de 2018.

### 3.4.3. Fuentes del Currículo

En palabras de León De Herdó, R. E. y Zerpa, M. M., (2022) el diseño curricular desde la visión socio formativa, tiene como fin la motivación en la sociedad para mejorar la calidad de vida, basado en el pensamiento complejo, fundamentado en los principios: auto-eco-organización,

recursividad organizacional, dialógico, hologramático, como enfoque surgido en la primera década del siglo XXI del trabajo de profesores universitarios. Ante ello, se plantea el aprender a aprender, aprender a vivir, por cuanto el conocimiento está a la orden del entorno, de una realidad inmediata a los actores, con respuestas efectivas, funcionales, con una verdadera conexión de las áreas del saber, las competencias, recursos, medios y la tecnología, todo a favor de esos procesos de transformaciones sociales.

En esta investigación se considera importante evaluar el nivel de competencia que presentan los estudiantes cuando ingresan al nivel superior, no basta con identificar las competencias que queremos desarrollar. Conocer el esquema antecedente, nos permitirá reevaluar en el corto tiempo y definir la estrategia de aprendizaje identificando las competencias clave presentadas en la Tabla 3.3, estas están relacionadas con los pilares de la educación.

**Tabla 3.3**

*Competencias clave*

Competencia: Comunicación Lingüística		
Descripción: Acción comunicativa en prácticas sociales		
Saber	Saber hacer	Saber ser
Diversidad del lenguaje y de la comunicación en función del contexto.	Expresarse de forma oral en múltiples situaciones comunicativas.	Estar dispuesto al diálogo crítico y constructivo.
Las funciones del lenguaje.	Comprende distintos tipos de textos: buscar, recopilar y procesar información.	Reconocer el diálogo como herramienta primordial para la convivencia.
Principales características de los distintos estilos y registros de la lengua.	Expresarse de forma escrita en múltiples modalidades, formatos y soportes.	Tener interés por la interacción con los demás.
El Vocabulario.		Ser consciente de la repercusión de la lengua en otras personas.
La gramática.		
Competencia: Matemática y competencias básicas en ciencia y tecnología		

## Capítulo 3 Educación basada en competencias.

**Descripción:** Implica la capacidad de aplicar el razonamiento matemático y sus distintos fenómenos en su contexto.  
Las competencias básicas en ciencia y tecnología proporcionan un acercamiento al mundo físico y a la interacción responsable con él desde acciones, tanto individuales como colectivas, orientadas a la conservación. Protección y mantenimiento de la calidad de vida y el progreso de los pueblos.

Saber	Saber hacer	Saber ser
Términos y conceptos: Matemáticos. Geometría. Estadística. Álgebra. Medidas. Números. Lenguaje científico. Representaciones matemáticas. Sistemas biológicos. Sistemas físicos. Sistema de la Tierra del Espacio. Sistemas tecnológicos.	Aplicar gráficos y representaciones matemáticas. Tomar decisiones basadas en pruebas y argumentos. Resolver problemas. Interpretar y reflexionar sobre los resultados matemáticos. Emitir juicios en la realización de cálculos. Utilizar y manipular herramientas y máquinas tecnológicas.	Respetar los datos y su veracidad. Asumir los criterios éticos asociados a la ciencia y la tecnología. Apoyar la investigación científica y valorar el conocimiento científico.

**Competencia:** Digital

**Descripción:** Implica el uso creativo, crítico y seguro de las tecnologías de la información y la comunicación para alcanzar los objetivos relacionados con el trabajo, la empleabilidad, el aprendizaje, el uso del tiempo libre, la inclusión y participación en la sociedad.

Saber	Saber hacer	Saber ser
Los derechos y los riesgos en el mundo digital. Fuentes de información. Lenguaje específico: textual, numérico, icónico, visual, gráfico y sonoro. Principales aplicaciones informáticas.	Usar y procesar información de manera crítica y sistémica. Buscar, obtener y tratar información. Utilizar recursos tecnológicos para la comunicación y resolución de problemas. Crear contenidos.	Tener actitud altiva, crítica y realista hacia las tecnologías y los medios tecnológicos. Valorar fortalezas debilidades de los medios tecnológicos. Tener curiosidad y la motivación por el aprendizaje y la mejora en el uso de las tecnologías.

**Competencia:** Aprender a aprender

**Descripción:** Supone la habilidad para iniciar, organizar y persistir en el aprendizaje. Requiere conocer y controlar los propios procesos de aprendizaje para ajustarlos a los tiempos y las demandas de las tareas y actividades que conducen al aprendizaje. La competencia de aprender a aprender desemboca en un aprendizaje cada vez más eficaz y autónomo.

Saber	Saber hacer	Saber ser
-------	-------------	-----------

## Capítulo 3 Educación basada en competencias.

<p>Los procesos implicados en el aprendizaje</p> <p>Conocimiento sobre lo que uno sabe y desconoce.</p> <p>El conocimiento de la disciplina y el contenido concreto de la tarea.</p> <p>Conocimiento sobre distintas estrategias posibles para afrontar tareas.</p>	<p>Estrategias de planificación de resolución de una tarea</p> <p>Estrategias de supervisión de las acciones que el estudiante está desarrollando.</p> <p>Estrategias de evaluación del resultado y del proceso que se ha llevado a cabo.</p>	<p>Motivarse para aprender.</p> <p>Tener la curiosidad y la necesidad de aprender.</p> <p>Sentirse protagonista del proceso y del resultado de su aprendizaje.</p> <p>Tener la percepción de auto-eficacia y confianza en el mismo.</p>
---	---	---

<b>Competencia:</b>	<b>Sentido de la iniciativa y espíritu emprendedor</b>
<b>Descripción:</b>	<p>Transformar las ideas en actos.</p> <p>Capacidad de reconocer las oportunidades existentes para las actividades personales, profesionales y comerciales.</p> <p>Incluye aspectos de mayor amplitud que proporcionan el contexto en el que las personas viven y trabajan.</p>

<b>Saber</b>	<b>Saber hacer</b>	<b>Saber ser</b>
<p>Comprensión del funcionamiento de las sociedades y las organizaciones sindicales y empresariales.</p> <p>Diseño e implementación de un plan.</p> <p>Conocimiento de las oportunidades existentes para las actividades personales, profesionales y comerciales.</p>	<p>Capacidad de análisis, planificación, organización y gestión.</p> <p>Capacidad de adaptación al cambio y resolución de problemas.</p> <p>Saber comunicar, presentar, representar y negociar.</p> <p>Hacer evaluación y auto-evaluación.</p>	<p>Actuar de forma creativa e imaginativa.</p> <p>Tener autoconocimiento y autoestima.</p> <p>Tener iniciativa, interés, proactividad e innovación, tanto en la vida privada y social como en la profesional.</p>

<b>Competencia:</b>	<b>Conciencia y expresiones culturales.</b>
<b>Descripción:</b>	<p>Requiere conocimientos que permitan acceder a las distintas manifestaciones sobre la herencia cultural (patrimonio cultural, histórico-artístico, literario filosófico, tecnológico, medioambiental, etcétera) a escala local y nacional.</p>

<b>Saber</b>	<b>Saber hacer</b>	<b>Saber ser</b>
<p>Herencia cultural (patrimonio cultural, histórico-artístico, literario, filosófico, tecnológico, medioambiental, etc.)</p> <p>Diferentes géneros y estilos de las bellas artes (música, pintura, escultura, arquitectura, ciencia, literatura, fotografía, teatro, danza).</p> <p>Manifestaciones artístico-culturales de la vida cotidiana (vivienda, vestido, gastronomía,</p>	<p>Aplicar diferentes habilidades de pensamiento, perceptivas, comunicativas, de sensibilidad y sentido estético.</p> <p>Desarrollar la iniciativa, la imaginación y la creatividad.</p> <p>Ser capaz de emplear distintos materiales y técnicas en el diseño de proyectos.</p>	<p>Respetar el derecho a la diversidad cultural, el diálogo entre las culturas y sociedades.</p> <p>Valorar la libertad de expresión.</p> <p>Tener interés, aprecio, respeto, disfrute y valoración crítica de las obras artísticas y culturales.</p>

artes aplicadas, folklores, fiestas).

### Competencia: Sociales y cívicas

**Descripción:** La competencia social se relaciona con el bienestar personal y colectivo. Exige entender el modo en que las personas pueden procurarse un estado de salud física y mental óptimo, tanto para ellas mismas como para sus familias y para su entorno social próximo, y saber cómo un estilo de vida saludable puede contribuir a ello.

La competencia cívica se basa en el conocimiento crítico de los conceptos de democracia, justicia, igualdad, ciudadanía y derechos humanos y civiles.

Saber	Saber hacer	Saber ser
Comprender códigos de conducta aceptados en distintas sociedades y entornos.	Saber comunicarse de una manera constructiva en distintos entornos y mostrar tolerancia.	Tener interés por el desarrollo socioeconómico y por su contribución a un mayor bienestar social.
Comprender los conceptos de igualdad, no discriminación entre mujeres y hombres, diferentes grupos étnicos o culturales, la sociedad y la cultura.	Manifestar solidaridad e interés por resolver problemas. Participar de manera constructiva en las actividades de la comunidad.	Tener disposición para superar los prejuicios y respetar las diferencias. Respetar los derechos humanos.
Comprender las dimensiones intercultural y socioeconómica de las sociedades.	Tomar decisiones en los contextos local, nacional a través del voto.	Participar en la toma de decisiones democráticas a todos los niveles.
Comprender los conceptos de democracia, justicia, igualdad, ciudadanía y derechos humanos.		

Nota: Adaptado del Portal del Sistema Educativo Español

Respecto al pronunciamiento del desafío laboral, Aguerrevere, G. (2020) consultora de comunicaciones de la División de Mercados Laborales del Banco Interamericano de Desarrollo, refiere que durante la pandemia ha existido una amplia gama de oferta de formación en habilidades digitales y teletrabajo, necesarias para responder a los cambios generados por el aislamiento, pero como muchos sabemos no todos están capacitados para comunicarse digitalmente. Las competencias digitales consideran una brecha en la educación dado que algunas instituciones educativas no cuentan con los recursos tecnológicos o en el caso de las personas de la tercera edad se tiene resiliencia al uso de tecnología para llevar a



cabo movimientos bancarios, solicitar un taxi mediante un aplicativo o comida, tal es el caso tanto de zonas marginadas, o de personas que no tienen un correo o cuenta de Facebook, lo que impide descargar las aplicaciones.

Durante la pandemia, las universidades redoblaron los esfuerzos para incorporar estrategias, metodologías y técnicas de enseñanza en línea, haciendo uso de recursos digitales para dinamizar la educación; el aprendizaje tanto para los docentes como para los alumnos en el uso de recursos tecnológicos de forma abrupta representó en algunos casos sentimientos de angustia y frustración; además del entorno de incertidumbre vivido durante la pandemia. El uso de la tecnología debe favorecer el desarrollo autónomo de los estudiantes y un aprendizaje más significativo mediante la enseñanza estratégica.

Según Jones, B.F et. al (1987), la enseñanza estratégica se centra en las actividades cognitivas en que se comprometen a docentes y estudiantes. Esta se considera a partir de los puntos descritos en la Figura 3.6 y argumentan que el aprendizaje estratégico es a su vez un rol y un proceso, donde el rol depende del docente estratégico porque es muy diferente del papel del organizador.

Existen evidencias que la capacidad de un docente al destinar tiempo, al utilizar una base rica en conocimientos, al conocer ampliamente su área curricular y al hecho de planear, elegir, secuenciar y evaluar propicia en él, una visión como modelo y mediador.

**Figura 3.6**

*Enseñanza estratégica centrada en actividades cognitivas.*



Fuente: Adaptado de Jones, B.F. et. al (1987)

### 3.5. Programación de competencias

La programación considera estructurar, planificar y programar el proceso que se seguirá para cada materia a lo largo del curso. Esto le permitirá al docente conocer el siguiente paso dentro de su proceso de enseñanza.

En mi entender, las competencias agregan un valor añadido al proceso de enseñanza posibilitando una dinámica entre los conocimientos, las habilidades básicas y el

comportamiento efectivo. Por tanto, en las competencias digitales se debe considerar el desarrollo de:

- La autonomía de las personas.
- La significatividad del aprendizaje.
- Considerar la competencia desde un enfoque integrado.

### 3.6. Competencias Digitales

El concepto de competencia digital debe posicionarse y evolucionar en el ámbito educativo en donde, de manera general, se concibe como una movilización de recursos tecnológicos y cognitivos ante situaciones problemáticas. Esto permite a la persona un saber actuar, o desempeñarse de manera más consciente y con compromiso social a lo largo de la vida, para integrarse en un entorno laboral demandante del uso de tecnología cada vez más dinámico y cambiante.

De conformidad con los enfoques por competencias, estamos ante la exigencia de desarrollar nuevas prácticas educativas, lo cual nos plantea lo siguiente: ¿requerimos nuevas competencias digitales docentes? La respuesta refiere que el e-learning, requiere el desarrollo de las competencias digitales para ofrecer ventajas competitivas en el aprendizaje. Según la Comisión Europea (2020) considera 6 áreas a evaluar en las competencias digitales las cuáles son presentadas en la Figura 3.7.

Figura 3.7  
*Competencias Digitales*



Nota: adaptado de DigiComp, Comisión Europea 2020

Ante esta realidad, el cuestionamiento es: ¿cuáles son las competencias digitales del docente que trabaja por competencias? Partiendo de, que lo específico de la actividad docente es contribuir al desarrollo de las competencias expresadas en un perfil de egreso, entonces las competencias digitales de los docentes tendrán que ser congruentes con la necesidad de elaborar un currículo diseñado por competencias.

### 3.6.1. Competencias Digitales del Docente

No obstante, que en algunas universidades desde hace varios años se utilizaban las dos modalidades (presencial y en línea) no existía congruencia ni similitud en los materiales y en la forma de enseñar, bajo una mismo currículo de materias en la misma Licenciatura y además en la misma universidad con diferentes modalidades, se reflejó la improvisación en las clases,

la ausencia de estrategias para dinamizar una clase, la desinformación ante los recursos tecnológicos, entre otros aspectos, que no forman parte del análisis del capítulo, pero que impactan en el aprendizaje.

Lo anterior abre la discusión sobre la necesidad de plantear estrategias docentes de uno y otro modelo de educación, ya que no se pueden plantear competencias docentes al margen de la docencia específica; para esto “uno de los primeros ejercicios en la selección de las competencias digitales docentes podrá ser la discusión colegiada en cada uno de los contextos institucionales donde se adopte el enfoque por competencias” (Rueda, 2009).

Algunos obstáculos a considerar para el uso de la tecnología por parte de los docentes los plantea Tracy Gray, directora general de la AIR Equity Initiative y experta en educación e implementación de tecnología (Vilchis, N., 2020), determinó que todo se reduce en la planificación estratégica de la inversión en tecnología donde el distrito adquiere el software y presupuesta el costo inicial. No obstante, falla en calcular las actualizaciones y licencias necesarias, los dispositivos de reemplazo, sistemas de seguridad y elementos clave de las infraestructuras de tecnologías de la información (TI).

Los docentes no tienen el tiempo ni experiencia para hacer que la tecnología funcione para ellos y sus estudiantes, pues por la evolución constante también necesitan más de una capacitación, por tanto, es necesario considerar este inconveniente dentro de la planeación

para dar soluciones emergentes mediante el apoyo técnico correspondiente a fin de no afectar la dinámica y planeación del docente.

Considerando como parte de la competencia digital la integración de recursos digitales en la planeación del curso, dado que esto permitirá incrementar la competencia del estudiante porque existe una dirección sobre el mismo, de tal forma que deberá “planear el curso de la asignatura con la integración de competencias digitales”, el profesor deberá partir de la problematización sobre la situación de integración que se le presenta, lo cual lo obligará a desarrollar procesos de conceptualización sobre las características y diferencias de una planificación didáctica convencional respecto a una planificación para el desarrollo de competencias; a su vez estos dos momentos lo llevarán a construir y aplicar propuestas que deberán materializar en proyectos de docencia.

### 3.6.2. La Evaluación de Competencia Digital

La evaluación por competencias requiere distintos procedimientos y técnicas de evaluación según el propósito que se desea evaluar. Una cuestión es la evaluación de conocimientos donde se pueden utilizar diversas técnicas (prueba de respuesta larga, prueba de respuesta corta, pruebas objetivas); evaluación de actitudes y valores (técnicas de observación, pruebas de autoevaluación, escalas de actitudes, etc.); evaluación de comportamientos competenciales (cómo aplicar los conocimientos a situaciones concretas, escribir determinados tipos de escritos, desarrollar diferentes tipos de pensamiento (análisis, síntesis, comparativo, crítico, creativo, deliberativo, entre otros).

Dado lo anterior, se pueden utilizar procedimientos como portafolios, informes, pruebas de ejecución, trabajos, entre otros.

La evaluación de las competencias, es un tema clave para determinar la validez del proceso de enseñanza – aprendizaje, pues el resultado del mismo está en función de ¿cómo se ha medido? y ¿qué se ha medido? La evaluación por competencias requiere una capacitación técnica del profesorado y una sensibilización de su verdadero valor para que pueda prestar el tiempo y la dedicación necesaria para hacerlo del mejor modo posible, para el caso de esta investigación además del profesorado se requieren incluir herramientas tecnológicas basadas en *e-learning*, que permitan coadyuvar en el desarrollo de competencias.

La UNESCO (2021) en la Declaración global reconectada, señala que las brechas de capacidad siguen siendo un obstáculo persistente para la educación conectada. Las habilidades digitales inadecuadas se clasifican como la mayor barrera individual para el uso de la tecnología para la educación, y esto independientemente del estado de desarrollo de un país. Las brechas de habilidades digitales tienden a ser más pronunciadas para los padres, seguidos por los maestros y luego por los estudiantes, lo que indica que la educación conectada depende de sociedades alfabetizadas digitalmente.

### 3.6.3. Propuesta de evaluación de competencias digitales del docente.

El contexto anterior permite plantear en primer término la evaluación de competencia digital docente e identificar las áreas de oportunidad, para definir planes de capacitación estratégicos

acordes con la transformación digital y el docente pueda realizar la planeación estratégica de los conocimientos, actitudes, habilidades, roles y responsabilidades de las competencias a desarrollar en sus educandos: La propuesta de evaluación considera 3 fases: la primera evalúa el conocimiento de las competencias digitales docentes, la segunda fase corresponde a la planeación del curso mediante competencias digitales y transversales y la última fase comprende la evaluación de la eficacia se muestra en la Tabla 3.4.

**Tabla 3.4**  
*Propuesta de Evaluación de Competencia Digital Docente*

Fase	Evaluación de Competencia Digital Docente	Puntaje
Fase 1 Conocimiento	Área 1 Información y alfabetización de datos	
	Área 2 Comunicación y colaboración	
	Área 3 Crear contenidos digitales	
	Área 4 Seguridad	
	Área 5 Solución de problemas	
	Área 6 Usos y aplicaciones	
Fase 2 Planeación	Área 1 Información y alfabetización de datos	
	Área 2 Comunicación y colaboración	
	Área 3 Crear contenidos digitales	
	Área 4 Seguridad	
	Área 5 Solución de problemas	
	Área 6 Usos y aplicaciones	
Fase 3 Eficacia	Área 1 Información y alfabetización de datos	
	Área 2 Comunicación y colaboración	
	Área 3 Crear contenidos digitales	
	Área 4 Seguridad	
	Área 5 Solución de problemas	
	Área 6 Usos y aplicaciones	

Nota: Adaptado del Marco DigiComp de la Comisión Europea (Diciembre, 2020)



Los conceptos a evaluar y el nivel de dominio se muestran en la Tabla 3.5.

**Tabla 3.5**

*Conocimiento de las Competencias Digitales del Docente*

FASE 1. Competencias Digitales del Docente

Área 1 Información y alfabetización de datos		Nivel de Dominio					
Código	Descripción	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
A1C1	Navegación, búsqueda y filtrado de datos, información y contenido digital						
	Busca datos, información y contenido en entornos digitales confiables, accede a los datos, información y contenido y navegar entre ellos.	■	■	■	■	■	■
	Crea y actualiza estrategias de búsqueda personal.	■	▲	■	■	■	■
A1C2	Evaluar datos, información y contenido digital						
	Analiza, compara y evalúa críticamente la credibilidad y fiabilidad de las fuentes de datos, información y contenidos digitales.	■	■	■	■	■	■
	Analiza, interpreta y evalúa críticamente los datos, la información y el contenido digital.	■	▲	■	■	■	■
A1C3	Gestionar datos, información y contenido digital						
	Organiza, almacena y recupera datos, información y contenidos en entornos digitales. Organiza y procesa en un entorno estructurado.	■	■	■	■	■	■
		■	▲	■	■	■	■
Área 2 Comunicación y colaboración		Nivel de Dominio					
Código	Descripción	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
A2C1	Interactuar mediante tecnologías digitales						
	Comparte datos, información y contenido digital con otros a través de tecnologías digitales apropiadas.	■	■	■	■	■	■
	Actúa como intermediario, conoce las prácticas de referencia y atribución.	■	■	■	■	■	▲
A2C2	Compartir mediante tecnologías digitales						
	Articula las necesidades de información, busca datos, información y contenido en entornos digitales, accede a los datos, información y contenido y navegar entre ellos.	■	■	■	■	■	■
	Crea y actualiza estrategias de búsqueda personal	■	■	■	■	■	▲

## Capítulo 3 Educación basada en competencias.

A2C3	Compromiso ciudadano con tecnologías digitales	Básico		Intermedio		Avanzado			
		A1	A2	B1	B2	C1	C2		
Participa en la sociedad a través del uso de servicios digitales públicos y privados, de forma respetuosa en un contexto de diálogo inclusivo.									
Busca oportunidades para el auto empoderamiento y la ciudadanía participativa a través de tecnologías digitales apropiadas.									
A2C4	Colaborar mediante tecnologías digitales	Básico		Intermedio		Avanzado			
Utiliza herramientas y tecnologías digitales para procesos colaborativos, y para la co-construcción y co-creación de datos, recursos y conocimiento.									
A2C5	Netiquette	Básico		Intermedio		Avanzado			
Conoce las normas de comportamiento y el saber-hacer en el uso de las tecnologías digitales e interactuar en entornos digitales.									
Adapta las estrategias de comunicación al público específico y ser conscientes de la diversidad cultural y generacional en entornos digitales.									
A2C6	Gestión de la identidad digital	Básico		Intermedio		Avanzado			
Crea y gestiona una o varias identidades digitales, para ser capaz de proteger la propia reputación.									
Trata los datos que se producen a través de diversas herramientas, entornos y servicios digitales.									

### Área 3 Crear contenidos digitales

### Nivel de Dominio

A3C1	Desarrollo de contenidos	Básico		Intermedio		Avanzado			
		A1	A2	B1	B2	C1	C2		
Crea y edita contenidos digitales en diferentes formatos, expresarse a través de medios digitales.									
A3C2	Integrar y reelaborar contenido digital	Básico		Intermedio		Avanzado			
Modifica, perfecciona, mejora e integra la información y los contenidos en un conjunto de conocimientos ya existente para crear contenidos y conocimientos nuevos, originales y pertinentes.									
A3C3	Copyright y licencias	Básico		Intermedio		Avanzado			
Comprende cómo se aplican los derechos de autor y las licencias a los datos, la información digital y el contenido.									
A3C4	Programación de plan de trabajo	Básico		Intermedio		Avanzado			

## Capítulo 3 Educación basada en competencias.

Planifica y desarrolla una secuencia de instrucciones comprensibles para que un sistema informático resuelva un problema determinado o realice una tarea específica.



### Área 4 Seguridad

#### Nivel de Dominio

A4C1	Proteger los dispositivos	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Protege los dispositivos y el contenido digital, y comprende los riesgos y amenazas en entornos digitales.



Conoce las medidas de seguridad y protección y respeta la fiabilidad y privacidad.



A4C2	Proteger los datos personales y la privacidad	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Protege los datos personales y la privacidad en entornos digitales.



Entiende cómo usar y compartir información personal identificable mientras se protege así mismo y a los demás de daños y perjuicios.



Entiende que los servicios digitales utilizan una "Política de Privacidad" para informar cómo se utilizan los datos personales.



A4C3	Proteger la salud y el bienestar	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Es capaz de evitar riesgos para la salud y amenazas para el bienestar físico y psicológico utilizando tecnologías digitales.



Es capaz de protegerse a sí mismo y a los demás de posibles peligros en entornos digitales (p. ej., intimidación cibernética).



Conoce las tecnologías digitales para el bienestar y la inclusión social.



A4C4	Proteger el medio ambiente	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Conoce el impacto ambiental de las tecnologías digitales y su uso.



### Área 5 Solución de problemas

#### Nivel de Dominio

A5C1	Resolver problemas técnicos	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Identifica problemas técnicos en el manejo de dispositivos y en el uso de entornos digitales, y los resuelve (desde la localización de averías hasta la resolución de problemas más complejos).










A5C2	Identificar necesidades y respuestas tecnológicas	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

## Capítulo 3 Educación basada en competencias.

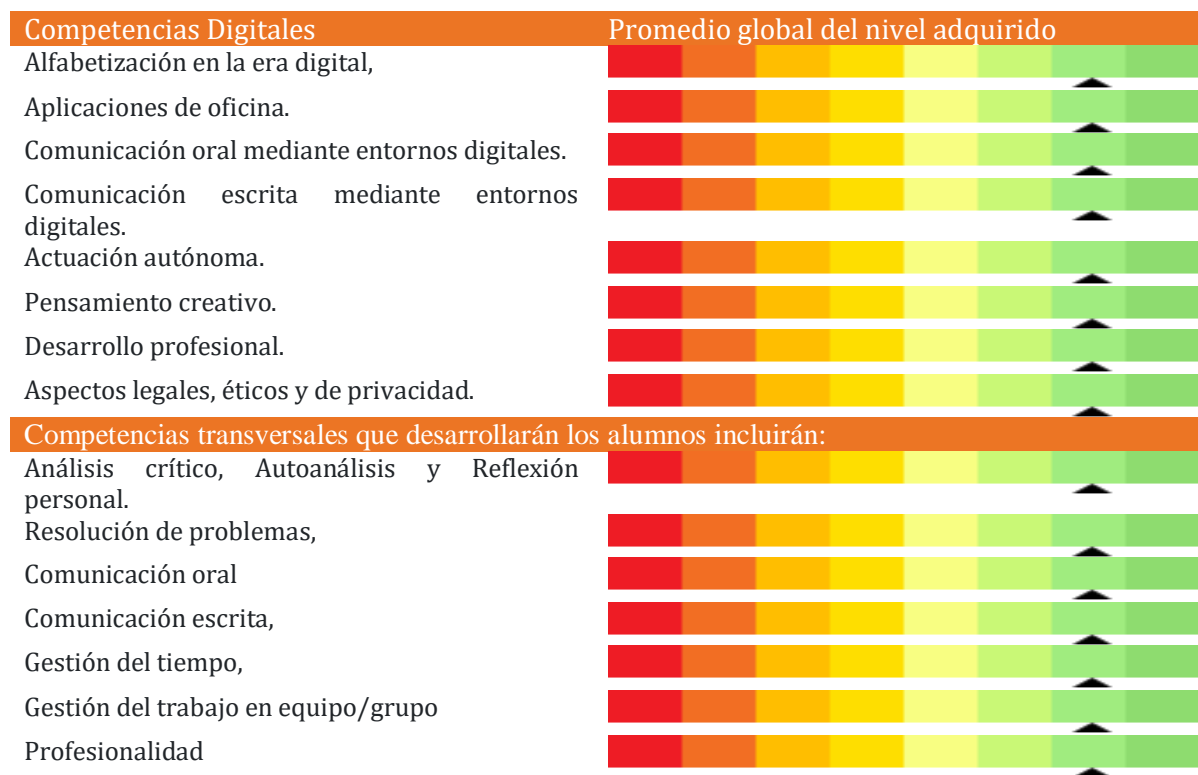
<p>Evalúa las necesidades e identifica, evalúa, selecciona y utiliza herramientas digitales y las posibles respuestas tecnológicas para resolverlas.</p> <p>Adapta y personaliza los entornos digitales a las necesidades personales (por ejemplo, accesibilidad).</p>													
<p><b>A5C3</b>      <b>Uso creativo de la tecnología digital</b></p>	<table border="1"> <thead> <tr> <th colspan="2">Básico</th> <th colspan="2">Intermedio</th> <th colspan="2">Avanzado</th> </tr> <tr> <th>A1</th> <th>A2</th> <th>B1</th> <th>B2</th> <th>C1</th> <th>C2</th> </tr> </thead> </table>	Básico		Intermedio		Avanzado		A1	A2	B1	B2	C1	C2
Básico		Intermedio		Avanzado									
A1	A2	B1	B2	C1	C2								
<p>Utiliza herramienta y tecnologías digitales para crear conocimiento e innovar procesos y productos.</p> <p>Participa individual y colectivamente en el procesamiento cognitivo para comprender y resuelve los aspectos conceptuales</p>													
<p><b>A5C4</b>      <b>Resolver problemas técnicos</b></p>	<table border="1"> <thead> <tr> <th colspan="2">Básico</th> <th colspan="2">Intermedio</th> <th colspan="2">Avanzado</th> </tr> <tr> <th>A1</th> <th>A2</th> <th>B1</th> <th>B2</th> <th>C1</th> <th>C2</th> </tr> </thead> </table>	Básico		Intermedio		Avanzado		A1	A2	B1	B2	C1	C2
Básico		Intermedio		Avanzado									
A1	A2	B1	B2	C1	C2								
<p>Entiende dónde hay que mejorar o actualizar la propia competencia digital.</p> <p>Apoya a los demás en el desarrollo de sus competencias digitales.</p> <p>Busca oportunidades para el autodesarrollo y se mantiene al día con la evolución digital.</p>													
<p><b>Área 6 Usos y aplicaciones</b>      <b>Nivel de Dominio</b></p>													
<p><b>A6C1</b>      <b>Campos de aplicación y aportaciones</b></p>	<table border="1"> <thead> <tr> <th colspan="2">Básico</th> <th colspan="2">Intermedio</th> <th colspan="2">Avanzado</th> </tr> <tr> <th>A1</th> <th>A2</th> <th>B1</th> <th>B2</th> <th>C1</th> <th>C2</th> </tr> </thead> </table>	Básico		Intermedio		Avanzado		A1	A2	B1	B2	C1	C2
Básico		Intermedio		Avanzado									
A1	A2	B1	B2	C1	C2								
<p>Utiliza la competencia digital en beneficio de la humanidad, para mejora del campo profesional.</p> <p>Entiende los usos e innovaciones tecnológicas.</p>													
<p><b>A6C2</b>      <b>Campos de aplicación y aportaciones</b></p>	<table border="1"> <thead> <tr> <th colspan="2">Básico</th> <th colspan="2">Intermedio</th> <th colspan="2">Avanzado</th> </tr> <tr> <th>A1</th> <th>A2</th> <th>B1</th> <th>B2</th> <th>C1</th> <th>C2</th> </tr> </thead> </table>	Básico		Intermedio		Avanzado		A1	A2	B1	B2	C1	C2
Básico		Intermedio		Avanzado									
A1	A2	B1	B2	C1	C2								
<p>Utiliza las aplicaciones para promover los valores y la equidad de género.</p>													
<p><b>A6C3</b>      <b>Campos de aplicación y aportaciones</b></p>	<table border="1"> <thead> <tr> <th colspan="2">Básico</th> <th colspan="2">Intermedio</th> <th colspan="2">Avanzado</th> </tr> <tr> <th>A1</th> <th>A2</th> <th>B1</th> <th>B2</th> <th>C1</th> <th>C2</th> </tr> </thead> </table>	Básico		Intermedio		Avanzado		A1	A2	B1	B2	C1	C2
Básico		Intermedio		Avanzado									
A1	A2	B1	B2	C1	C2								
<p>Entiende que el uso y aplicaciones de tecnología deben ser inclusiva.</p> <p>Comparte y promueve aplicaciones innovadoras que aporten a los sectores más marginados.</p>													
<p><b>A6C4</b>      <b>Campos de aplicación y aportaciones</b></p>	<table border="1"> <thead> <tr> <th colspan="2">Básico</th> <th colspan="2">Intermedio</th> <th colspan="2">Avanzado</th> </tr> <tr> <th>A1</th> <th>A2</th> <th>B1</th> <th>B2</th> <th>C1</th> <th>C2</th> </tr> </thead> </table>	Básico		Intermedio		Avanzado		A1	A2	B1	B2	C1	C2
Básico		Intermedio		Avanzado									
A1	A2	B1	B2	C1	C2								
<p>Entiende la responsabilidad social como individuo para contribuir en el mejoramiento del cambio climático, mediante el uso de los recursos naturales de forma responsable.</p> <p>Utiliza las aplicaciones, innovaciones o desarrollos para contribuir al mejoramiento del medio ambiente.</p>													

Fase 2 Planeación del Curso mediante el Desarrollo de Competencias

Situación de integración (indicador)	Problematización	Criterios y atributos	Nivel de dominio
Selección de contenidos.	Objetivo de la asignatura	Analiza el objetivo de su asignatura dentro de un contexto práctico laboral.	
Selección de requerimientos laborales a desarrollar.	Relaciones de la materia en el plan de estudios con el Perfil de egreso en la formación del estudiante	En la planeación didáctica relaciona su materia en el plan de estudios y en el perfil de egreso con las necesidades curriculares del entorno laboral.	
Selección de conocimientos previos a evaluar.	Incorporar el conocimiento previo de los alumnos al proceso de planeación	En el proceso de planeación, considera el conocimiento previo de los alumnos.	
Selección de casos de aplicación.	Seleccionar contenidos significativos.	Incorpora contenidos significativos y relevantes para los estudiantes.	
Actualización y selección del entorno social y tecnológico.	Considerar el contexto de la realidad social e institucional de la institución y estudiantes	Contextualiza la realidad social e institucional y con base en ello diseña situaciones de integración.	
Desarrollo del contenido.	Organizar los contenidos del curso de tal manera que permita la problematización y conceptualización de los estudiantes	Organiza y secuencia los contenidos del curso de manera lógica y psicológica de tal forma que problematicen y conceptualicen a partir de las situaciones de integración.	
	Adaptar los contenidos del curso al tema del eje vertical o al diseño de situaciones de integración	Adapta los contenidos del curso al tema del eje vertical o a situaciones de integración.	
Elección de estrategias de aprendizaje.	Identificar las bases que requiero para el diseño de estrategias y actividades de aprendizaje.	Analiza las bases de un modelo pedagógico que integra las cuatro competencias específicas del estudiante.	
	Identificar los recursos (instalaciones y equipos) de la institución que requiero para desarrollar las estrategias y	Selecciona y adecua las instalaciones y equipos de la institución o del aula para desarrollar las estrategias y actividades de aprendizaje diseñadas.	

	actividades de aprendizaje.		
	Identificar las mejores estrategias de aprendizaje que puedo incorporar en el curso para el desarrollo de competencias en los estudiantes.	Analiza la estructura y los fundamentos de una secuencia didáctica o dispositivo para el desarrollo y la evaluación de competencias estudiantiles.	
Diseño de las actividades	Diseñar situaciones de integración.	Diseña situaciones de integración como base de las secuencias didácticas.	
	Relacionar los contenidos de la materia con las situaciones de integración y el diseño de actividades de aprendizaje para el desarrollo de competencias	Parte de los propósitos de su materia, para integrar los contenidos en el diseño de situaciones de integración y de las actividades de aprendizaje para el desarrollo de competencias.	
Evaluación	Definir las estrategias más adecuadas para evaluar competencias estudiantiles a partir de su desempeño.	Discute sobre las estrategias y formas más adecuadas para evaluar desempeños y competencias en sus estudiantes.	
	Diseñar los instrumentos empleados para evaluar el desempeño de los alumnos en el logro de competencias	Selecciona instrumentos de evaluación y diseña dispositivos para la evaluación de las propuestas y los proyectos de sus estudiantes.	
	Definir los criterios y atributos a integrar en las rúbricas que me permitan evaluar las propuestas y proyectos de los estudiantes	Diseña rúbricas que integren criterios y atributos para evaluar propuestas y proyectos como competencias específicas del área de estudio del alumno.	
	Evaluar impacto de las competencias desarrolladas en su aplicación en la práctica profesional	Reflexiona sobre el proceso de evaluación de competencias y su impacto en la práctica profesional de los estudiantes.	

**Fase 3 Eficacia de las Competencias Digitales adquiridas**



Fuente: Adaptado del Marco DigiComp de la Comisión Europea (Diciembre, 2020)

Además de definir los parámetros para evaluar las competencias digitales del docente, la Tabla 2.6 muestra el detalle del conocimiento de competencias digitales del estudiante, también segmentada en 6 áreas, identificando en la primer columna la clave de la competencia, posteriormente la descripción de la competencias y al final el rango de evaluación en un intervalo de básico, intermedio y avanzado.

**Tabla 3.6**

*Conocimiento de las Competencias Digitales del Estudiante*

Área 1 Información y alfabetización de datos		Nivel de Dominio					
		Básico		Intermedio		Avanzado	
A1C1	Navegación, búsqueda y filtrado de datos, información y contenido digital	A1	A2	B1	B2	C1	C2
	Busca datos, información y contenido en entornos digitales, acceder a los datos, información y contenido y navegar entre ellos.						
	Crea y actualiza estrategias de búsqueda personal						
A1C2	Evaluar datos, información y contenido digital	A1	A2	B1	B2	C1	C2
	Analiza, compara y evalúa críticamente la credibilidad y fiabilidad de las fuentes de datos, información y contenidos digitales.						
	Analiza, interpreta y evalúa críticamente los datos, la información y el contenido digital.						
A1C3	Gestionar datos, información y contenido digital	A1	A2	B1	B2	C1	C2
	Organiza, almacena y recupera datos, información y contenidos en entornos digitales. Organiza y procesa en un entorno estructurado.						
Área 2 Comunicación y colaboración							
A2C1	Interactuar mediante tecnologías digitales	A1	A2	B1	B2	C1	C2
	Comparte datos, información y contenido digital con otros a través de tecnologías digitales apropiadas.						
	Actúa como intermediario, conoce las prácticas de referencia y atribución.						
A2C2	Compartir mediante tecnologías digitales	A1	A2	B1	B2	C1	C2
	Articula las necesidades de información, busca datos, información y contenido en entornos digitales, acceder a los datos, información y contenido y navegar entre ellos.						
	Crea y actualiza estrategias de búsqueda personal						
A2C3	Compromiso ciudadano con tecnologías digitales	A1	A2	B1	B2	C1	C2
	Participa en la sociedad a través del uso de servicios digitales públicos y privados.						
	Busca oportunidades para el auto empoderamiento y la ciudadanía participativa a través de tecnologías digitales apropiadas.						
A2C4	Colaborar mediante tecnologías digitales	Básico		Intermedio		Avanzado	



## Capítulo 3 Educación basada en competencias.

		A1	A2	B1	B2	C1	C2
Utiliza herramientas y tecnologías digitales para procesos colaborativos, y para la co-construcción y co-creación de datos, recursos y conocimiento.							
A2C5	Netiquette	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Conoce las normas de comportamiento y el saber-hacer en el uso de las tecnologías digitales e interactuar en entornos digitales.							
Adapta las estrategias de comunicación al público específico y ser conscientes de la diversidad cultural y generacional en entornos digitales.							
A2C6	Gestión de la identidad digital	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Crea y gestiona una o varias identidades digitales, para ser capaz de proteger la propia reputación.							
Trata los datos que se producen a través de diversas herramientas, entornos y servicios digitales.							

### Área 3 Crear contenidos digitales

		A1	A2	B1	B2	C1	C2
A3C1	Desarrollo de contenidos	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Crea y edita contenidos digitales en diferentes formatos, expresarse a través de medios digitales.							
A3C2	Integrar y reelaborar contenido digital	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Modifica, perfecciona, mejora e integra la información y los contenidos en un conjunto de conocimientos ya existente para crear contenidos y conocimientos nuevos, originales y pertinentes.							
A3C3	Copyright y licencias	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Comprende cómo se aplican los derechos de autor y las licencias a los datos, la información digital y el contenido.							
A3C4	Programación	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Planifica y desarrolla una secuencia de instrucciones comprensibles para que un sistema informático resuelva un problema determinado o realice una tarea específica.							

### Área 4 Seguridad

		A1	A2	B1	B2	C1	C2
A4C1	Proteger los dispositivos	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Protege los dispositivos y el contenido digital, y comprende los riesgos y amenazas en entornos digitales.							
Conoce las medidas de seguridad y protección y respeta la fiabilidad y privacidad.							

## Capítulo 3 Educación basada en competencias.

<b>A4C2</b>	<b>Proteger los datos personales y la privacidad</b>	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Protege los datos personales y la privacidad en entornos digitales.						
	Entiende cómo usar y compartir información personal identificable mientras se protege así mismo y a los demás de daños y perjuicios.						
	Entiende que los servicios digitales utilizan una "Política de Privacidad" para informar cómo se utilizan los datos personales.						
<b>A4C3</b>	<b>Proteger la salud y el bienestar</b>	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Es capaz de evitar riesgos para la salud y amenazas para el bienestar físico y psicológico utilizando tecnologías digitales.						
	Es capaz de protegerse a sí mismo y a los demás de posibles peligros en entornos digitales (p. ej., intimidación cibernética).						
	Conoce las tecnologías digitales para el bienestar y la inclusión social.						
<b>A4C4</b>	<b>Proteger el medio ambiente</b>	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Conoce el impacto ambiental de las tecnologías digitales y su uso.						
<b>Área 5 Solución de problemas</b>							
<b>A5C1</b>	<b>Resolver problemas técnicos</b>	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Identifica problemas técnicos en el manejo de dispositivos y en el uso de entornos digitales, y los resuelve (desde la localización de averías hasta la resolución de problemas más complejos).						
<b>A5C2</b>	<b>Identificar necesidades y respuestas tecnológicas</b>	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Evalúa las necesidades e identifica, evalúa, selecciona y utiliza herramientas digitales y las posibles respuestas tecnológicas para resolverlas.						
	Adapta y personaliza los entornos digitales a las necesidades personales (por ejemplo, accesibilidad).						
<b>A5C3</b>	<b>Uso creativo de la tecnología digital</b>	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Utiliza herramienta y tecnologías digitales para crear conocimiento e innovar procesos y productos.						
	Participa individual y colectivamente en el procesamiento cognitivo para comprender y resuelve los aspectos conceptuales						
<b>A5C4</b>	<b>Resolver problemas técnicos</b>	Básico		Intermedio		Avanzado	

## Capítulo 3 Educación basada en competencias.

	A1	A2	B1	B2	C1	C2
Entiende dónde hay que mejorar o actualizar la propia competencia digital.	■	■	■	■	■	■▲
Apoya a los demás en el desarrollo de sus competencias digitales.	■	■	■	■	■	■▲
Busca oportunidades para el autodesarrollo y se mantiene al día con la evolución digital.	■	■	■	■	■	■▲

### Área 6 Usos y aplicaciones

A6C1	Campos de aplicación y aportaciones	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Utiliza la competencia digital en beneficio de la humanidad, para mejora del campo profesional.		■	■	■	■	■	■▲
Entiende los usos e innovaciones tecnológicas.		■	■	■	■	■	■▲
A6C2	Campos de aplicación y aportaciones	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Utiliza las aplicaciones para promover los valores y la equidad de género...		■	■	■	■	■	■▲
A6C3	Campos de aplicación y aportaciones	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Entiende que el uso y aplicaciones de tecnología debe ser inclusiva.		■	■	■	■	■	■▲
Comparte y promueve aplicaciones innovadoras que aporten a los sectores más marginados.		■	■	■	■	■	■▲
A6C4	Campos de aplicación y aportaciones	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
Entiende la responsabilidad social como individuo para contribuir en el mejoramiento del cambio climático, mediante el uso de los recursos naturales de forma responsable.		■	■	■	■	■	■▲
Utiliza las aplicaciones, innovaciones o desarrollos para contribuir al mejoramiento del medio ambiente.		■	■	■	■	■	■▲

Fuente: Adaptado del Marco DigiComp de la Comisión Europea (Diciembre,2020)

### 3.7. Tendencias Educativas Relacionadas con las Competencias Digitales

#### 3.7.1. Inteligencia Artificial en la Educación

En el capítulo 2 se abordaron algunas de las aplicaciones que ha tenido la IA, se hace énfasis en el apoyo de los organismos internacionales para hacer uso de la IA solamente en beneficio de la humanidad. La misión de la UNESCO (2021b), constituye un llamamiento intrínseco a adoptar un enfoque en materia de IA centrado en el ser humano, que tenga como objetivo reorientar el debate para incluir la función de la IA en la lucha contra las desigualdades actuales en materia de acceso al saber, a la investigación y a la diversidad de las expresiones culturales, y para que la IA no acentúe las diferencias tecnológicas entre los países y dentro de estos.

En América del Norte, la Universidad de San Diego (2020), en su portal presenta los siguientes ejemplos del uso de la IA en el sector educativo:

- Detección de plagio
- Chatbots para inscripción y retención
- Transcripción de conferencias de la facultad
- Análisis de las métricas de éxito de los estudiantes
- Integridad del examen
- Sistemas de gestión del aprendizaje
- Foros de discusión en línea mejorados
- Campus conectados
- Investigación académica


#### 3.7.2. Las Redes Sociales en la Educación

El distanciamiento social marcado por la pandemia incrementó el uso de las redes sociales, se identificó que 81 millones de usuarios se mantenían con cuentas de redes sociales en

México (Statista, 4 de mayo de 2022) y se espera que para 2023 incremente a 90 millones, además México se posiciona con el 78.3% en comparación con otros países en el uso de redes sociales como se muestra en la Figura 3.8.

**Figura 3.8**

*Tasa de penetración de redes sociales en América Latina y Caribe por país (enero 2022)*



Fuente: Statista (4 de febrero 2022)

Las redes sociales deben promover el aprendizaje y hacer uso consciente de la información, estas nos permiten socializar y eliminar las barreras socioculturales, genera autonomía y creatividad, motivación entre pares; los docentes deben involucrarse en su uso y generar una visión de aprendizaje y desarrollo en sus estudiantes. En México, jóvenes entre 16 y 24 años

preferían utilizar TikTok y un 90% visita la red social más de una vez hasta completar un promedio de 52 minutos o, lo que equivale a que cada día se visualicen mil millones de videos (El Universal, 7 de agosto de 2020). Esta situación ha permitido, que también se presente contenido de curso, comercio y muchos otros temas.

Los estudiantes también pueden promover su producción académica mediante el uso de redes sociales, establecer redes de consulta y aprendizaje comunitario entre cada plantel, sesiones de trabajo, grupos de estudio, convivencia académica, exposición de temas en videos de TikTok, hackathon<sup>15</sup>, lo anterior, les permitirá adquirir las habilidades digitales respecto a diseño, selección de contenido, comunicación, uso correcto de la lengua, entre otras. Lejos de la calificación que asigne el docente, sería importante considerar el grado de penetración que tuvo su artículo, video, presentación o lo que él sugiera, además del aprendizaje digital que conlleva, logrando con ello que comparen entre todos sus compañeros sus materiales producto de su creación e innovación para lograr mejorar su competencia.

### 3.7.3. Realidad Virtual en la educación

Algunos de los autores como Aukstankanis y Blatner (1993:7) quienes afirman simplemente que “la realidad virtual es una forma humana de visualizar, manipular e interactuar con ordenadores y datos complejos” hasta las dudas terminológicas del francés Claude Cadoz (1994) que prefiere hablar de realidades virtuales o mejor aún de “representaciones

---

<sup>15</sup> Punto de encuentro donde se inician proyectos tecnológicos innovadores, se presentan ideas y se establecen contactos, es una reunión productiva de gente de tecnología, que pudiera ampliarse a otros temas propios de su profesión.

integrales”. El recorrido nos muestra las dificultades que presenta sintetizar en pocas palabras una técnica que aún no ha terminado de configurarse.

Una de las tendencias educativas de mayor uso en los últimos años es el dispositivo de Realidad Virtual (RV); Esta aplicación permite que el ser humano sea introducido en un entorno virtual y transmite una vivencia y sensación real, estando conformado por un visor con una pantalla única y sensores de movimiento, un auricular de RV; la peculiaridad consiste en rastrear el movimiento del usuario y cambia el ángulo de la pantalla en consecuencia, teniendo opción de incluir accesorios como guantes, cintas de correr y rastreadores.

Algunos usos se dan en la Universidad de Medicina en China, Beijing, los estudiantes incorporan la realidad virtual para aprender acupuntura, tal como se muestra en la Figura 3.9 (Yau, E., 2018).

**Figura 3.9**

*Uso de la Realidad Virtual en Medicina*



Fuente: Yau, E., 19 de octubre de 2018

En el Reino Unido, la Universidad de Westminster implementó un centro de formación virtual que permite a los estudiantes de derecho penal investigar posibles escenas del crimen citado por Rose, N. (2016).

Akdere, M., Acheson, K., y Jiang, Y. (2021). Realizaron un estudio que examina la efectividad de la tecnología de RV como una plataforma de aprendizaje innovadora en el desarrollo de competencias interculturales, incluidos conocimientos, actitudes y creencias interculturales. La investigación se basó en datos de estudiantes universitarios de STEM (Science, Technology, Engineering and Mathematics) en un curso de tecnología de primer año en una gran universidad pública en el medio oeste de EE. UU. Los resultados del estudio sugieren la importancia de la inmersión (incluso cuando la movilidad no es posible) en el desarrollo de la competencia intercultural y el potencial de la tecnología de RV en el avance del aprendizaje intercultural.

### 3.7.4. Realidad Aumentada en la educación

En el estudio de Vásquez Carbonell y Silva-Ortega (2020) señalan una definición reciente de Klopfer y Squire (2008) quien sugiere que la realidad aumentada (RA) puede ser considerada como una situación que entremezcla mundos reales, siendo el mundo real, sobrepuesto de forma dinámica por un mundo virtual o información virtual. Convirtiéndose en una tendencia educativa en la competencia digital, ya que permite que los estudiantes puedan visualizar activos digitales en un mundo real con un teléfono o una tableta con una cámara y capacidad de RA.

Alatraste (2013) en su investigación “El Paradigma del Libro”, señala la reflexión sobre la transición del libro impreso al electrónico, hasta llegar a un libro de realidad aumentada,



tomando el papel del diseño como fundamental en la creación de estos materiales tanto impresos como electrónicos, para adecuarlos a las necesidades de una cultura emergente.

Algunas ventajas que presenta en la educación son las experiencias de los estudiantes en momentos educativos diferentes. Existen aplicaciones de RA como Froggipedia que permite a los estudiantes explorar los órganos internos de una rana. Otro uso en el mismo ámbito, es dar vida a las imágenes realizadas, por ejemplo, trazos geométricos y la representación del área, como se muestra en la Figura 3.10.

**Figura 3.10**  
*Representación geométrica con RA*



Fuente: Polo (2013)

Una opción de uso para los niños es que pueden utilizarla para desarrollar la imaginación y creatividad. Lo que se requiere es realizar un dibujo en cualquier papel y mediante el software de RA podrán dar vida a su dibujo, visualizándolo en su tableta o celular con los colores que utilizaron, pueden girar y jugar con él desde su dispositivo, como se muestra en la Figura 3.11.

**Figura 3.11**

*Animación de dibujos mediante RA*



Fuente: Arteaga (2015).

Pringle, J. K., et. al. (2022) llevaron a cabo 3 estudios que detallan los entornos de aprendizaje y enseñanza de la RA para facilitar la enseñanza y el aprendizaje en línea para los geocientíficos forenses, descritos en la Tabla 3.7.

**Tabla 3.7**

*Casos de estudio aplicando RA*

Estudio	Software	Resultados
1 Recursos de equipos basados en laboratorios virtuales de XR.	Thinglink Sistema de internet	Malas conexiones a Internet por parte de los estudiantes Deficientes habilidades informáticas. No se involucran bien con el aprendizaje en línea.
2 Recurso de geofísica aplicada de aprendizaje virtual.	Thinglink Sistema de internet	Igual al anterior.

## Capítulo 3 Educación basada en competencias.

Estudio	Software	Resultados
3 Desarrollo para llevar al usuario a través de una investigación de búsqueda de casos sin resolver, desde el estudio de escritorio hasta el reconocimiento de campo y las investigaciones de sitios de varias etapas.	eGame educativo de geociencia forense RA	Incremento en la comprensión del uso de equipos de geofísica y las mejores prácticas de investigaciones en fases de búsqueda de geociencia forense.

Fuente: Pringle, J. K., et. al. (2022)

En la Figura 3.12, se muestra la representación de la imagen a través del software utilizado.

**Figura 3.12**  
*Foro Thinglink*



Fuente: Pringle, J. K., et. al. (2022)

### Diferencia de la RV y la RA

Si bien el avance de la RA ha ido de la mano con la RV, podemos remontarnos al año 1993 donde la RA es mostrada como una tecnología diferente a la RV, la cual consistía, no en reemplazar el mundo de un usuario, sino en incrementar el mundo real de un usuario. Este

hecho se dio con el uso de unas gafas y HMD's, según Feiner et. al. (1993) y Prender (2014). La gran diferencia entre RV y RA es entonces que la RA trata de enriquecer el mundo alrededor de nosotros mediante la combinación del mundo real y de imágenes generadas por máquinas (Bronack, 2011) citado por Vásquez Carbonell, M. A., & Silva-Ortega, J. I. (2020), mientras que la realidad virtual crea un mundo semejante al que habitamos y se aprecia mediante las gafas.

### 3.7.5. Internet de las Cosas en la Educación

La transformación digital del sector educativo debe incluir innovación en sus procesos que mejore el aprovechamiento académico mediante el uso de tecnología. El Internet de las cosas (IoT, por sus siglas en inglés) permite incorporar herramientas que facilitan la labor de los docentes y optimizan los resultados de aprendizaje.

Internet de las cosas (IoT, por sus siglas en inglés), es una arquitectura emergente basada en la Internet global que facilita el intercambio de bienes y servicios entre redes de la cadena de suministro y que contribuye a la seguridad y privacidad de los actores involucrados (Weber, 2010 citado por Salazar et. al (2017).

Algunas ventajas que ofrece el IoT es el fomento de las capacidades de los alumnos, mejora la implicación de los estudiantes y desarrolla la autonomía. La interconexión de dispositivos y tareas eficiente la productividad de todos los actores en el proceso educativo.

Insider Intelligence, (2022), señala que los dispositivos conectados a la nube permiten a los profesores recopilar datos sobre sus alumnos y luego determinar cuáles necesitan la atención y el cuidado más individualizado; las estadísticas ayudan a los maestros a mejorar la participación de los estudiantes, así como a ajustar sus planes de lecciones, prueba de ello es la aplicación ClassDojo, entre otras, en la que los padres pueden visualizar el trabajo de sus hijos mediante fotos y videos.

### 3.7.6. Metaverso en la Educación

El término metaverso suele emplearse como sinónimo del mundo virtual tridimensional, esto es, como un espacio digital inmersivo abierto a la exploración, acción e interacción de sus usuarios. El propio Castronova define el metaverso o mundo virtual como el producto de combinar el entorno gráfico 3D de videojuegos como Tomb Rider con los sistemas sociales de chat basados en la interacción desarrollados en el mundo de los multiusuarios (Márquez, 2011).

Citando a Llamas (2020) define el metaverso como un espacio virtual en el que se recrean situaciones reales o ficticias para que las personas podamos disfrutar de nuevas experiencias. Esto es posible gracias a un dispositivo electrónico conectado a internet.

Esta tendencia educativa conjunta las tecnologías RA y RV para interactuar usando un holograma o avatar, es posible, tocar y mover objetos e influir en el entorno; mediante la

interacción se fortalece la competencia aprender a hacer. Se ha utilizado para realizar prácticas de procedimientos quirúrgicos, antes de realizarlos directamente al paciente.

En el aspecto profesional es posible realizar reuniones para gestionar proyectos desde la oficina virtual.

El Turismo es un fuerte ejemplo de su uso, puedes realizar viajes virtuales para conocer los atractivos turísticos, lo cual reduce costos y tiempos, para una selección más adecuada de las opciones que visitarás, también es posible visitar exposiciones artísticas.

El Ministerio de TIC, Ciencia y Planificación del Futuro de Corea del Sur destinará 223,700 millones de won coreanos, lo que es lo mismo a 186.7 millones de dólares americanos, en crear un amplio ecosistema de metaverso que permita el crecimiento de los contenidos digitales y el crecimiento empresarial en el país. (Newar, B., 2022).

La corriente actual de innovación pedagógica se desarrolla básicamente en el ámbito de la educación tecnológica y es en ella donde se definen la competencia genérica y la competencia específica. Desde el punto de vista genérico una competencia hace referencia a procesos generales de estrategias de aprendizaje, tanto intelectuales como de procesos socio afectivos, mientras que las competencias específicas se centran en la búsqueda de una mayor vinculación entre conocimientos, destrezas, habilidades y valores, trascendiendo los procesos

educativos tradicionales para conformar en los estudiantes, una mentalidad acorde con el conocimiento lógico, la reflexión metódica y la práctica creativa.

Ha quedado determinado en este capítulo, que una competencia es un concepto basado en las acciones que los estudiantes deberán realizar en su actividad profesional, estableciendo así el perfil general del egresado y los lineamientos que determinarán al conjunto de conocimientos, procedimientos y actitudes combinados, coordinados e integrados, en el sentido que el individuo ha de “saber hacer” y “saber estar” para el ejercicio profesional. Se ha hecho mención también que las técnicas de aprendizaje son útiles y necesarias para “aprender a aprender” dado que permiten organizar la información, seleccionar los conceptos relevantes o establecer relaciones entre diferentes partes de una información, de igual forma se abordaron las tendencias de las competencias digitales.

El tema sobre competencias es uno de los aspectos teóricos de la investigación que se desarrolla, y se ha fundamentado la utilidad de los conceptos. En este mismo contexto del marco teórico abordamos en el siguiente capítulo el tema de e-learning, pieza clave para potenciar las competencias en un ambiente de aprendizaje donde el único recurso para su uso es la tecnología.



## Capítulo 4 **E-learning**



## Capítulo 4 E-learning

### 4. El Sector Educativo antes de la Pandemia

El sector educativo ha sufrido grandes cambios durante los últimos años y ha sido impactado por diversos acontecimientos, algunos de ellos son el desarrollo tecnológico, los altos índices de desempleo, la pobreza, violencia intrafamiliar y la pandemia COVID-19, entre otros. Organismos Internacionales han mostrado su preocupación ante este escenario, como es el caso del Banco Mundial (2018), quien presentó el Informe sobre el desarrollo mundial 2018, en este advirtió sobre una crisis en el aprendizaje a nivel mundial e instó a aumentar las mediciones y actuar en función de la evidencia.

#### 4.1. La Crisis del Sector Educativo

Otro organismo que mostró preocupación es la ONU, informó el caos provocado por la pandemia de COVID-19 a la educación en todo el mundo y refirió que 1600 millones de escolares y universitarios interrumpieron sus estudios en el peor momento de la emergencia, además aseveró que la crisis del sector educativo trasciende las cuestiones de acceso y desigualdad, y citó el ritmo acelerado de los cambios que experimenta el mundo en los ámbitos del trabajo, la tecnología, el clima, la confianza entre las personas y las instituciones Guterres (2022).

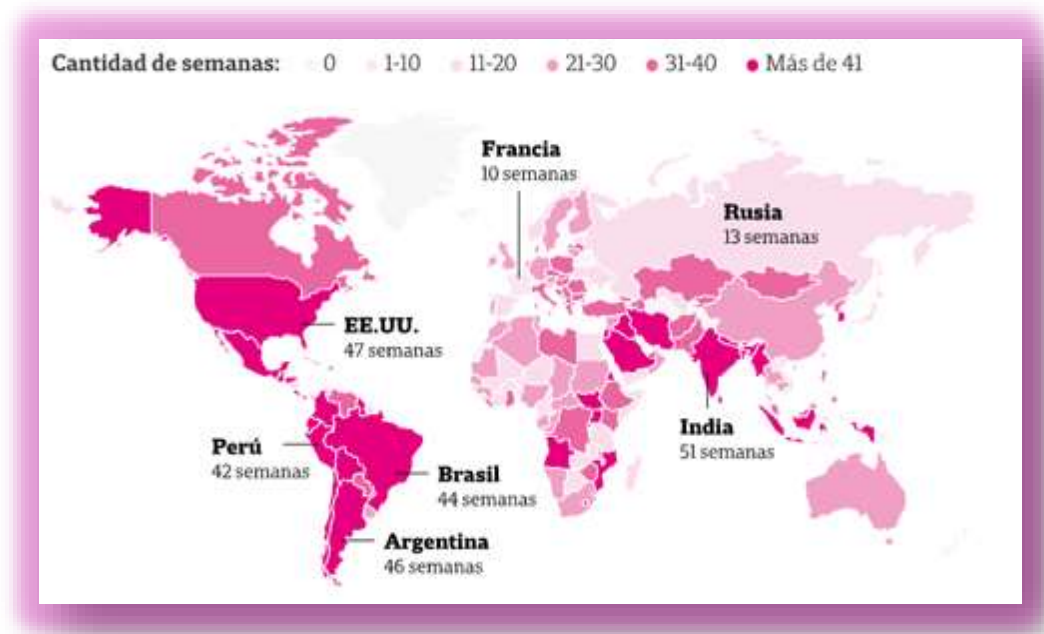
La ONU se ha referido al efecto de la pandemia en la educación como una “catástrofe generacional” que duraría décadas con un impacto negativo en el desarrollo mundial, (REDEM, 2021).

En este escenario el Banco Interamericano de Desarrollo (BID) ha mencionado que “El aislamiento social que han asumido los países para frenar el avance del virus ha evidenciado nuevas realidades en el ámbito de las habilidades del siglo XXI (Aguerrevere, et. al (2020).

La pandemia ha marcado un antes y un después en la redefinición de todos los sectores; considerando que el sector educativo, es la base para la generación y fortalecimiento económico de un país. El cierre de escuelas a nivel mundial, incrementó la crisis en el sector educativo, la Figura 4.1 presenta la duración en semanas que han permanecido cerradas las escuelas con corte a abril de 2021.

**Figura 4.1**

*Cierre de escuelas a nivel mundial durante el COVID-19.*

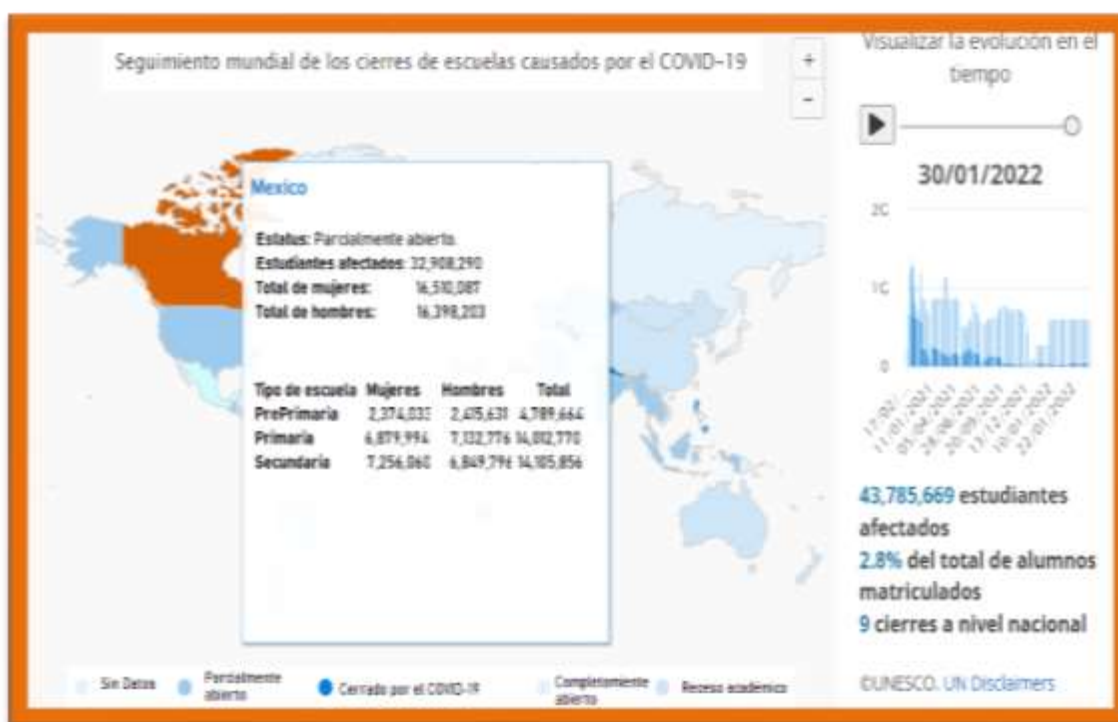


Fuente: UNESCO 2022

Los organismos internacionales han mostrado gran preocupación por los efectos post-pandémicos y la estimación en la recuperación tanto económica como educativa. Según datos presentados por la UNESCO (2022) al 30 de enero de 2022 durante la COVID-19, en México se afectó a 32'908,290 estudiantes; a nivel Preprimaria 4'789,664, Primaria 14'012,770 y Secundaria 14'105,856, estas cifras se presentan en la Figura 4.2. "Estudiantes afectados en México durante la pandemia COVID-19<sup>16</sup>".

**Figura 4.2**

*Estudiantes afectados con el cierre de escuelas durante el COVID-19.*



Fuente: UNESCO 2022


En estudios nacionales, el Instituto Nacional de Estadística, Geografía e Información (INEGI) identificó a través de la Encuesta para la Medición del Impacto COVID-19 en la Educación

<sup>16</sup> <https://en.unesco.org/covid19/educationresponse#durationschoolclosures>

(INEGI, 2021), que de los 54.3 millones de personas de 3 a 29 años, 13.1% (7.1 millones) corresponden al nivel superior; en la Figura 4.3 se muestra que solamente el 97.8% concluyeron y el 2.2% no concluyeron el ciclo escolar 2019-2020.

**Figura 4.3**

*Distribución porcentual inscrita en el ciclo 2019-2020 nivel superior que concluyó. .*




Fuente: adaptada INEGI. Encuesta para la Medición del Impacto COVID-19 en la Educación, nivel superior

La distribución porcentual de la población de nivel superior inscritos en el ciclo escolar 2019-2020 se muestra en la Figura 4.4, en esta se observa que el 76% se encuentra inscrito en instituciones públicas y 24% en privadas, es decir aproximadamente  $\frac{1}{4}$  de la población a nivel superior está inscrita en las instituciones privadas.

**Figura 4.4**

*Inscritos en el ciclo escolar 2019-2020, nivel superior por tipo de sostenimiento.*



Fuente: adaptada INEGI. Encuesta para la Medición del Impacto COVID-19 en la Educación, nivel superior.

La resiliencia a la educación en línea presentó un alto índice de deserción escolar; en la Figura 4.5 destaca que el 2%, no concluyó el ciclo escolar en instituciones públicas y el 4.2% en privadas.

**Figura 4.5**

*Inscritos por tipo de sostenimiento y su condición escolar.*




Condición	Pública	Privada
Concluyó	98.0%	95.8%
No concluyó	2.0%	4.2%

Fuente: INEGI. Encuesta para la Medición del Impacto COVID-19 en la Educación

Entre las causas para no concluir el ciclo escolar mostrados en la Figura 4.6., resalta una distribución porcentual del 44.6% asociado a la COVID-19, el 30% por otra razón, el 17.1% a causa del trabajo y el 8% por falta de dinero o recursos.

**Figura 4.6**

*Inscritos en el ciclo escolar 2019-2020, por motivo de no conclusión en el nivel superior.*



Fuente: INEGI. Encuesta para la Medición del Impacto COVID-19 en la Educación

El INEGI (2021) refiere la opinión de las principales desventajas de la educación en línea: señalando que el 58.3%, opinan que no se aprende o se aprende menos que de manera presencial, 27.1% por falta de seguimiento al aprendizaje de los alumnos y 23.9% por falta de capacidad técnica o habilidad pedagógica de padres o tutores para transmitir los conocimientos. Los datos proporcionan evidencia de la crisis educativa presentada durante la pandemia y la resiliencia al uso de e-learning, además de la necesidad de implementar estrategias que fortalezcan las competencias de los estudiantes.

Barrón (2020) considera que la educación en línea sin duda es necesaria, pero insuficiente, si de entrada no se cambian los paradigmas educativos, si no se hace un análisis profundo de los currículos, de los contenidos enciclopédicos centrados en lo disciplinario, de la enseñanza, del aprendizaje y de la evaluación, de la práctica docente y de la gestión académico-administrativa.

En palabras de Silas Casillas y Vázquez Rodríguez (2020), este proceso de transición ha tenido a los profesores universitarios como los actores clave en la transferencia emergente de la modalidad presencial a lo que ahora se conoce como Enseñanza Remota de Emergencia (ERE).

Los datos presentados por la Universidad Nacional Autónoma de México (UNAM), relacionado con el número de materias reprobadas y recursadas por los estudiantes de nivel Licenciatura

en 2018, señalan que el 60% reprobó al menos una materia y el 59% recurrió más de una materia, la información es presentada en el Tabla 4.1.

**Tabla 4.1**

*Índice de reprobación y recursamiento a nivel Licenciatura durante 2018*

Extraordinarios presentados			Materias recurridas		
Extraordinarios	Frecuencia	Frecuencia relativa	Materias recurridas	Frecuencia	Frecuencia relativa
Ninguno	10,078	39.62	Ninguna	10,313	40.54
1-3	7,538	29.63	1 -2	7,274	28.59
4-6	4,097	16.11	3-más	7,851	30.86
7 o más	3,714	14.6	No contestó	1	0
No contestó	12	0.05			
<b>Total</b>	<b>25,439</b>	<b>100.01</b>	<b>Total</b>	<b>25,439</b>	<b>99.99</b>

Fuente: UNAM<sup>17</sup>

Los hechos reafirman los altos índices de reprobación, los resultados del aprendizaje esperado por parte de los alumnos han estado centrados en la memorización de lo enseñado o en los procedimientos aprendidos para enfrentar situaciones predecibles.

Ante estos estilos de actuación resulta lógico también que las evaluaciones persigan la constatación de lo que el alumno recuerde o la forma en que presenta lo aprendido, sin margen al uso creativo del conocimiento, pero también es necesario plantear la educación en términos de las demandas laborales para que los estudiantes demuestren que tienen las competencias acordes a las funciones laborales como se planteó en el capítulo anterior.

<sup>17</sup> <https://www.estadistica.unam.mx/>, los criterios seleccionados en la página fueron todos los planteles, sin distinción de género, durante el año 2018, materias recurridas y reprobadas respectivamente.

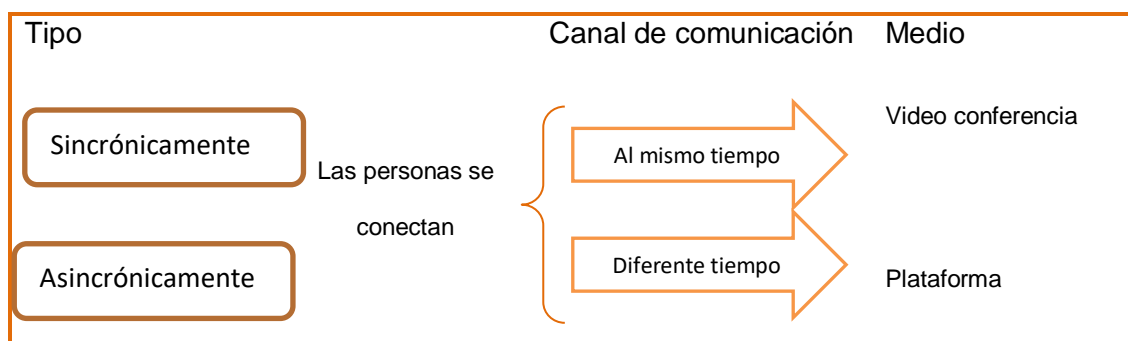
### 4.2. Características del e-learning

En la década de los 90 aparece el e-learning, asociado a la educación a distancia a nivel superior y empresarial, basado en el proceso de aprendizaje remoto que da facilidad mediante el uso de las tecnologías de la información y comunicación. (Barbera, 2008) y la Comisión Europea (2003), lo define como la utilización de las nuevas tecnologías multimedia y de Internet para mejorar la calidad del aprendizaje facilitando el acceso a recursos y servicios, así como a la colaboración e intercambio remoto.

Podemos destacar la diferencia entre la educación a distancia y el e-learning ya que, este último considera el uso del internet y la tecnología para el aprendizaje sin la necesidad de que el docente se encuentre conectado de forma sincrónica con el estudiante, siendo la interacción y la comunicación una parte fundamental del modelo, algunas de las características del e-learning se describen en la Figura 4.7.

**Figura 4.7**

*Características del e-learning*



El e-learning presenta ventajas al dinamizar la educación haciendo uso del internet y permitiendo la comunicación asíncrona al mismo tiempo presenta desventajas al requerir



estrategias para lograr la atención, concentración del estudiante así como una autogestión y motivación personal. La sobre demanda durante la pandemia del e-learning obligó a los docentes y a los estudiantes a adquirir las competencias digitales, al mismo tiempo incrementa la brecha digital en aquellas zonas en las que aún no se cuenta con internet.

### 4.3. Evolución Tecnológica del e-learning

Downes (2012) describe la evolución del e-learning en 7 generaciones descritas en la Tabla 4.2; generaciones que no necesariamente son excluyentes, sino que han ido conviviendo a lo largo del tiempo.

**Tabla 4.2**

*Evolución tecnológica del e-learning Downes*

Generación	Características	Aplicación
0	Diseño de recursos multimedia en línea.	Contenido instructivo. Actividades basadas en pruebas. Cuestionarios ilustrativos.
1	Comunicación virtual.	Uso de correo e internet.
2	Juegos.	Se incluyen juegos para el aprendizaje en la computadora.
3	Gestores de aprendizaje (LMS).	Conexión de contenidos de la generación cero con la plataforma,
4	Uso de la Web 2.0.  Uso de dispositivos móviles	Interacción social entre los alumnos. Los nodos son sustituidos por personas en lugar de computadoras. Aprendizaje mediante el móvil.
5	Cómputo en la nube y contenido abierto.	Contenido abierto.
6	Generación de recursos y espacios más amplios. El aprendizaje ya no está encapsulado en un único lugar. Conjunto de nodos.	Cursos masivos (MOOC's).  El estudiante representa a cada nodo.

Fuente: Adaptado de Downes (2012)

La Tabla 4.3 muestra la opinión de otros autores como García-Peñalvo y Seoane- Pardo (2015), ellos consideran su evolución en tres generaciones:

**Tabla 4.3.**

*Evolución tecnológica del e-learning*

Generación	Características	Aplicación
1	Plataformas de aprendizaje en línea Aulas y Campus virtuales.	Blackboard. Moodle.
2	Interacción entre compañeros Comunicación entre profesores y estudiantes.  Desarrollo de la web 2.0. Tecnologías móviles.	Foro. Chat.  Recursos abiertos.
3	Deja de estar asociado de forma exclusiva a las plataformas de aprendizaje en línea.	Se incluyen juegos para el aprendizaje en la computadora.

Fuente: Adaptado de García-Peñalvo y Seoane- Pardo (2015)

Un elemento importante en la evolución del e-learning es que se van generando recursos y espacios cada vez más amplios y complejos en los que participan múltiples agentes. El aprendizaje ya no está encapsulado en un único lugar sino en un conjunto de nodos (Begoña, 2018). La inclusión de la tecnología en el e-learning, favorece la dinámica en el aprendizaje al contribuir a la actualización continua de materiales, dada la continua incorporación de aplicaciones o recursos tecnológicos. En este orden de ideas, en la evolución constante de la tecnología, la formación educativa y el aprendizaje, es necesario considerar un plan de emergencia tanto en la educación en línea como presencial que sea activado de forma inmediata para no retrasar el aprendizaje y que consolide aspectos de mejora continua y calidad, García-Peñalvo y Seoane-Pardo (2015, p. 132) definen el e-learning como:

Un proceso formativo, de naturaleza intencional o no intencional, orientado a la adquisición de una serie de competencias y destrezas en un contexto social, que se desarrolla en un ecosistema tecnológico en el que interactúan diferentes perfiles de usuarios que comparten contenidos, actividades y experiencias y que, en situaciones de aprendizaje formal, debe ser tutelado por actores docentes cuya actividad contribuya a garantizar la calidad de todos los factores involucrados.

El e-learning conlleva un trabajo integral para su adecuado funcionamiento, a diferencia de la educación presencial; este requiere la elaboración de material digital, selección de contenidos, imagen, diseño, colores; uso y aplicación de la plataforma que administra el contenido, apoyo tecnológico para atender la operación de la plataforma, entre otros.

### 4.4. La tecnopedagogía en el e-learning

La tecnopedagogía se refiere a prácticas (de enseñanza) que tienen en cuenta aspectos tanto pedagógicos (métodos de enseñanza y aprendizaje, motivación, desarrollo de habilidades de los estudiantes) como tecnológicos (uso de computadoras, internet, pizarras interactivas, etc.)

Durante la pandemia se potenció el uso de y redes sociales como Facebook, twitter, TikTok, YouTube, utilizadas como medio para compartir información en tiempo real y comunicarse, las barreras geográficas se han difuminado y dieron paso a una gran apertura de conocimiento, la Figura 4.8 concentra los recursos tecnológicos que pueden utilizar tanto los docentes y como los alumnos; segmentado en temas específicos como: comunicación, creación de contenido, gestión, evaluación de aprendizaje, organización de ideas y pizarrones, entre otros.

En el siguiente link puedes consultarla y al dar clic a cada ícono te muestra una reseña de la utilidad que tiene y la liga del recurso <https://appsparaprofes.com/tabla/>.

**Figura 4.8**  
Recursos tecnológicos para el aprendizaje.



Fuente: Oviedov Andrea (s/f)

Cabe aclarar que aunque la tabla periódica señala que el uso es para profesores, cualquier persona puede utilizar los recursos.

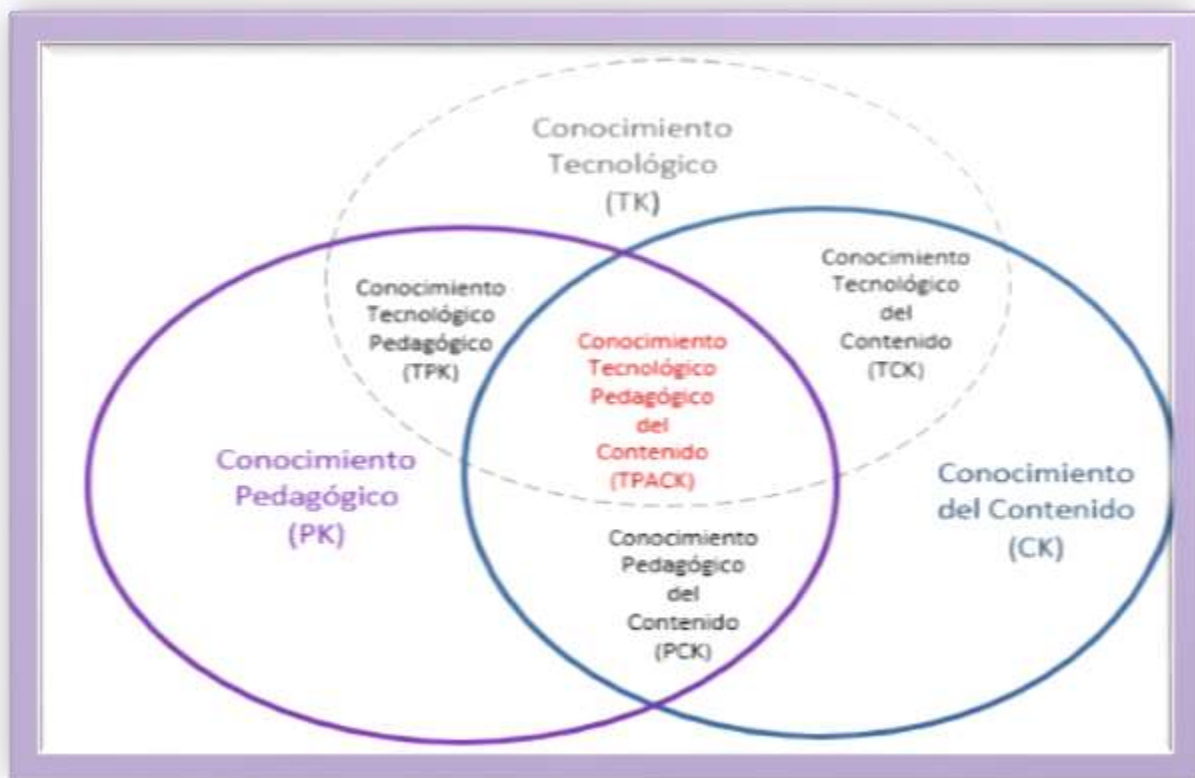
### 4.4.1. Modelo TPACK

El uso de la tecnología en el sector educativo ha impulsado al desarrollo de modelos que incluyan la pedagogía, uno de estos modelos es el TPACK. El modelo TPACK, basado en las siglas que corresponde en inglés al concepto Technological Pedagogical Content Knowledge (Conocimiento Técnico Pedagógico del Contenido) estudia la integración de la tecnología en la educación. Este modelo fue desarrollado entre 2006 y 2009 por los profesores Punya Mishra y Matthew J. Koehler, y se basa en la combinación de tres variables en las que cada docente debe formarse: conocimiento tecnológico, conocimiento pedagógico y conocimiento del contenido (UNIR, 2020).

Mishra y Koehler (2006) especifican que la tecnología puede enriquecer todas las prácticas pedagógicas, se basa en facilitar la planeación, organización y elaboración de actividades escolares como la discusión en foros por medio de la plataforma Moodle y la creación de contenidos en la herramienta Web 2.0 (Papanikolaou, Makri y Roussos, citados en Salas, 2019).

El modelo mostrado en la Figura 4.9., presenta un diagrama de Venn, en el que expone como base fundamental el conocimiento y en la intersección de todos los elementos se incorpora la tecnología, pedagogía y contenido.

**Figura 4.9**  
*Modelo TPACK*

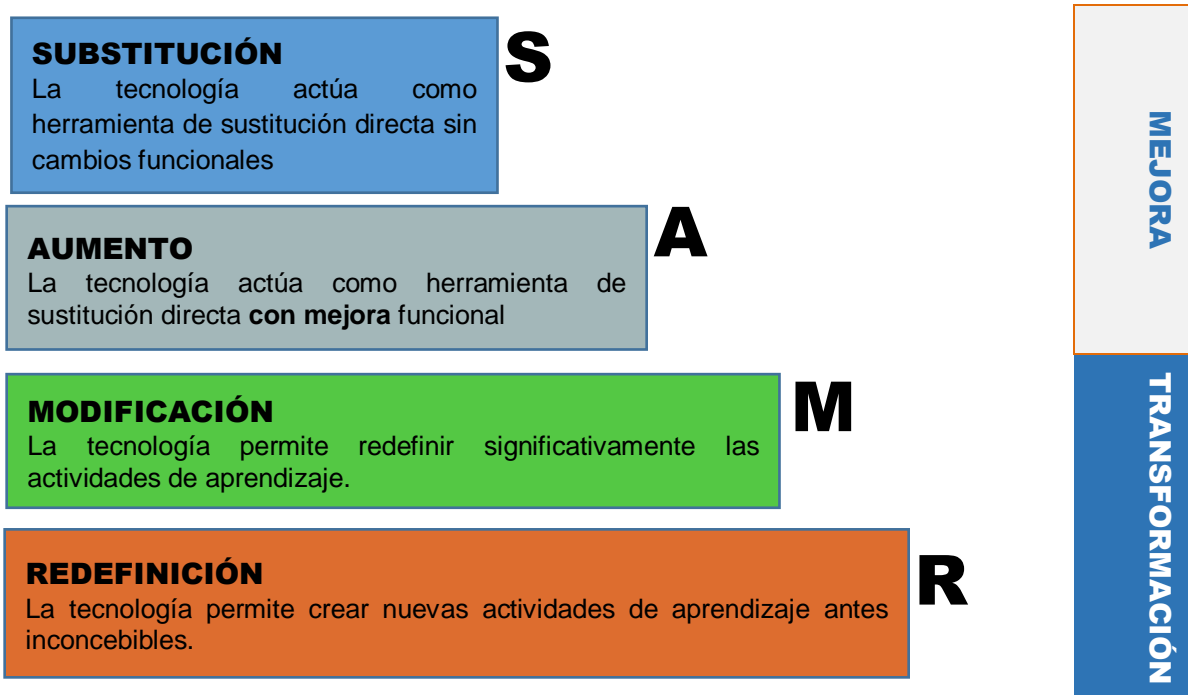


. Fuente: Mishra y Koehler (2006)

#### 4.4.2. Modelo SAMR

El modelo de Sustitución, Aumento, Modificación y Redefinición (SAMR), está compuesto por cuatro funciones que ejercen las TIC en los ambientes de aprendizaje: la Sustitución y Aumento buscan mejorar las actividades de aprendizaje con el uso de las TIC; y la Modificación y Redefinición tienen como propósito, transformar mediante las TIC, actividades de aprendizaje que realizan los docentes, representado en la Figura 4.10.

**Figura 4.10**  
*Modelo SAMR.*



Fuente: Dr. Rubén Puentedura (2006)

La tecnopedagogía nos permite reflexionar en los elementos que conforman el aula virtual para consolidar el aprendizaje.

Los docentes se han visto en la necesidad de incorporar o reformular las aulas virtuales (AV), al considerarlas como el único espacio de enseñanza y de aprendizaje que tienen los estudiantes para cumplir con los objetivos de cada asignatura (Digión, y Álvarez, 2021).

El uso de e-learning resalta la importancia de seleccionar materiales, revisar, citar, estructurar y organizar, representa un esfuerzo adicional y de colaboración al integrar la evidencia de la participación tanto del docente como del alumno. Existe diversidad en las dimensiones

pedagógicas que utilizan para la creación de AV. Barberá (2008) señala los elementos o componentes básicos que configuran un aula son: componentes de planificación, de consulta, de comunicación y de seguimiento. Area y Adell (2009) considera 4 dimensiones:

- **Dimensión informativa:** Contenido y recursos que el docente presenta, mediante el uso de recursos multimedia o software especializado en la materia, para el aprendizaje de los estudiantes.
- **Dimensión Práctica:** Acciones, tareas o actividades que los estudiantes deben realizar en el aula virtual planificadas por el docente.
- **Dimensión comunicativa:** Recursos y acciones de interacción social entre estudiantes y el profesor. Producida a través de herramientas como los foros, los chats, la mensajería interna, el correo electrónico, la videoconferencia o audio conferencia.
- **Dimensión tutorial y evaluativa:** Funciones docentes o papel que el profesor debe realizar en el marco de un curso virtual.

Nuestra discusión de la tecnopedagogía en la sección anterior muestra cómo esta combinación de tecnología con pedagogía exige experiencia en diferentes campos de especialización y habilidades para aplicar múltiples herramientas. Subraya la inevitabilidad de la formación de profesores en tecnología educativa.

La tecnopedagogía es la base del éxito del e-learning y en consecuencia de los estudiantes, al conocer lo que se espera de ellos, las herramientas que utilizarán durante el curso, ¿cómo afrontar los cambios tecnológicos?, entre otras, serán estudiantes autogestivos, auto



regulados y seguros para enfrentar situaciones de conflicto, angustia o estrés derivado de las materias.

Actualmente, existe gran cantidad de recursos tecnológicos para dinamizar la educación; ejemplo de ello y sus características son presentados en la Figura 4.11. Los materiales educativos consideran el uso de la gamificación, el aprendizaje móvil, el aprendizaje blended, la educación expandida y el aprendizaje basado en la experimentación.

**Figura 4.11**  
*Recursos Tecnopedagógicos*



### 4.5. Innovación en el e-learning

Constantemente se desarrollan aplicativos para facilitarnos el trabajo o recursos como la inteligencia artificial que coadyuva en el proceso de enseñanza aprendizaje. Gurukkal (2021) refiere que la tecnología de inteligencia artificial (IA) se ha utilizado cada vez más en una variedad de tareas cognitivas, probablemente desde hace más de una década. La tecnología de IA se dirige hacia el diseño de un aprendizaje, razonamiento y toma de decisiones más profundos basados en análisis de datos enormes. Es capaz de diseñar dispositivos de interfaz de aprendizaje de entrega interactiva de conocimiento en extremos de usuario personalizados (Holstein et al., 2018).

Desarrollando interfaces de usuario, más allá de aplicaciones y herramientas que responden al tacto, toque y deslizamiento, la IA ahora permite la operación a través de acciones físicas, gestos, movimientos corporales, expresiones faciales y palabras (Lathuilliere et al., 2019).

La apertura del e-learning para proporcionar cursos masivos permite administrar los datos de los estudiantes y analizar su avance en tiempo real. Otra forma de comunicar el aprendizaje en línea es a través de las redes sociales; estas facilitan la comunicación mediante la creación de contenido mediante videos que tienen un tiempo aproximado de 2 a 5 minutos, desarrollando además competencias digitales y fomentando la creatividad.

Esta constante reflexión y mejora de los procesos hacia la consecución de altos niveles de calidad es hoy una de las principales hojas de ruta para cualquier entidad y profesional que la conforma, y es aquí donde la intervención de los nuevos escenarios y marcos de aprendizaje condiciona y cuestiona todo el proceso de consecución de la calidad, de su relevancia y sus diferentes interpretaciones (Fernández et al., 1999; Córdova et al., 2017).

Paralelo al uso del e-learning se deberán considerar métricas de calidad que permitan la mejora continua para estandarizar procesos o en su caso adecuarlos a las necesidades tanto de los docentes como de los alumnos. La emergencia sanitaria demandó el uso inmediato de la tecnología, pero después de casi dos años de hacer uso de esta, es necesario documentar las lecciones aprendidas, la curva de aprendizaje tanto de los actores del sistema de enseñanza aprendizaje como de los tutores para mejorar la calidad de los contenidos y de las prácticas. Del mismo modo en que medimos el aprovechamiento de los estudiantes, los datos utilizados en las plataformas educativas deberán permitirnos medir la productividad del docente. Refiriéndome como productividad a que ambos cuenten con las competencias digitales que demanda el mercado laboral para integrarse a una sociedad cada vez más competitiva.

### **4.6. Calidad en el Ecosistema del e-learning**

Como he mencionado la educación en línea cobró importancia durante la pandemia, pero sus orígenes fueron mucho antes, su uso se fue intensificando y produjo el empleo abrupto de la educación a través del e-learning, sin la planeación adecuada y esto incrementó la crisis en el

aprendizaje, además de otros factores como la falta de autodisciplina, autorregulación, administración del tiempo, perseverancia, resistencia al cambio, entre otros. Los factores anteriores deben ser medibles y considerados en el estudiantado para lograr el éxito en la educación con el uso del e-learning, dada la gran cantidad de recursos tecnológicos adicionales con los que podemos contar en esta modalidad.

La base de la mejora continua consiste en identificar las áreas a fortalecer mediante la evaluación de los servicios proporcionados, basados en esta medición es que podemos identificar aquello que se debe mejorar. En el marco de la evaluación de la calidad Ortiz-López et. al (2021) elabora una propuesta con base en el análisis de diversos autores para medir la calidad en el e-learning en Educación Superior y consta de cuatro dimensiones que evalúan las diferentes perspectivas y componentes de la calidad, en esta investigación además se desarrollaron los componentes de “calidad en el aprovechamiento del alumno y calidad en la mejora continua”:

### 4.6.1. Calidad de la Institución

La institución centra sus bases de la calidad de las políticas institucionales que implementa y desarrolla (EC1), en su misión y visión (EC2), en la respuesta y en la ayuda que la institución ofrece a sus usuarios en materia de e-learning (EC3); en las políticas en materia de coordinación pedagógica referidas al e-learning (EC4), en los canales de comunicación (EC5), en el tiempo de respuesta que la institución de al docente respecto a situaciones relacionadas con el e-learning (EC6), el tiempo de respuesta que la institución proporcione al alumno respecto a situaciones relacionadas con el e-Learning (EC7).

### 4.6.2. Calidad Docente

La evaluación referida a la función docente, su formación y su preparación en la materia a impartir (EC-8), las estrategias docentes y las metodologías que implementan en las enseñanzas en el e-learning (EC-9), los materiales y los recursos a las plataformas de enseñanza (EC-10), la acción tutorial, el acompañamiento de los docentes a su alumnado en el e-learning (EC-11), la planeación presentada, la calidad del contenido, el nivel de trabajo requerido a los alumnos es acorde con el tiempo estimado, la carga de trabajo presentada en el curso, las métricas y escalas de evaluación, canales de comunicación del docente (EC-12) y tiempo de respuesta del docente al alumno (EC-13).

### 4.6.3. Calidad del Sistema de Aprendizaje o Plataforma

Prácticamente la totalidad de instituciones poseen plataformas de esta índole, contando con suficientes herramientas para dotar también de calidad a los sistemas formativos (Velasquí, 2017), pero durante la emergencia sanitaria de la pandemia se vislumbró que algunas instituciones académicas que estaban en la modalidad presencial no hicieron uso de alguna plataforma para el aprendizaje.

En el ecosistema de la educación mediante e-learning la plataforma es el principal recurso tecnológico y es mediador en el aprendizaje, por lo que su análisis se considera de gran impacto para medir la calidad de la enseñanza-aprendizaje, esta dimensión comprende el funcionamiento del sistema institucional –analizando su funcionamiento (EC-14), accesibilidad (EC-15), adaptabilidad (EC-16), Tiempos fuera de conexión (EC-17) donde el valor de 100 representaría que siempre está disponible y 0 que no existe la conexión de la plataforma, nivel

de satisfacción del docente con el uso de la plataforma (EC-18), nivel de satisfacción del alumno con el uso de la plataforma (EC-19), métricas de calidad de soporte técnico de la plataforma (EC-20).

### 4.6.4. Calidad de la Evaluación del Programa

Con un enfoque desde la evaluación de la preparación previa del programa (preparación de recursos y del programa, del entorno virtual) (EC-21), la evaluación procesal (EC-22), la evaluación de la calidad del programa (EC-23), la evaluación del contenido del programa, (EC-24), la evaluación de los recursos tecnológicos integrados (EC-25) y la evaluación de la pedagogía incorporada (EC-26).

### 4.6.5. Calidad del Aprovechamiento del Alumno

La importancia de identificar áreas de oportunidad, considera la evaluación en la calidad del aprovechamiento del alumno, ya que no necesariamente realizar muchos trabajos o tareas es significado de aprendizaje, los ejes considerados son: evaluación de la participación (EC-27), el trabajo en equipo (EC-28), la calidad de los trabajos (EC-29), la autonomía (EC-30), la mejora en la entrega a tiempo (EC-31) y la mejora en la calidad en el aprendizaje (EC-32).

### 4.6.6. Calidad en la Mejora Continua

La importancia de la mejora continua, cobra relevancia en un mundo en el que la transformación tecnológica se convierte en la solución tecnológica del presente y la educación en línea no debe permanecer estática, toda vez que los contenidos deben ser actualizados y

acordes con la demanda laboral. En este apartado se consideran la evaluación de actualización de contenidos (EC-33) y el seguimiento y retroalimentación docente e institucional (EC-34).

De forma global se realiza la suma de todas las evaluaciones y se integra en el concepto: Evaluación final (EC-35).

### 4.7. Aportaciones del e-learning

Las empresas adoptaron hace varios años el e-learning, debido a los beneficios que presentaba en costos, tiempos y productividad de sus empleados para la mejora continua y la capacitación en beneficio de su capital humano. Algunas de las aportaciones a la mejora del aprendizaje son las siguientes:

- Incremento en la capacitación continua.
- Incremento en la autonomía y responsabilidad del estudiante.
- Autorregulación en el proceso de aprendizaje.
- Superación de las limitaciones físicas profesor-alumno por falta de espacio.
- Interacción instructor-alumno de forma asíncrona.
- Flexibilidad en los tiempos.
- Diversidad en las fuentes de consulta y recursos tecnológicos
- Aprendizaje colaborativo.

La educación en línea y la presencial, ambas representan excelentes opciones de aprendizaje y actualmente aquellos alumnos que dieron continuidad a sus estudios durante la pandemia, podrán valorar mejor cada modalidad.

Es importante destacar que del mismo modo en que la tecnología cambia e innova, el e-learning debe adaptarse a la transformación digital y a las necesidades del estudiantado, debido a que mediante esta modalidad el esfuerzo en recursos debe ser mayor para mantener centrado al estudiante en el aprendizaje, no existe un sentido de pertenencia con la institución como se puede percibir en la educación presencial, situación que desmotiva a los estudiantes, al no existir una comunicación cercana tanto con sus docentes como con sus compañeros de grupo; en consecuencia en algunos casos se crean sentimientos de soledad y angustia situación que repercute en el aprovechamiento.

Las revisiones realizadas de algunos modelos tecno pedagógicos fortalecen la instrucción educativa del e-learning, como conclusión del capítulo es importante resaltar que el análisis realizado, no pretende sustituir la educación presencial, en opinión del autor, se considera de suma importancia valorar el papel del docente en la educación en línea, ya que el ecosistema es más complejo y lograr la retención y participación activa del estudiante también requiere de mayores recursos y estrategias.

Para dar continuidad al marco teórico el siguiente capítulo describe datos importantes sobre los modelos de Machine Learning como un sub-campo de la IA, mismo que cobra importancia por la asistencia que ofrece a través del reconocimiento de patrones y la analítica de grandes volúmenes de datos.





## Capítulo 5 **Machine Learning**

## Capítulo 5 Machine Learning.

### 5. Machine Learning

El Machine Learning (aprendizaje máquina, ML por sus siglas en inglés) es un sub-campo de la inteligencia artificial. Este ayuda a los ordenadores a aprender y actuar como seres humanos con la ayuda de algoritmos y datos. Una definición del machine learning señala que dado un conjunto de datos, un algoritmo de aprendizaje máquina aprende diferentes propiedades de estos e infiere las propiedades que se pueden presentar en el futuro (Valdemar et al., 2021). En otra investigación Godoy (2017) y Mitchell (1997, p. 15) afirman que el aprendizaje máquina es un área que estudia cómo construir programas de computadoras que mejoren su desempeño en alguna tarea gracias a la experiencia.

De acuerdo con lo anterior, el ML dará una aportación al desempeño de las competencias digitales de los estudiantes de nivel superior mediante e-learning, por lo que se considera necesario conocer en primer término las aportaciones que ha dado y posteriormente las bases, fundamentos y conceptualización para generar un modelo. Para profundizar en el campo del ML a continuación se da una breve descripción de su evolución.

#### 5.1. Historia del Machine Learning

Durante los últimos años se ha potenciado el uso del ML, dado el crecimiento vertiginoso de los datos y la necesidad de analizar y predecir sucesos en diferentes sectores. Los inicios se remontan a 1950, cuando el científico Alan Mathison Turing desarrolló el conocido “Test de Turing”, mencionado en el capítulo 2. En 1952 Arthur Samuel escribió el primer programa de

ordenador capaz de aprender. Este consistía en un programa que jugaba a las damas y que mejoraba su juego después de cada partida (Rioja Checa, 2018).

En el año de 1956 Martin Minsky, John McCarthy y otro grupo de profesionales que le dieron vida al término "Artificial Intelligence" abrieron paso a Frank Rosenblatt, para que diseñara la primera red neuronal llamada perceptrón (Mesa & Yate E, 2022).

A mediados de 1979, estudiantes de ingeniería en la Universidad de Stanford, lograron crear un robot llamado "Stanford Car" capaz de desplazarse por una habitación sorteando los obstáculos en ella (Mesa & Yate E, 2022).

Durante 1974 y 1980 tiene lugar el llamado AI Winter (época conocida como invierno en Inteligencia Artificial), ya que numerosas empresas que financiaban los proyectos de inteligencia artificial, dejan de invertir. (Rioja Checa, 2018). Durante una década, la investigación en redes neuronales estuvo prácticamente suspendida (García Rodríguez, 2017).

En 1981 Gerald Dejong introduce el concepto "Explanation Based Learning" (EBL), donde un computador analiza datos de entrenamiento y crea reglas generales que le permiten descartar los datos menos importantes (Rioja Checa, 2018), consistía en una forma de aprendizaje automático, considerando las siguientes directrices (Valdemar et al., 2021):

- **Dominio:** Tener un objetivo específico de lo que se pretende obtener.
- **Espacio de hipótesis:** Considera todas las posibles soluciones.
- **Ejemplos de entrenamiento:** Datos y soluciones diferentes identificadas.
- **Criterios de operatividad:** Permiten el reconocimiento del tipo de dominio a tratar.

En el año 1985 el profesor Terry Sejnowski incursionó con un programa llamado “NetTalk” un algoritmo con la habilidad de captar la pronunciación de palabras (García Ortiz, 2021).

IBM desarrolla en 1997, el ordenador Deep Blue, este venció al campeón mundial de ajedrez Gary Kaspárov, demostrando así la capacidad de análisis para definir la estrategia y replicar una mejor respuesta (Bensusán et al., 2017).

A partir de 2006 empresas como Microsoft e IBM generan mayor análisis y expansión a nivel global con el manejo y procesamiento de datos, lo que da gran relevancia al e-learning.

En 2008 Microsoft lanza un programa llamado Azure Machine Learning, permitiendo almacenar aplicaciones directamente en el centro de procesamiento para los usuarios (Mesa & Yate E, 2022).

Durante 2011 IBM presenta su ordenador Watson en el concurso Jeopardy de América del Norte, el cual podía responder preguntas en lenguaje natural ganándole a humanos que

respondían las mismas preguntas, aunque con cierta debilidad en algunos tipos de categorías (Mesa & Yate E, 2022).

En el marco de la competencia e innovación, Jeff Dean, de Google y Andrew N. profesor de la Universidad de Stanford, dirigieron el proyecto Google Brain; refiriendo una red neuronal que por medio de google era capaz de detectar patrones en videos e imágenes, una gran revolución al consolidarse como una de las grandes maravillas de machine learning (Mesa & Yate E, 2022).

### 5.2. Clasificación de los datos de ML

Para utilizar el abordaje de aprendizaje, se deben considerar una serie de decisiones que incluyen la selección del tipo de entrenamiento, la función objetivo a ser aprendida, su representación y el algoritmo para aprender esa función a partir de ejemplos de entrenamiento (Godoy, 2017; Mitchell, 1997). La evolución del ML ha permitido que se potencialice su uso, dado el alto volumen de datos que maneja; de tal forma que estos datos refieren cierta categorización. Las bases del ML generadas para la comprensión de los datos, son divididas en dos áreas sustanciales (Valdemar et al., 2021):

- **Conceptos sobre datos:** otorgan la nomenclatura apropiada para describir los datos y sus conjuntos.
- **Conceptos sobre aprendizaje:** describen el conocimiento obtenido a partir de los datos.

Cabe precisar que ambas clasificaciones consideran como conceptos básicos la observación, las características y el tipo de datos que se están utilizando; información que resulta imprescindible para la comprensión tanto en los datos de entrada a utilizar en el modelo, como su análisis y evaluación en la toma de decisiones. Además, es importante considerar su organización, la cual puede ser distribuida en una tabla de base de datos o mediante una hoja de cálculo estructurada en filas y columnas.

### 5.2.1. Conceptos y Definiciones de Datos

El desarrollo de un modelo de ML el conjunto de datos y cada uno tiene conceptos diferentes de acuerdo al uso y tratamiento que tiene dentro de nuestro estudio, por lo que se considera necesario identificar las partes que conforman el algoritmo y su definición, estas se presentan en la Tabla 5.1.

**Tabla 5.1**

*Conceptos y definición de los datos para Machine Learning*

Concepto	Definición
Observación	Considera el registro de las propiedades de interés en el estudio.
Características	Son las propiedades o atributos de las observaciones que son útiles para el aprendizaje.
Tipo de datos	Se refiere al valor que tiene el dato: real o entero, valor categórico u ordinal
Conjunto de datos	Es la colección de observaciones.
Datos de entrenamiento	Se denomina al conjunto de datos utilizados para entrenar al modelo.
Datos de prueba	Es el conjunto de datos utilizado para validar la precisión del modelo, los cuales no deben ser utilizados para el entrenamiento.
Datos no estructurados	Son las imágenes, videos y texto, que deben ser transformados a una forma estructurada.

---

Datos atípicos	También denominados anómalos tienen diferentes propiedades con respecto a la generalidad, ya que debido a la naturaleza de sus valores y, por ende, a su comportamiento no son datos que mantienen un comportamiento similar a la mayoría. Los datos anómalos son susceptibles de ser introducidos por mecanismos maliciosos (Orellana & Cedillo, 2020).
----------------	--

---

Fuente: adaptada de (Valdemar et al., 2021).

---

### 5.2.2. Conceptos sobre Aprendizaje para Machine Learning.

El ML se apoya en el aprendizaje de sus algoritmos, es decir el proceso de realimentación de datos permite a nuestro modelo mejorar (en su caso) el resultado; los conceptos sobre el aprendizaje se muestran en la Tabla 5.2.

**Tabla 5.2**

*Conceptos sobre aprendizaje para Machine Learning*

Concepto	Definición
Inducción:	Proceso de razonamiento donde se realiza un modelo de la información (datos de entrenamiento).
Generalización*	Proceso en el que se identifica el patrón o modelo más significativo para las instancias del entrenamiento. A partir de este modelo, se realizan las predicciones o decisiones.
Sobre entrenamiento	Proceso en el que el modelo aprende de los datos de entrenamiento de una manera tan precisa o exacta que llega a perder la capacidad de generalizar. En nuestro conjunto de datos de entrada muchas veces introducimos muestras atípicas (o anómalas) o con “ruido/distorsión” en alguna de sus dimensiones, o muestras que pueden no ser del todo representativas. Cuando “sobre-entrenamos” nuestro modelo y caemos en el overfitting, el algoritmo estará considerando como válidos sólo los datos idénticos a los del conjunto de entrenamiento (Bonaccorso, 2018).
Sub entrenamiento	Cuando un modelo no ha aprendido suficientemente la estructura de la base de datos, debido a que el proceso de aprendizaje finalizó de forma temprana o inesperada.
Aprendizaje en línea	Se lleva a cabo cuando un método de ML se alimenta con observaciones de datos del tema en cuestión, a medida que estén disponibles. El aprendizaje en línea requiere métodos que sean robustos para los datos ruidosos, pero también puede producir modelos que sean más afines con el estado actual del conjunto de datos del tema en cuestión.

---

---

Aprendizaje fuera de línea:	Se produce cuando el método se alimenta con datos preparados previamente, que luego, se utilizan de manera operacional en datos no observados. El proceso de entrenamiento puede controlarse y puede ajustarse de forma cuidadosa, porque el alcance de los datos de entrenamiento es conocido.
-----------------------------	---

---

Fuente: adaptada de (Valdemar et al., 2021)

---

### 5.3. Tipos de Problemas

Existen diferentes clases comunes de problemas en el ML. Las clases de problemas mencionados en la Tabla 5.3 son arquetipos<sup>18</sup> para la mayoría de los problemas, a los que nos referimos cuando el ML es implementado:

**Tabla 5.3**

*Tipos de problemas*

Concepto	Definición
Clasificación	La decisión que se modela consiste en asignar etiqueta a nuevos datos no etiquetados. Esto puede ser considerado como un problema al generar un discriminante y modelar las diferencias o similitudes entre grupos.
Regresión	Los datos se encuentran etiquetados con un valor real en lugar de una etiqueta. Los ejemplos, fáciles de entender, son datos de series de tiempo, como el precio de un producto y sus variaciones, dentro de una ventana de tiempo. La decisión que se modela es la relación entre entradas y salidas.
Agrupamiento	Los datos no están etiquetados, pero se pueden dividir en grupos según la similitud y otras medidas de estructura natural en los datos. Un claro ejemplo reside en la segmentación de clientes en grupos con datos demográficos similares.
Extracción de reglas	Los datos se utilizan como base para la extracción de reglas proposicionales (antecedente/consecuente o si/entonces) Normalmente, estas reglas no están dirigidas, lo que significa que, con los métodos, se descubren relaciones estadísticamente compatibles entre atributos en los datos, que no necesariamente implican algo que se está prediciendo.

---

Fuente: adaptada de (Valdemar et al., 2021)

---

---

<sup>18</sup> Representación que se considera modelo de cualquier manifestación de la realidad (ASALE & RAE, s. f.)



### 5.4. Tipos de Datos

Para cumplir con los propósitos del análisis de datos y del modelo predictivo, resulta importante conocer el tipo de dato que se va a seleccionar, con el fin de ayudar a determinar el tipo de visualización, análisis de datos o modelo estadístico, mostrados en la Tabla 5.4.

**Tabla 5.4**

#### *Conceptos sobre aprendizaje para Machine Learning*

Concepto	Definición
Continuo	Los datos con cualquier valor dentro de un intervalo.
Discreto	Datos con valores enteros.
Categorico	Datos que pueden tomar solo un conjunto específico de valores, los cuales representan un conjunto de categorías posibles, tales como el tipo de sangre o los estados de un país, entre otros.
Binario	Datos que cuentan con solo dos categorías de valores, por ejemplo si o no.
Ordinal:	Son datos categóricos que tienen un orden explícito; por ejemplo, la talla de ropa o la calificación numérica de un producto (1º, 2º, 3º, ...)

Fuente: adaptada de (Valdemar et al., 2021)

### 5.5. Tipos de Aprendizaje de Machine Learning

#### 5.5.1. Aprendizaje Supervisado

Un escenario supervisado se caracteriza por el concepto de profesor o supervisor, cuya tarea principal es proporcionar al agente una medida precisa de su error (directamente comparable con los valores de salida). Con los algoritmos reales, esta función la proporciona un conjunto de entrenamiento formado por parejas (entrada y salida esperada). A partir de esta información, el agente puede corregir sus parámetros para reducir la magnitud de una función de pérdida global. Después de cada iteración, si el algoritmo es lo suficientemente flexible y los elementos de datos son coherentes, la precisión general aumenta y la diferencia entre el valor previsto y el esperado se acerca a cero.

El objetivo es entrenar un sistema que también debe funcionar con muestras nunca antes vistas. Por lo tanto, es necesario permitir que el modelo desarrolle una capacidad de generalización y evitar un problema común llamado sobreajuste, que provoca un aprendizaje debido a una capacidad excesiva (Bonaccorsso, 2020).

Los datos con que es alimentado el algoritmo, con la solución deseada, son referidos como “labels” (etiquetas), (Russell, 2018). Los principales algoritmos del aprendizaje supervisado son:

- K-Nearest Neighbors (KNN, vecinos cercanos).
- Red Neuronal.
- Máquinas de soporte de vectores.
- Regresión logística.
- Árboles de decisiones y bosques.

Algunas aplicaciones del aprendizaje supervisado son las siguientes (Bonaccorsso, 2018):

- Análisis predictivo basado en regresión o clasificación categórica.
- Detección de spam
- Detección de Patrón
- Procesamiento de Lenguaje Natural
- Análisis de Sentimientos
- Clasificación automática de imágenes.
- Procesamiento secuencial automático (por ejemplo, música o conversación)

Un estudio comparativo de algoritmos de aprendizaje supervisado para la predicción del rendimiento de los alumnos, aplicaron algoritmos de aprendizaje supervisado como: Decision Tree, Naïve Bayes y KNN, todos estos tienen sus propias influencias y salidas. Los autores concluyeron que en el conjunto de datos de 230 estudiantes de la Universidad de Kabul para predecir su GPA como alto, medio y bajo. Este proceso puede ayudar a los instructores a decidir fácilmente sobre el desempeño de los estudiantes y programar métodos para su educación. (Mohammadi et al., 2019), la representación de etiquetar los datos se muestra en la Figura 5.1.

**Figura 5.1**  
*Aprendizaje supervisado*



### 5.5.2. Aprendizaje No Supervisado

Mientras que el aprendizaje supervisado se enfoca en la inducción de clasificadores, el aprendizaje no supervisado está interesado en descubrir propiedades útiles de los datos disponibles. Quizás la tarea más popular busca grupos (llamados clústeres) de ejemplos

similares (Kubat, 2017). Por otro lado, el aprendizaje no supervisado consiste en analizar los datos y descubrir estructuras ocultas en datos no etiquetados. Como no se da una noción de las etiquetas correctas, tampoco hay una medida de error para evaluar un modelo aprendido; sin embargo, el aprendizaje no supervisado es una herramienta extremadamente poderosa (Kaluzka, 2016, p.13). Es decir, este proceso de aprendizaje no requiere etiquetas, el modelo aprende con los datos presentados, como se muestra en la Figura 5.2. Las estructuras naturales son identificadas y explotadas para relacionar ciertas observaciones respecto a otras.

**Figura 5.2**  
*Aprendizaje No Supervisado*



Los principales algoritmos del aprendizaje no supervisado son (Russell, 2018):

- Agrupamiento (Clustering): Medios k, análisis de agrupamiento jerárquico.
- Machine Learning de Asociación de Regla: Eclat y A priori.
- Visualización y Reducción de Dimensionalidad: Núcleo Principal Component Analysis (PCA, por sus siglas en inglés), distribuido de T-PCA.

Ejemplos de aplicaciones en el aprendizaje no supervisado (Bonaccorsso, 2018) son:

- Segmentación de objetos (por ejemplo, usuarios, productos, cine, canciones)
- Detecciones similares
- Etiquetas automáticas
- Motor de recomendación

Un caso de estudio respecto al aprendizaje no supervisado del ML es el Análisis de Clúster (De-La-Hoz et al., 2019): Es capaz de crear grupos de tal forma que las observaciones pertenecientes a un grupo están muy cercanas entre ellas y apartadas de las observaciones ubicadas en otro clúster. Existen 4 categorías de algoritmos de clustering: 1) de particionamiento; 2) basados en densidad; 3) basados en redes; y 4) jerárquicos.

Los algoritmos de partición tal como k-means y de partición alrededor de las medianas iterativamente refinan un conjunto de k clústeres y por lo general no escalan bien para grandes conjuntos de datos.

- Los algoritmos basados en densidad, son capaces de generar clústeres de tamaño arbitrario y de lidiar con valores extremos.
- Los algoritmos basados en red reducen el espacio de agrupamiento a celdas dentro de una red, permitiendo un agrupamiento eficiente de conjuntos de datos de gran tamaño.
- Los algoritmos jerárquicos pueden ser de aglomeración o divisivos, en la forma aglomerada repetidamente se fusionan dos clústeres, mientras en la forma divisiva repetidamente se divide un clúster en dos.

Citando nuevamente el caso de estudio los autores aportan una metodología para clasificar estudiantes participantes en ambientes virtuales de aprendizaje, identificando las relaciones entre la intensidad de uso de la plataforma y los resultados en los exámenes semestrales. Así mismo se establecen criterios para el estudio y análisis de los procesos de transición de los perfiles de los estudiantes de acuerdo al rendimiento alcanzado previamente. De igual forma con la metodología propuesta se puede pronosticar la pertenencia a un conglomerado de un estudiante independiente cuando se tienen las variables inherentes utilizadas en esta investigación (De-La-Hoz et al., 2019).

### 5.5.3. Algoritmo Semi-Supervisado.

El Aprendizaje Semi-supervisado es más útil cuando existe una mayor cantidad de datos no clasificados que de datos clasificados, la representación se muestra en la Figura 5.3. Especialmente, cuando para obtener los clasificados se requiere mucho esfuerzo, demora mucho o es muy costoso; ya que, además, la obtención no clasificados generalmente es menos costosa (Godoy (2017 citado por Chapelle et al., 2006, p. 11). Citado por el mismo autor, algunos ejemplos de técnicas de aprendizaje semi-supervisado son:

- Las técnicas de Transductive Support Vector Machine (Máquinas Transductivas de Soporte Vectorial, T-SVM, por sus siglas en inglés).
- La Maximización de Expectativas (EM).

Algunas aplicaciones del aprendizaje semi-supervisado, son el reconocimiento del habla, clasificación de páginas web y la secuencia de proteínas.

La investigación de González y Cruz (2008) mediante un sistema para la clasificación de imágenes médicas de radiología usa aprendizaje semi-supervisado, a través de la T-SVM (Support Vector Machine). La principal ventaja que presentan fue utilizar información de ejemplos no etiquetados para mejorar el desempeño del clasificador; siendo que lograron demostrar un mejor resultado del modelo semi-supervisado frente al supervisado. La Figura 5.3 presenta un ejemplo del etiquetado de algunos datos con la identificación de estilos de aprendizaje de los estudiantes.

**Figura 5.3**  
*Aprendizaje Semi supervisado*



### 5.5.4. Algoritmos por refuerzo

Un agente “Sistema de IA” observará el ambiente, ejecutando diferentes acciones, y luego recibe recompensas a cambio, ejemplificado en la Figura 5.4. Con este tipo, el agente debe aprender por sí mismo.

En este sistema de aprendizaje, llamado agente, se puede observar el entorno, seleccionar y realizar acciones, con la finalidad de obtener recompensas a cambio (o sanciones en forma de recompensas negativas) como se ilustra en la Figura 5.4. Luego, debe aprender por sí mismo cuál es la mejor estrategia, con una política, se define qué acción debe hacer el agente cuando se encuentra en una situación dada (Bonaccorso, 2020).

**Figura 5.4**  
*Algoritmo por refuerzo*



Fuente: Adaptado de (Russell, 2018)

A continuación, se citan algunos ejemplos comunes del aprendizaje por refuerzo (Bonaccorso, 2018) como:

- Control automático de robot



- Solución de juego
- Análisis de tendencias de comercio basado en comentarios.

### 5.6. Etapas de Implementación del ML

La implementación de algoritmos de ML considera cinco etapas, presentadas en la Tabla 5.5: recopilación de datos, exploración y preparación de datos, entrenamiento, evaluación del modelo y, por último, mejora del modelo.

**Tabla 5.5**

*Etapas para la implementación de un modelo machine learning*

Concepto	Definición
<b>Recopilación de datos</b>	Implica reunir el material de aprendizaje que se implementará en el algoritmo para generar conocimiento procesable
<b>Exploración y preparación de datos</b>	Implica arreglar o limpiar los llamados datos desordenados, eliminando datos innecesarios, atípicos, y recodificando los datos para ajustarse a las entradas esperadas de la técnica de ML.
<b>Entrenamiento</b>	Una vez que los datos han sido preparados, estos alimentan a la técnica o algoritmo específico, el cual construirá un modelo con base en los datos de entrenamiento.
<b>Evaluación del modelo</b>	Resulta importante evaluar lo eficiente que es el aprendizaje del algoritmo durante su etapa de entrenamiento. Dependiendo del tipo de modelo utilizado, es posible valorar la precisión del modelo mediante una evaluación con los datos de prueba. En algunos casos, se requiere del desarrollo de medidas de rendimiento específicas para la aplicación prevista.
<b>Mejora del modelo</b>	Cuando se requiera un mejor rendimiento, deberá utilizar estrategias más avanzadas para aumentar el rendimiento del modelo. Algunas veces, puede ser necesario cambiar a un tipo diferente de algoritmo de aprendizaje, con la finalidad de que el nuevo algoritmo pueda realizar la misma tarea de una manera más precisa. A su vez, puede que se requiera complementar los datos de entrenamiento con datos adicionales más representativos del problema abordado, o realizar un trabajo preparatorio adicional.

Fuente: adaptada de (Valdemar et al., 2021)

Derivado de la fase de mejora del modelo, en la tabla 5.6, se presenta un cuadro que clasifica los tipos de algoritmos y sus características para identificar el uso adecuado de estos.

**Tabla 5.6**

*Criterios para seleccionar el tipo de algoritmo de ML*

Algoritmo	Tamaño del Conjunto de Datos	Velocidad de entrenamiento (solo).	Interpretabilidad Dificultad para llegar a la decisión	Ajuste permitido	Comentarios
Modelos lineales	Pequeña	Muy rápido	Fácil	Mínimo	Algoritmo básico Utilizado en las SVM (máquinas de vector soporte). Maneja bien los datos de alta dimensión.
Árboles de decisión	Pequeña	Muy rápido	Fácil	Poco	Es necesario verificar el sobreajuste.
Máquina de Vector Soporte	Media	Lento	Difícil	Poco	Buen algoritmo generalista, verifique el sobreajuste.
Vecino más cercano (K-NN)	Media	Rápido	Fácil	Mínimo	Menor precisión, pero fácil de usar e interpretar.
Bayesiana ingenua	Media	Muy rápido	Algo fácil	Poco	Ampliamente utilizado para análisis de texto (ejemplo, filtrado de spam); kernel Bayes se ejecutará más lento.
Conjuntos	Largo	Rápido	Difícil	Poco	Mayor precisión con una compensación de menor interpretabilidad
Red neuronal	Talla media	Rápido	Fácil	Poco	Utilizado para la clasificación, comprensión y pronóstico de señales.
Redes profundas	Largo	Muy lento	Difícil	Mucho	Un algoritmo estándar para imagen, video, señales y texto.

Este capítulo concluye con la fase del marco teórico presentado en el esquema conceptual, mediante el estudio de los conceptos, definiciones, tipos de datos y algoritmos de aprendizaje, se ha dado la base teórica del machine learning para proponer modelos de aprendizaje que realicen un análisis masivo de datos y que en función de estos tomen decisiones. El siguiente capítulo describe la base teórica del comportamiento y aplicaciones de las redes neuronales artificiales.



## Capítulo 6 **Curriculum Learning**

## Capítulo 6 Deep Learning y Curriculum Learning.

### 6. Fundamento Teórico

En este apartado se introducen los conceptos básicos de las redes neuronales artificiales, considerada la base teórica de la propuesta de investigación haciendo una similitud a la red neuronal biológica, cabe aclarar que no es una sustitución del cerebro humano, sino una herramienta para resolver problemas de aprendizaje que van de lo fácil a lo difícil mediante el modelo de curriculum learning. Es importante destacar algunos conceptos de la red neuronal biológica para el entendimiento de la red neuronal computacional y la propuesta de diseño de esta investigación.

#### 6.1. Red Neuronal

Desde un punto de vista evolutivo señala Kaku, M. (2014), la estructura más reciente de la corteza cerebral es la neocorteza (nueva corteza), que controla los comportamientos cognitivos más elevados. Está especialmente desarrollada en el cerebro humano: constituye casi un 80% de la masa cerebral, a pesar de que es tan gruesa como una servilleta. En las ratas la neocorteza es plana, pero en los humanos posee muchas circunvoluciones, lo que permite empaquetar una gran superficie en el cráneo humano.

Una red neuronal se puede definir como un sistema que permite establecer una relación entre entradas y salidas inspiradas en el sistema nervioso. En las redes neuronales biológicas, la información se almacena en los puntos de contacto entre diferentes neuronas en el cerebro, este proceso se conoce como sinapsis (Acevedo, M. et. al 2017).


El premio nobel de medicina de 1906, Santiago Ramón y Cajal (1905) fue la primer persona en poder demostrar y validar que el sistema nervioso humano se compone de células individuales a las que se les empezó a llamar neuronas, las cuales se conectan entre sí creando una gran red de comunicación, pero en donde no se ha determinado hasta hoy la forma en que se procesa su información (Acevedo, M. et. al 2017).

La materia gris del cerebro está compuesta por miles de millones de diminutas células cerebrales llamadas **neuronas**. Como una gigantesca red telefónica, reciben mensajes de otras neuronas a través de las dendritas, que son como tentáculos que brotan de un extremo de la neurona. En el extremo opuesto se encuentra una fibra alargada denominada axón, que puede llegar a conectar hasta con diez mil neuronas por medio de sus dendritas. En la unión entre ambas existe un minúsculo espacio llamado **sinapsis**. La sinapsis actúa como puertas que regulan el flujo de información en el cerebro.

Determinados compuestos químicos, llamados **neurotransmisores**, pueden penetrar en la sinapsis y alterar el flujo de las señales. Puesto que los neurotransmisores, como la dopamina, la serotonina y la noradrenalina ayudan a controlar el flujo de información que recorre las innumerables vías del cerebro, ejercen un poderoso efecto sobre lo que pensamos y nuestros estados de ánimo (Kaku, M. 2014). La estructura de una neurona biológica es presentada en la Figura 6.1.

**Figura 6.1**

*Estructura de una neurona*



Nota: Diagrama de una neurona. Las señales eléctricas recorren el axón de la neurona hasta que llegan a la sinapsis. Los neurotransmisores pueden regular el flujo de señales eléctricas a través de la sinapsis. Fuente: Kaku, M. (2014, p. 45) *El futuro de nuestra mente Debate*.

El avance tecnológico mediante el uso de la resonancia magnética ha permitido desde hace algunos años la decodificación del funcionamiento del cerebro, a través de imágenes del funcionamiento interno del cerebro mientras experimenta sensaciones y emociones.

De forma natural, el cerebro se modela durante el desarrollo de un ser vivo. Algunas cualidades del ser humano no son innatas, sino adquiridas por la influencia de la información que del medio externo se proporciona a sus sensores; algunas maneras de modelar el sistema nervioso son (Acevedo et. al 2017):

- Establecimiento de nuevas conexiones.
- Ruptura de conexiones.
- Modelado de las intensidades sinápticas (uniones entre neuronas)
- Muerte o reproducción neuronal

En estos procesos se presentan conceptos clave representados por:

- Procesamiento paralelo: miles de millones de neuronas intervienen; siendo un ejemplo el proceso de visualización al operar en paralelo sobre la totalidad de la imagen.
- Memoria distribuida: en una computadora la información está en posiciones de memoria bien definidas y en las redes neuronales biológicas dicha información está distribuida por la sinapsis de la red, existiendo una redundancia en el almacenamiento, para evitar la pérdida de información en caso de que una sinapsis resulte dañada.
- Adaptabilidad al entorno, por medio de la información de la sinapsis. Por medio de esta adaptabilidad se puede aprender de la experiencia y es posible generalizar conceptos a partir de casos particulares.

### 6.2. Red Neuronal Artificial

Las redes neuronales artificiales son un modelo computacional basado en IA que emula el comportamiento del cerebro humano, debido a la capacidad de aprendizaje que logran las máquinas similar al cerebro humano, formada por neuronas artificiales, representando la unidad o nodos que reciben la información del exterior o de otras neuronas, de manera similar a los impulsos nerviosos que reciben las neuronas del cerebro humano, las procesan y

generan un valor que alimenta a otras neuronas de la red o son la salida hacia el exterior de la red.

La sinapsis se ha tratado de llevar a la forma artificial debido a la eficacia de los procesos llevados a cabo por el cerebro. Por lo que se ha desarrollado la teoría de las Redes Neuronales Artificiales (RNA), el objetivo es poder emular las redes neuronales biológicas y hacer posible que estas aprendan tácticas y soluciones basadas en ejemplos de comportamiento típico de patrones. Estos sistemas artificiales no necesitan de una programación previa, teniendo la capacidad de generalizar y aprender de la experiencia (Acevedo et. al 2017).

Las neuronas como procesadores de información sencillos para la emulación de una neurona artificial están interconectadas y cada componente de la neurona biológica está representada en de la siguiente forma:

- Las dendritas constituyen el canal de entrada de la información.
- El soma es el órgano de cómputo.
- El axón corresponde al canal de salida, y a la vez envía información a otras neuronas. Cada neurona recibe información de aproximadamente 10,000 neuronas y envía impulsos a cientos de ellas.
- Algunas neuronas reciben la información directamente del exterior.



La evolución de las redes neuronales artificiales considera algunos principios importantes basados en su origen y evolución, mostrados en la Tabla 6.1.

**Tabla 6.1**

*Principios de las redes neuronales artificiales*

Principio	Definición
Aprendizaje Adaptativo	Las redes neuronales se comportan en función de un entrenamiento. Se le exponen ejemplos ilustrativos. No es necesario elaborar un modelo a priori, ni establecer funciones probabilísticas.
Auto organización	Consiste en la modificación de la red con el fin de llevar a cabo un objetivo específico. Como se menciona con anterioridad, se puede presentar un efecto llamado generalización, en donde, después de haber aprendido una serie de patrones, les podría reconocer otros patrones similares, aunque no se le hubiesen presentado en el entrenamiento.
Tolerancia a fallos	Las redes neuronales artificiales poseen una alta capacidad de tolerancia a fallos, por lo que el ruido en los patrones de información con ruido no los afecta y pueden seguir trabajando, aunque se destruya parte de la red. Esto se debe a que la información en las redes neuronales se hacen de forma distribuida y con redundancia
Operación en tiempo real	Las redes neuronales artificiales realizan reconocimiento de patrones en tiempo real, debido a que trabajan en paralelo actualizando todas sus instancias simultáneamente.
Fácil inserción en la tecnología existente	Es fácil obtener hardware para trabajar con redes neuronales y es fácil realizar integración de forma modular en tecnologías existentes.

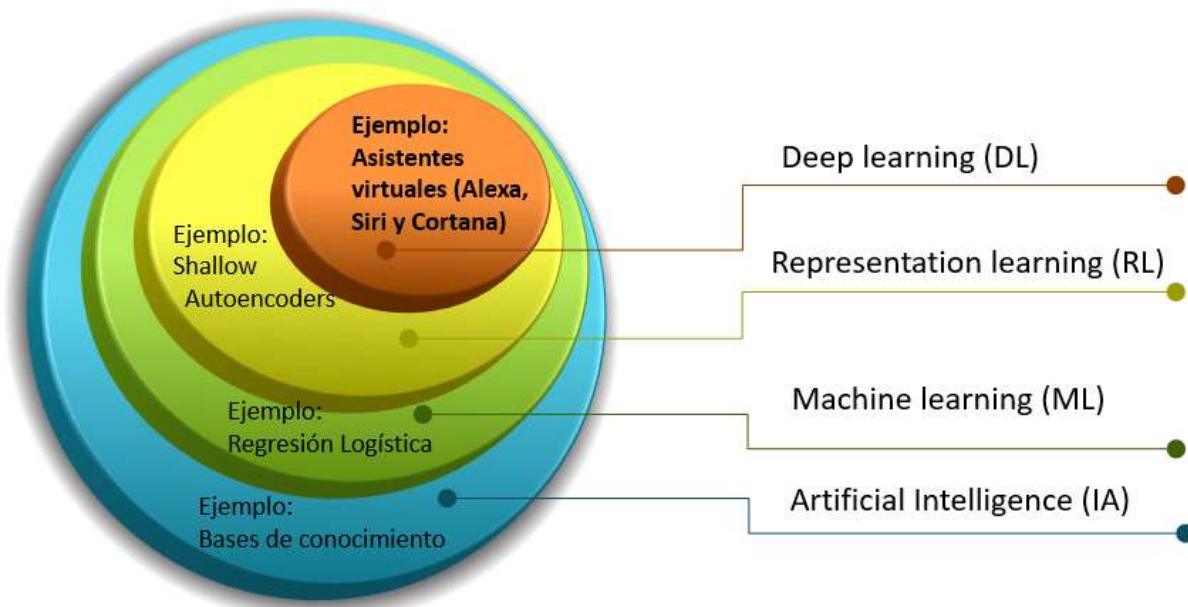
Nota: Tomado de Acevedo et. al (2017). Principios y Características de las redes neuronales artificiales. Desarrollo de la Ingeniería Ambiental en la Evaluación de los Recursos Naturales y la Salud Ambiental, Cap. 10, pag. 176 citado por (Sotolongo, G. y Guzmán, M. (2001) Aplicaciones de las redes neuronales. El caso de la Bibliometría. Ciencias de la Información 32 (1), pp. 27-34.

### 6.3. Deep Learning

El Deep Learning es una técnica donde la información se procesa en capas jerárquicas para comprender representaciones y características de datos en niveles crecientes de complejidad. En la práctica, todos los algoritmos de Deep Learning son redes neuronales que comparten algunas propiedades básicas comunes, como que todas consisten en neuronas interconectadas que se organizan en capas (Torres, 2020).

En la práctica, todos los algoritmos de Deep Learning son redes neuronales que comparten algunas propiedades básicas comunes, como todas consisten en neuronas interconectadas que se organizan en capas. La Figura 6.2 se muestra un ejemplo de las subramas de la IA hasta el Deep learning (DL).

**Figura 6.2**  
*La IA, subramas y ejemplos.*




Algunos autores como Torres (2020) señalan que las redes neuronales artificiales son un caso especial de los algoritmos de ML, que en cierta manera son un intento de imitar la actividad en capas de neuronas en la neocorteza, que es la parte del cerebro humano donde ocurre el pensamiento. Estas redes neuronales aprenden estructuras jerárquicas y niveles de representación y abstracción para comprender los patrones de datos que provienen de varios tipos de fuentes, como imágenes, videos, sonido o texto.

En los modelos de redes neuronales, las abstracciones de nivel superior se definen como la composición de la abstracción de nivel inferior. Una de las mayores ventajas del Deep Learning es su capacidad de aprender automáticamente la representación de características en múltiples niveles de abstracción. Esto permite que un sistema aprenda funciones complejas asignadas desde el espacio de entrada al espacio de salida sin muchas dependencias de las funciones creadas por humanos.

La neurona artificial tiene una o más entradas y una salida. Dependiendo del valor de esas entradas, la neurona puede dispararse. (encendida o apagada, mediante un interruptor binario con valores de 0 a 1). En el caso concreto de Deep Learning, las estructuras algorítmicas mencionadas permiten modelos que están compuestos de múltiples capas de procesamiento (construidas con neuronas artificiales) para aprender representaciones de datos, con múltiples niveles de abstracción que realizan una serie de transformaciones lineales y no lineales que, a partir de los datos de entrada, generan una salida próxima a la esperada. El aprendizaje – supervisado en este caso- consiste en obtener los parámetros de esas transformaciones y conseguir que esas transformaciones sean óptimas, es decir, que la salida producida y la

esperada difieran lo mínimo posible, una representación de una red neuronal artificial basada en 3 capas se presenta en la Figura 6.3.

**Figura 6.3**  
*Capas de la Red Neuronal Artificial*




Fuente: Calvo, D. 2017. Estructura de red neuronal artificial. <https://www.diegocalvo.es/definicion-de-red-neuronal/>  
Esta figura presenta una red artificial neuronal con 3 capas de entrada (input layer) que recibe los datos de entrada, una de salida (output layer) que devuelve la predicción realizada, y las capas que tenemos en medio. En la tabla 6.2. Son definidos los conceptos asociados a la red neuronal artificial

**Tabla 6.2**

Conceptos Básicos de la Red Neuronal Artificial

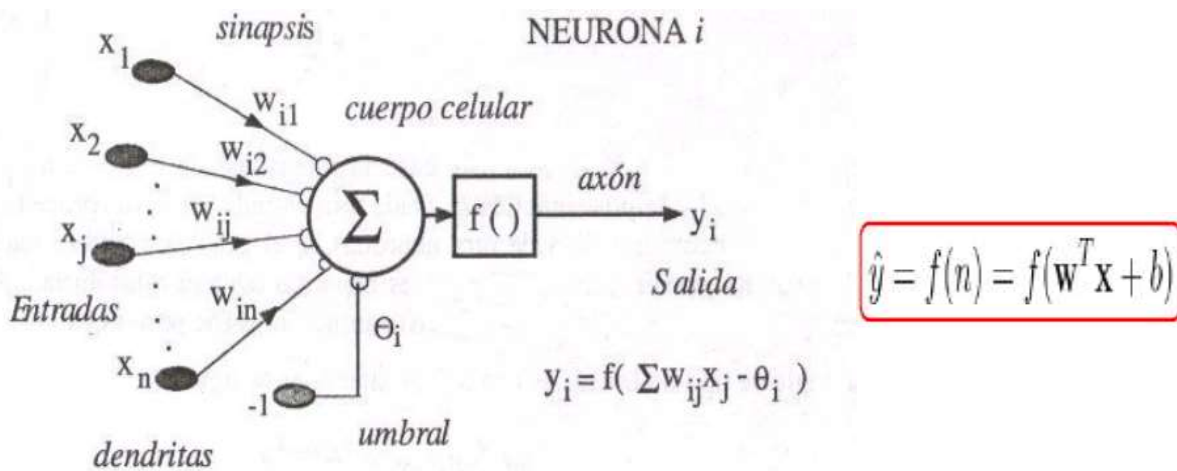
Concepto	Definición	Representación
Conjunto de entradas	Representa las entradas de la red neuronal	$X_1, \dots, X_n$
Pesos sinápticos	Cada entrada tiene un peso que se va ajustando de forma automática a medida que la red neuronal va aprendiendo.	$W_1, \dots, W_n$
Función de agregación	Realiza el sumatorio de todas las entradas ponderadas por sus pesos y un sesgo (bias) para el cálculo del valor de salida de la neurona.	$\sum_{i=0}^n$

Función de activación	Se encarga de mantener el conjunto de valores de salida en un rango determinado, normalmente (0,1) o (-1,1) Existen diferentes funciones de activación que cumplen este objetivo, la más habitual es la función sigmoide	
Salida	Representa el valor resultante tras pasar por la red neuronal	

La representación matemática presentada en la Figura 6.4 de la red neuronal artificial permite evaluar los datos de entrada, procesarlo y obtener la salida correspondiente a las capas representadas por la función  $y_i$ .

**Figura 6.4**

*Representación Matemática de una Red Neuronal Artificial*



**Terminología y notación básica**

A continuación se define la terminología y la notación básica de la neurona artificial, para conceptualizar los datos representados:

- Item: Alguno de los datos que conforman el conjunto de datos de entrada.

- Features: Determinadas características (o atributos o variables indistintamente).
- Etiqueta de clase (label): representa lo que se trata de predecir en el modelo.

En palabras de Torres (2020), un modelo define la relación entre las características y las etiquetas del conjunto de muestras y presenta dos fases claramente diferenciadas como:

- Fase de entrenamiento o aprendizaje (training, en inglés): cuando se crea o se aprende del modelo, a partir de mostrarle las muestras de entrada que se tienen etiquetadas; de esta manera se consigue que el modelo aprenda iterativamente las relaciones entre las características y las etiquetas de las muestras.
- Fase de inferencia o predicción (inference, en inglés): se refiere al proceso de hacer predicciones mediante la aplicación del modelo ya entrenado a muestras de las que no se dispone de etiqueta y que se quiere predecir.

Una notación simple para el modelo que expresa una relación lineal entre características y etiquetas para una muestra de entrada podría ser la siguiente:

Donde:

$$y = wx + b$$

y es la etiqueta de una muestra de entrada

x representa las características de la muestra

w es la pendiente de la recta y que, en general, llamaremos peso (weight, en inglés) y es uno de los dos parámetros que tendrá que aprender el modelo durante el proceso de entrenamiento para poder usarlo luego para la inferencia.

$b$  es lo que llamamos sesgo (bias, en inglés)

En el caso en el que cada muestra tiene varias características, cada una tendrá su peso representado por  $w_i$ . Es decir, en un conjunto de datos de entrada en el que cada muestra presenta tres características  $(x_1, x_2, x_3)$ , la relación algebraica anterior se expresaría de la siguiente forma:

$$y = w_1x_1 + w_2x_2 + w_3x_3 + b$$

Obteniendo la sumatoria del producto escalar entre los dos vectores  $(w_1 + w_2 + w_3)$  y

$(x_1 + x_2 + x_3)$  y luego la suma del sesgo:

$$y = \sum_i w_i x_i + b$$

Podemos expresar la ecuación como sigue:

$$y = w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n + b = w^T \cdot x + b$$

El parámetro sesgo  $b$  a menudo se expresa como el peso  $w_0$ , asumiendo una característica adicional fija de  $x_0 = 1$  para cada muestra, con lo cual la anterior formulación la podemos simplificar como:

$$y = w_0x_0 + w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n + b = w^T \cdot x$$

Para clasificar el elemento de entrada  $X$ , en nuestro caso de dos dimensiones, debemos aprender un vector de peso  $W$  de la misma dimensión que el vector de entrada, es decir, el vector  $(W_1+W_2+W_3+\dots+W_n)$  y un sesgo  $b$ .

Con los valores calculados, es posible construir una neurona artificial para clasificar un nuevo elemento  $X$ . Básicamente, la neurona aplica este vector  $W$  de pesos (calculados de manera ponderada) sobre los valores en cada dimensión del elemento  $X$  de entrada, le suma el sesgo  $b$ , y el resultado lo pasa a través de una función no lineal para producir un resultado de 0 o 1.

La función de esta neurona artificial como

$$z = \sum_i w_i x_i + b$$

Donde  $y = \begin{cases} 1 & \text{si } z \geq 0 \\ 0 & \text{si } z < 0 \end{cases}$

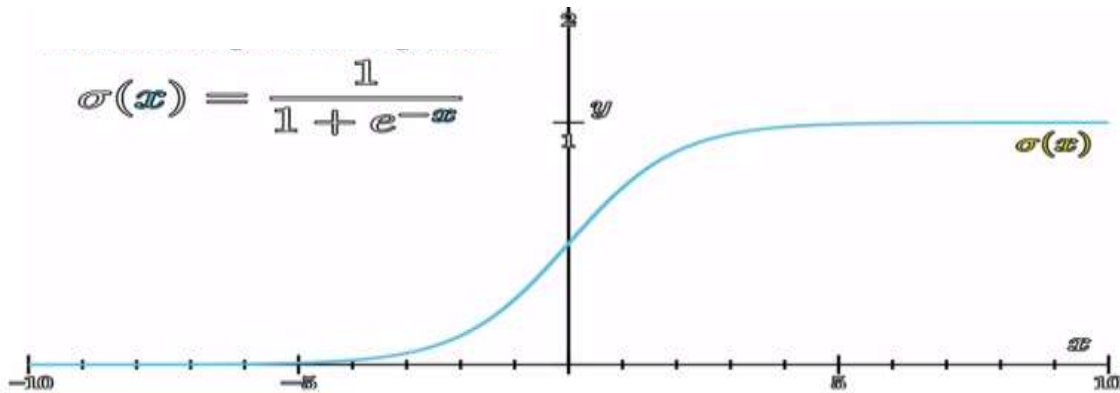
En este caso, para la función de activación utilizamos la función sigmoide que retoma un valor real de salida entre 0 y 1 para cualquier entrada:

$$y = \frac{1}{1 + e^{-z}}$$

La fórmula tiende a proporcionar valores próximos del 0 al 1. Si la entrada  $z$  es razonablemente grande y positiva, e a la menos  $z$  es cero, y por tanto, la  $y$  toma el valor de 1. Si  $z$  tiene un valor grande y negativo, resulta que para  $e$  elevado a un número positivo grande el denominador resultará ser un número grande y, por lo tanto, el valor de  $y$  será próximo a 0. Gráficamente se representa la función sigmoide en la Figura 6.5:

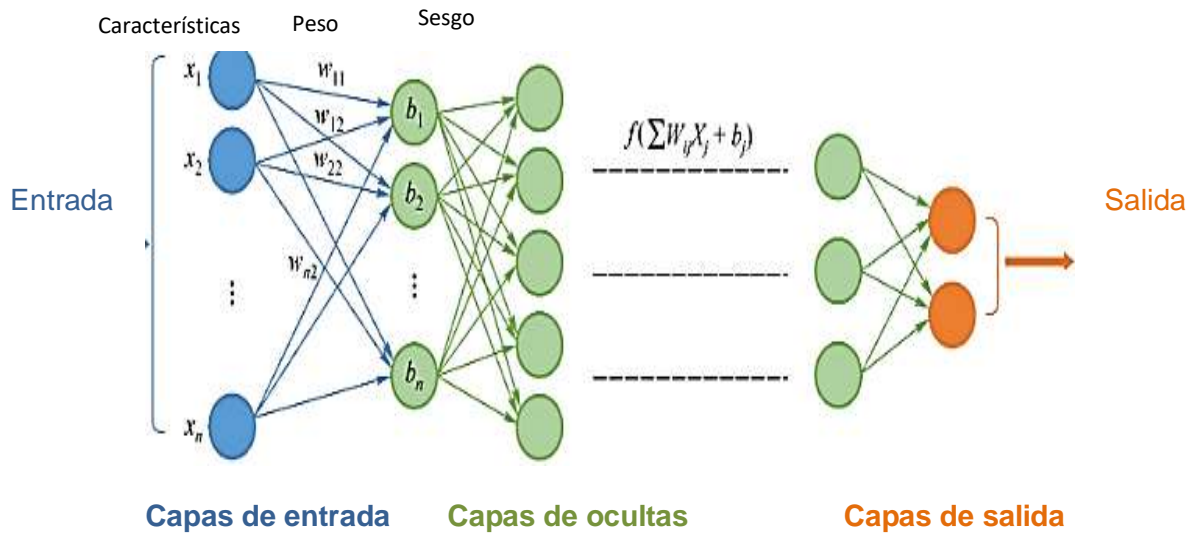


**Figura 6.5**  
Función sigmoide



En la Figura 6.6 se esquematiza cada fase por colores señalando que: los nodos azules, representan las capas de entrada (características) para cada variable, los nodos verdes evalúan las capas ocultas y los nodos naranjas reflejan las capas de salida.

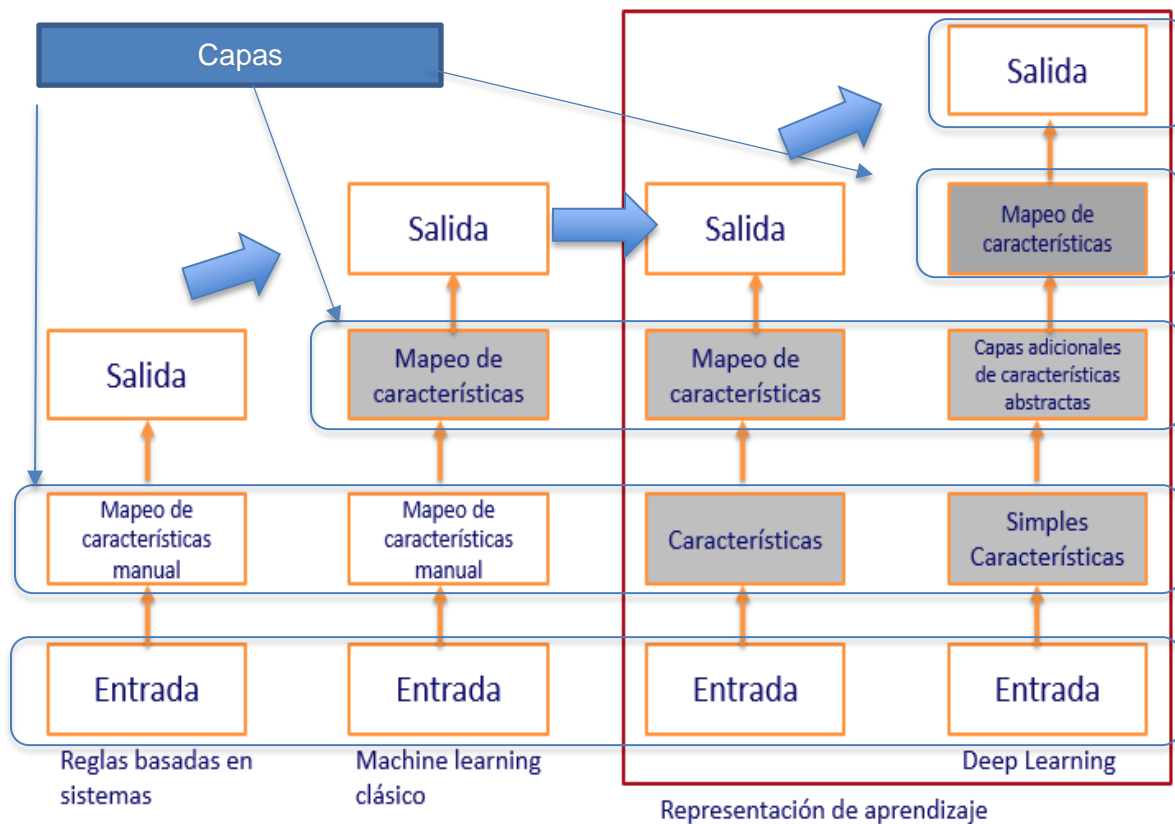
**Figura 6.6**  
Capas de la red neuronal artificial



La Figura 6.7 esquematiza como se lleva a cabo el mapeo de las características en las diferentes capas de la red neuronal artificial, representado el aprendizaje mediante la abstracción de las características.


**Figura 6.7**

*Representación de aprendizaje de una red neuronal artificial*



Algunos ejemplos presentados del modelo Deep Learning respecto de la desagregación de capas se visualiza en la Figura 6.8 mediante el análisis de la fotografía de un perro y la clasificación de sus características.

**Figura 6.8**  
*Representación de capas en una red convolucional*



Nota: imagen de un perro samoyedo (abajo a la izquierda; y RGB (rojo, verde, azul) entradas, abajo a la derecha). Cada imagen rectangular es un mapa de entidades, tomado de LeCun, Y., Bengio, Y., y Hinton, G. (2015). Deep learning. En *Nature* (Vol. 521, Números 7553, pp. 436-444). <https://doi.org/10.1038/nature14539>.

El aprendizaje obtenido para el reconocimiento de las siguientes imágenes da muestra de que el Deep learning es capaz de reconocer la integración de varios objetos como se muestra en las Figuras 6.9 y 6.10.

**Figura 6.9**  
*Detección de Múltiples Objetos*




Fuente: Juanes, G. (2017) *Deep Learning*. La Revolución Tecnológica del video análisis.

En el ejemplo presentado en la Figura 6.10 podemos tomar como entrada de la red de neuronas diferentes características biométricas, por ejemplo, el ancho entre los ojos, la

longitud que separa los ojos de la boca, el ancho y altura de la cara y una secuencia lateral. Estas características serán codificadas cada una como entrada específica de la red.

**Figura 6.10**

*Categorización de los rostros (masculino / femenino)*

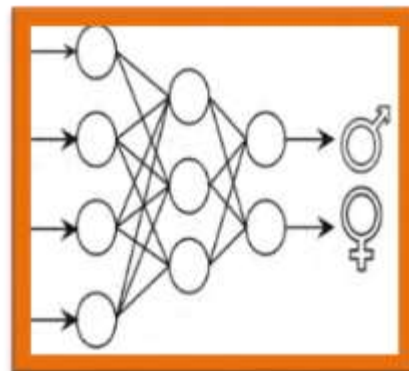


**Medidas biométricas**



**Características:**

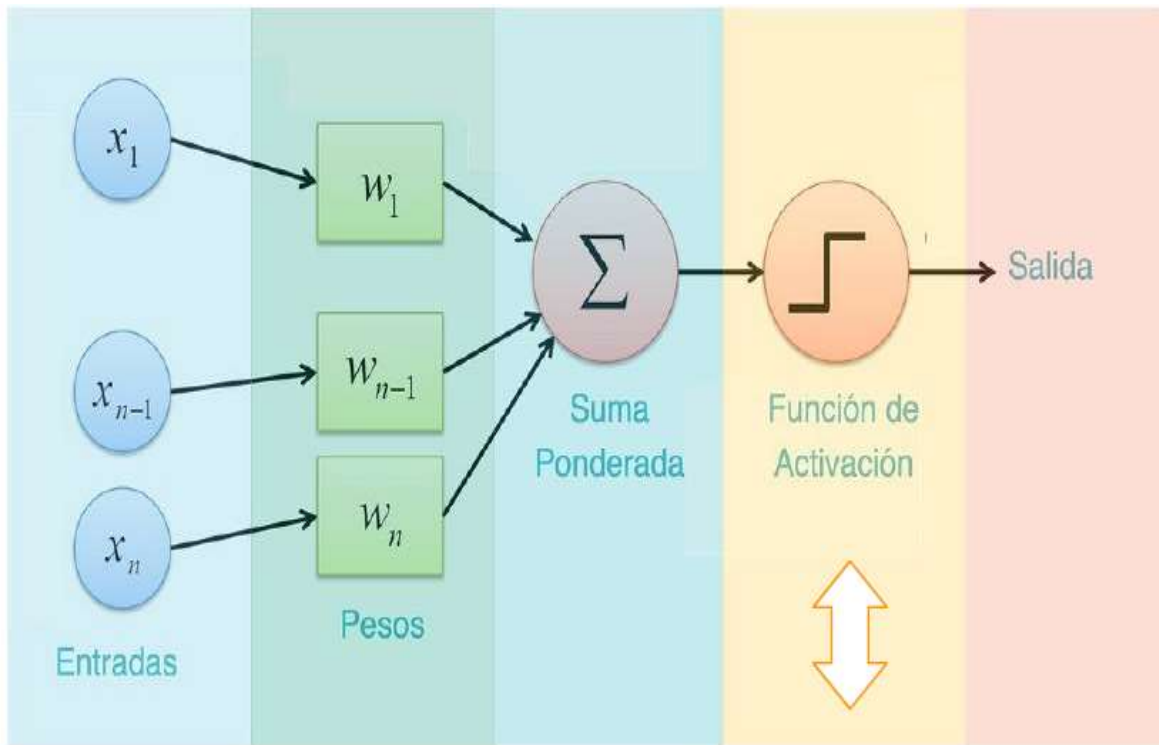
- Largo de los ojos.
- Ancho del rostro
- Largo del rostro.
- Etc.



El siguiente paso, una vez codificada la información en la capa de entrada perceptiva, será transferir la información a las neuronas de la siguiente capa (la(s) capa(s) oculta(s) hasta llegar a la función de activación como se muestra en la Figura 6.11. En general, la información de entrada se normaliza entre 0 y 1.

**Figura 6.11 Red Neuronal y sus Funciones de Activación**

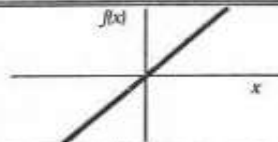
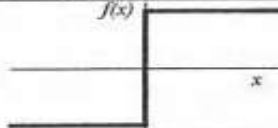
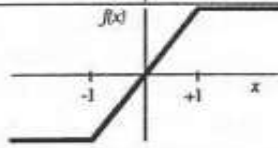
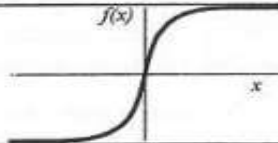
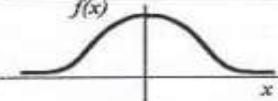
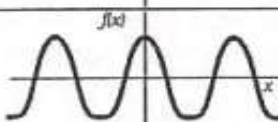
*Red neuronal y sus funciones de activación*



La función de activación de redes neuronales, son el componente más importante del Deep Learning, se utilizan fundamentalmente para determinar el resultado de los modelos de aprendizaje profundo, su precisión y la eficiencia del rendimiento del modelo de entrenamiento que puede diseñar o dividir una red neuronal a gran escala, en la Figura 6.12 se presentan algunas fórmulas de la función de activación.

Figura 6.12

Fórmulas de la función de activación

	<b>Función</b>	<b>Rango</b>	<b>Gráfica</b>
<b>Identidad</b>	$y = x$	$[-\infty, +\infty]$	
<b>Escalón</b>	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
<b>Lineal a tramos</b>	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq +l \\ +1, & \text{si } x > +l \end{cases}$	$[-1, +1]$	
<b>Sigmoidea</b>	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
<b>Gaussiana</b>	$y = Ae^{-Bx^2}$	$[0, +1]$	
<b>Sinusoidal</b>	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

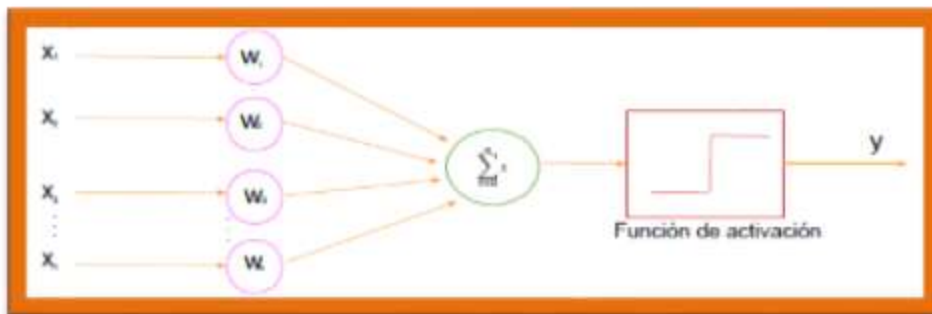
Nota: Tomado de Acevedo (2017)

### 6.3.1. Clasificación de Redes Neuronales

#### 6.3.1.1. Red Monocapa

Es la red neuronal más simple y se muestra en la Figura 6.13, está compuesta por una capa de neuronas de entrada conectada a una salida donde se realizan los diferentes cálculos en la función de activación.

**Figura 6.13**  
*Red Monocapa*



$$y_i = f(\mathbf{w}_i^T \mathbf{x} + b_i) \quad \forall_i \in [1, S]$$

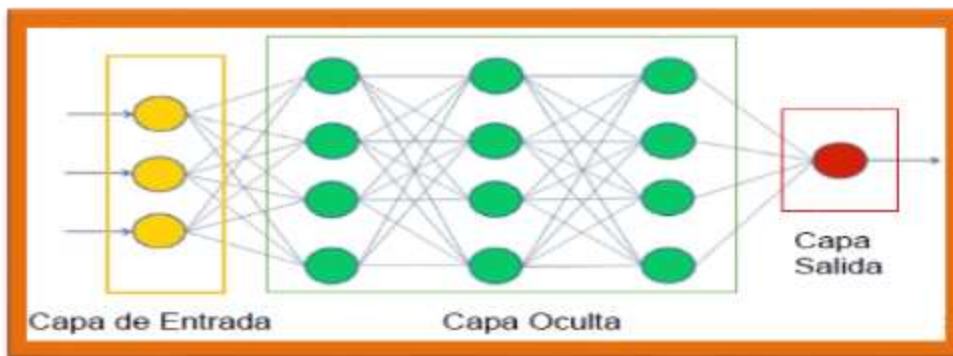
$$\mathbf{y} = f(\mathbf{W} \mathbf{x} + \mathbf{b})$$

### 6.3.1.2. Red Multicapa

La red neuronal multicapa representada en la Figura 6.14 es una generalización de la red neuronal monocapa, la diferencia es que esta tiene un conjunto de capas intermedias (capas ocultas) entre la capa de entrada y la de salida. Dependiendo del número de conexiones que presente la red esta puede estar total o parcialmente conectada y cuenta con dos tipos de conexiones: hacia adelante (feedforward) y hacia atrás (feedback).

**Figura 6.14**

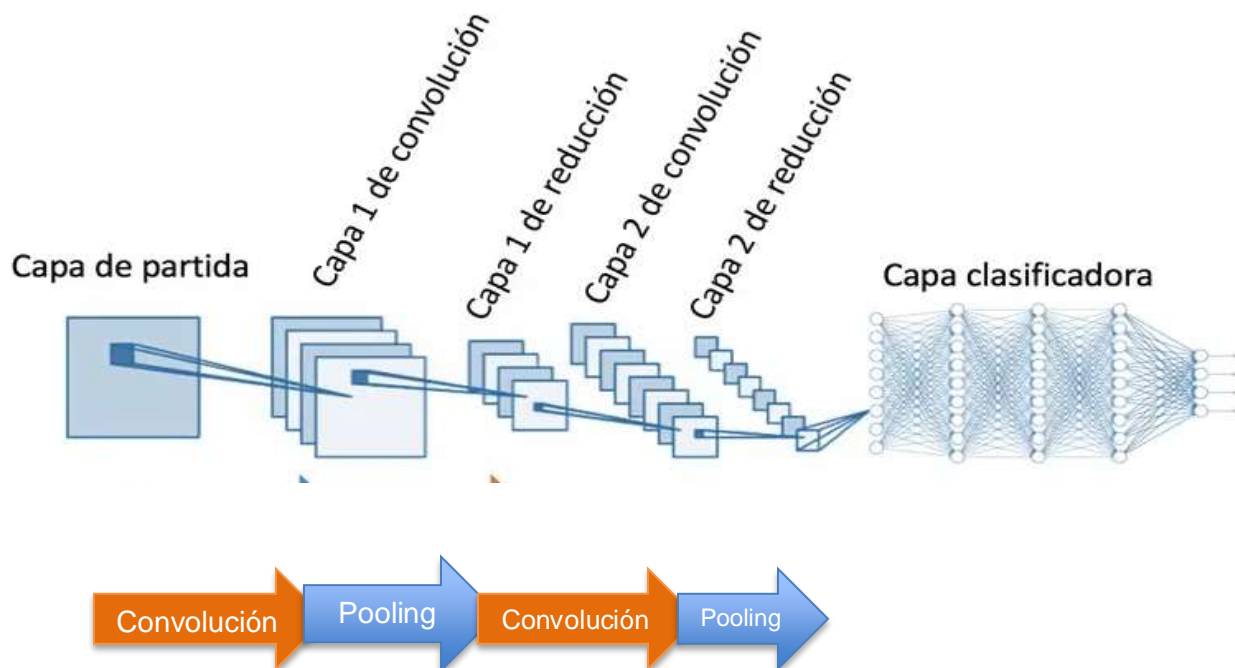
*Red Multicapa*



### 6.3.1.3. Red Neuronal Convolutacional

La Red Neuronal Convolutacional (CNN, por sus siglas en inglés) es similar a las redes neuronales multicapa, pero la diferencia radica en que en estas las neuronas de cada capa no se interconectan con todas las de la capa siguiente, si no con un subconjunto de estas, y tampoco se interconectan entre las neuronas de la misma capa, generando una especialización de las neuronas (grupos) y reduciendo la cantidad de unidades necesarias y la complejidad de los sistemas que utilizan este tipo de redes, lo cual optimiza los tiempos y mejora los resultados, su funcionamiento se muestra en la Figura 6.15. Los ejemplos más utilizados son el análisis de imágenes debido a que detectan características simples como bordes, líneas, etc., desagregando características más complejas de detectar hasta detectar el objetivo de búsqueda.

**Figura 6.15**  
*Red Neuronal Convolutacional*



Nota: Calvo, D. (2017a). Red Neuronal Convolutacional.



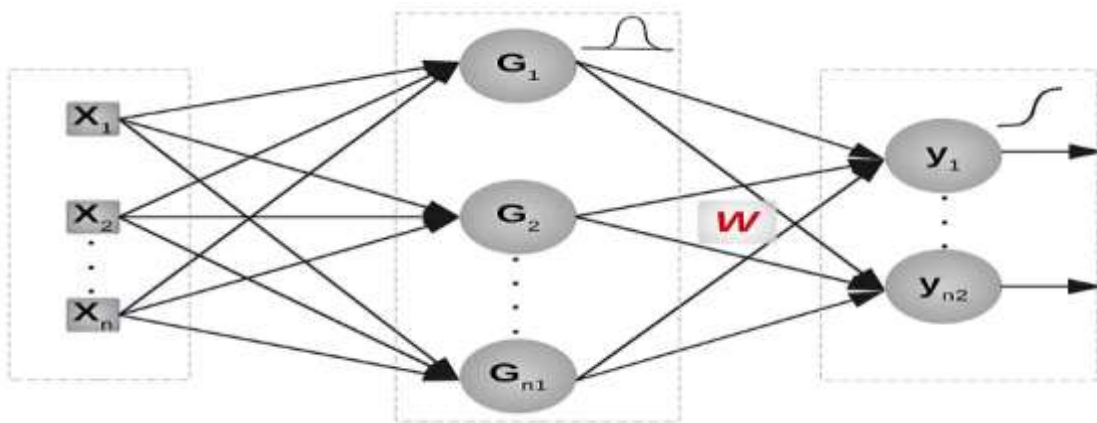
### 6.3.1.4. Red Neuronal Concurrente

En estas redes las neuronas no se organizan en capas, sino que las neuronas están interconectadas entre ellas de manera no estructurada en capas. Esto permite que estas redes tengan memoria, es decir, que la información generada en iteraciones anteriores afecte al resultado del procesamiento en un tiempo futuro.

### 6.3.1.5. Red Neuronal Base Radial

Las redes de base radial calculan la salida en función de la distancia a un punto denominado centro. Están compuestas de la capa de entradas, capa oculta y la capa de salida, presentadas en la Figura 6.16. La función de activación de las neuronas de la capa oculta es de base radial, de ahí el nombre de esta red, y una función comúnmente usada para activar estas neuronas es la función Gaussiana; y las neuronas de la capa de salida presentan un comportamiento similar a un perceptrón simple.

**Figura 6.16**  
*Red Neuronal Base Radial*



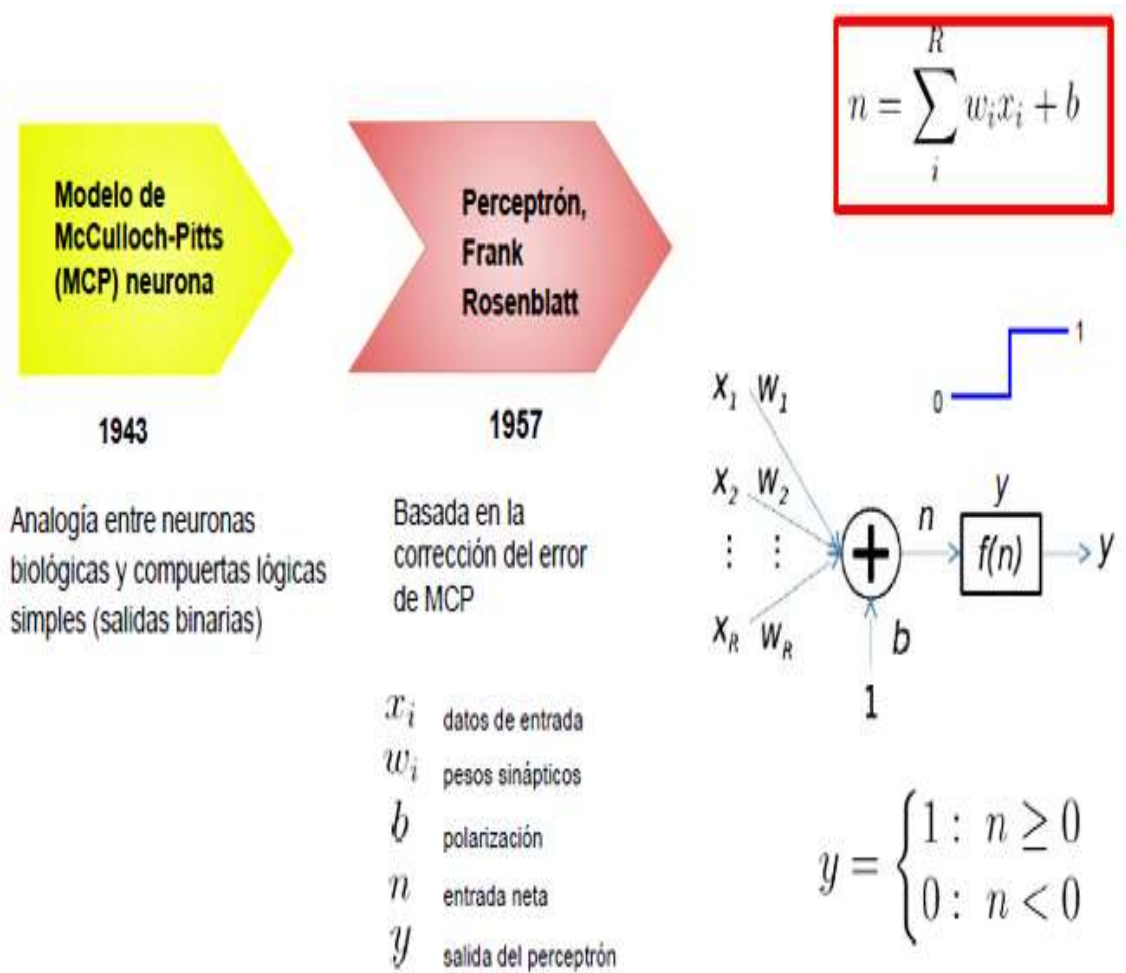
Nota: Tomado de Romero, V. (2021). *La red neuronal de base radial (RBF)* [La red neuronal de base radial \(RBF\) \(vreelectronic.wixsite.com\)](http://vreelectronic.wixsite.com)

El método de aprendizaje para este tipo de red se suele llamar híbrido debido a que implementa métodos de aprendizaje supervisado y no supervisado.

La clasificación de las redes presentada en la Figura 6.17, no solamente se refiere a la tipología, también podemos clasificarlas según sus características, el número de capas y el tipo de capas.

**Figura 6.17**

*Clasificación de las Redes Neuronales*



### 6.3.2. Entrenamiento de una red neuronal

Las redes neuronales resuelven problemas propuestos después de un entrenamiento, basados la Tabla 6.1. Principios y características de la RN.

#### 6.3.2.1. Regla de propagación

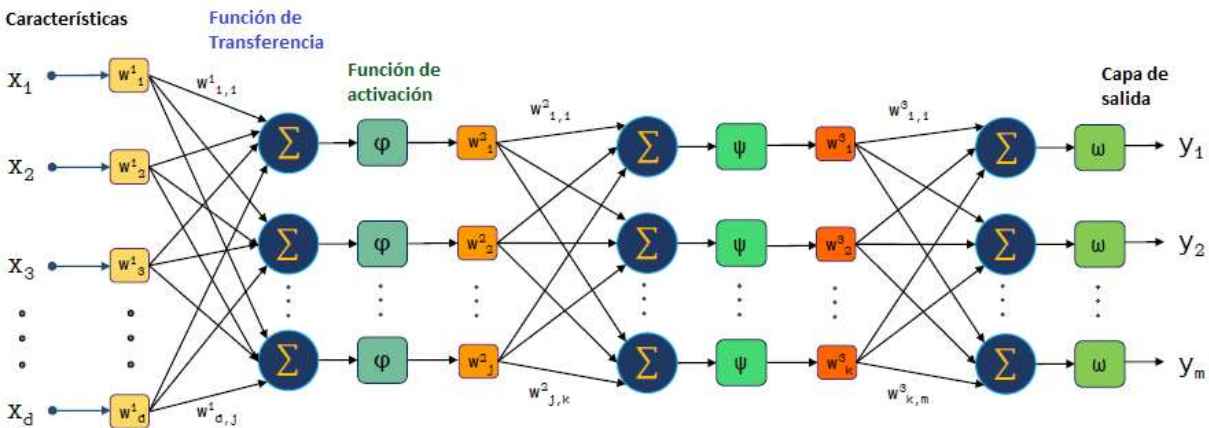
En un modelo neuronal, se debe disponer de una regla de propagación para combinar las salidas de cada neurona con las ponderaciones establecidas por el patrón de conexión, con eso se especifica la valoración de las entradas que recibe cada neurona (Acevedo et. al 2017) citado por Caridad, J. Celular, N. (2001). Normalmente puede realizarse una suma de las entradas, teniendo en cuenta el peso sináptico asociado a cada entrada. Aunque otras operaciones también son posibles (Acevedo et. al 2017).

En palabras de Acevedo et. al (2017) refiere que con el valor obtenido con la regla de propagación, esta se filtra con la función de activación (presentadas en la Figura 6.12 y con ello se produce la salida de la neurona.

#### 6.3.2.2. Forward Propagation

La forward propagation (propagación hacia adelante) es el conjunto de procesos matemáticos desde que introducimos nuestros datos en la red neuronal, hasta que la red neuronal da un resultado, su representación gráfica es mostrada en la Figura 6.18.

**Figura 6.18 Forward Propagation**  
*Forward Propagation*



Nota: Adaptada de Avramova, V. (2015). *Curriculum Learning with Deep Convolutional Neural Networks*. Kith Royal Institute of Technology School of Computer Science and Communication.

### 6.3.2.3. Backpropagation

En redes neuronales se busca ajustar los pesos de cada neurona de tal manera que se minimice el error. El **algoritmo de backpropagation** (propagación hacia atrás) indica cuanto de culpa tiene cada neurona del error global cometido. Backpropagation (abreviatura de backward propagation of errors), es un mecanismo utilizado para actualizar los pesos utilizando el descenso de gradiente. Calcula el gradiente de la función de error con respecto a los pesos de la red neuronal. El cálculo procede hacia atrás a través de la red como se muestra en la Figura 6.19.

**Figura 6.19**

*Back Propagation*

- Se refiere a ajustar los pesos sinápticos y así reducir el error.

Inicialización aleatoria  $\mathbf{x}_0$

Desde  $i = 1$  a  $N$  repetir

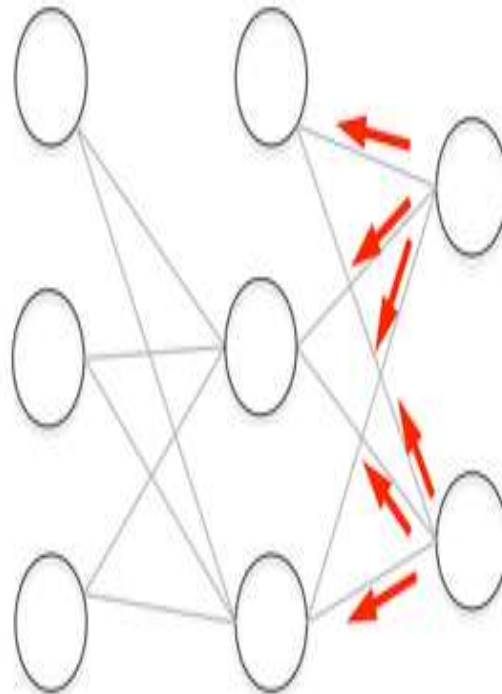
$$\mathbf{x}_0 := \mathbf{x}_0 - \alpha \left. \frac{dF}{dx} \right|_{\mathbf{x}=\mathbf{x}_0}$$

Fin

Donde:

$$\mathbf{x} \in \mathbb{R}, \mathbb{R}^n, \mathbb{R}^{n \times m}$$

$\alpha$  paso de búsqueda (índice de aprendizaje)



### 6.3.2.4. Pesos y Sesgo (bias)

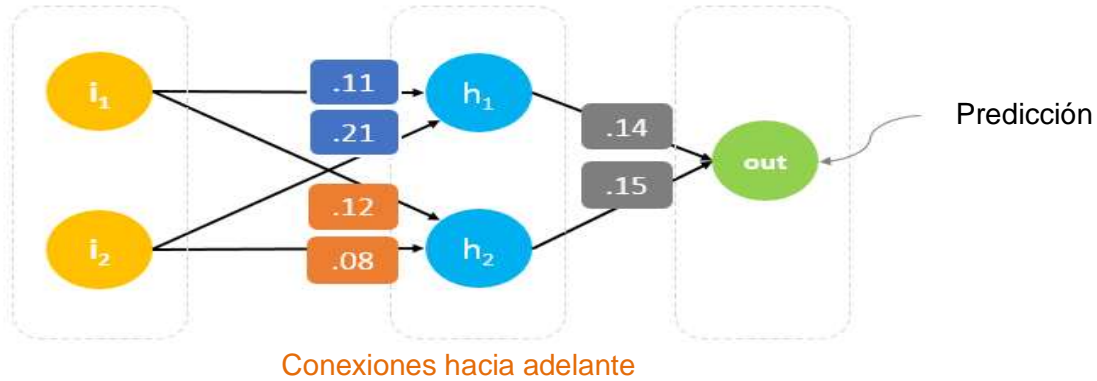
El entrenamiento de una red neuronal consiste en encontrar los pesos que minimicen el error de predicción. Por lo general, comenzamos nuestro entrenamiento con un conjunto de pesos generados al azar. Luego, la retropropagación se utiliza para actualizar los pesos en un intento de asignar correctamente entradas arbitrarias a las salidas como se muestra en la Figura 6.20.

Nuestros pesos iniciales serán los siguientes:

$$w_1 = 0.11 \quad w_2 = 0.21 \quad w_3 = 0.12 \quad w_4 = 0.08 \quad w_5 = 0.14 \quad w_6 = 0.15$$

Figura 6.20

*Pesos de la red neuronal y cálculo del error*




Realizando los cálculos de la multiplicación del vector y los pesos.

$$\begin{bmatrix} 2 & 3 \end{bmatrix} \cdot \begin{bmatrix} 0.11 & 0.12 \\ 0.21 & 0.08 \end{bmatrix} = \begin{bmatrix} 0.85 & 0.48 \end{bmatrix} \cdot \begin{bmatrix} 0.14 \\ 0.15 \end{bmatrix} = \begin{bmatrix} 0.191 \end{bmatrix}$$

$2 \times .11 + 3 \times .21 = .85$        $.85 \times .14 + .48 \times .15 = .191$   
 $2 \times .12 + 3 \times .08 = .48$

← Predicción



**Cálculo del error:**  $\frac{1}{2}(0.191 - 1.0)^2 = 0.327$

Nota: Tomado de Mahesh, H. Backpropagation Solved Example Train Neural network predict output Updates Weights by Dr. Mahesh.

### 6.3.2.5. El descenso de gradiente

Es un algoritmo de optimización iterativo para encontrar el mínimo de una función; siendo necesario minimizar la función de error. Para encontrar un mínimo local de una función utilizando el descenso de gradiente, se dan pasos proporcionales al negativo del gradiente de la función en el punto actual, a continuación, se muestra la fórmula utilizada:

**Descenso por gradiente**

$$w_i = w_i + \Delta w_i$$

$$\Delta w_i = -\alpha \frac{\partial E}{\partial w_i}$$

$$\frac{\partial E}{\partial w_i} = -(y - \hat{y}) \frac{\partial \hat{y}}{\partial w_i}$$

$$\frac{\partial E}{\partial w_i} = -(y - \hat{y}) f'(n) x_i$$

$$w_i = w_i + \alpha (y - \hat{y}) f'(n) x_i$$

$$J(Err) = \frac{1}{2n} \sum_{i=1}^n (y_i - \hat{y})^2$$

$$\frac{\partial E}{\partial w_i} = \frac{\partial}{\partial w_i} \frac{1}{2} (y - \hat{y})^2$$

Por simplicidad, cuando n = 1

$$\hat{y} = f(\mathbf{w}^T \mathbf{x} + b)$$

$$\frac{\partial \hat{y}}{\partial w_i} = f'(n) \frac{\partial}{\partial w_i} \mathbf{w}^T \mathbf{x}$$

$$w_i = w_i + \alpha \sum_k (y - \hat{y}) f'(n) x_i$$

Para todas las muestras

### 6.3.3. Tipos de Neuronas Artificiales

Las neuronas artificiales se pueden clasificar de acuerdo con los valores que pueden tomar.

Se pueden identificar dos tipos:

1. Neuronas binarias: únicamente pueden tomar valores que se encuentren dentro del intervalo  $\{-1, 1\}$  o  $\{0, 1\}$ .
2. Neuronas reales. estas pueden tomar valores que se encuentren dentro de los intervalos  $[0, 1]$  o  $[-1, 1]$ .

Generalmente, los pesos no se encuentran restringidos a intervalos específicos, aunque para aplicaciones específicas puede ser esto necesario Acevedo et. al (2017) citado por Matich, D. (2001). El aprendizaje de las redes neuronales se da a través de ejemplos. Basado a esto, podemos decir entonces que una red neuronal será capaz de resolver un problema dependiendo a los tipos de ejemplos que se obtienen durante la etapa del aprendizaje (Acevedo et. al 2017).

### 6.3.4. Aprendizaje de las Redes Neuronales

El proceso de aprendizaje de las redes neuronales artificiales se da en todo momento adquiriendo conocimiento a través de las experiencias ocurridas (de forma secuencial). El conjunto de aprendizaje de una red neuronal artificial contiene dos características denominadas:

- Ser significativo: debe existir un número significativo de ejemplos durante el proceso de aprendizaje.
- Ser representativo: los ejemplos y componentes del aprendizaje deberán ser diversos y equilibrados.

### 6.3.5. Tipos de Aprendizaje

Las redes neuronales se basan en un algoritmo para aprender durante su etapa de aprendizaje y dependiendo del tipo que se esté utilizando. Se da por entendido que una red aprendió cuando los pesos de las conexiones han cambiado según la regla de aprendizaje utilizada en



el entrenamiento y estos permanecen estables, los tipos de aprendizaje de las redes neuronales y su definición se muestran en la Tabla 6.3.

**Tabla 6.3**  
*Tipos de Aprendizaje*

Tipo de aprendizaje	Subtipo	Definición
Supervisado	Aprendizaje por corrección de error.	Durante el entrenamiento, se presenta a la red neuronal artificial, las entradas y salidas deseadas. Identifica una diferencia mínima entre la salida obtenida y la deseada. Para ello, se hace una comparación de ambas salidas y se ajustan los pesos de las conexiones de la red teniendo en cuenta las diferencias con los valores deseados y los obtenidos
	Aprendizaje por refuerzo.	No se cuenta con un ejemplo completo de una salida esperada, el diseñador de la red indica, mediante una señal de refuerzo, si la salida que se obtuvo de la red se acerca a la deseada. Las señales de refuerzo son: 1) Éxito o 2) Fracaso. Con esto se ajustan los pesos basándose en un mecanismo de probabilidades para acercarse a la salida deseada. Para este aprendizaje, la señal de refuerzo solo informa si la salida de la red se acerca a la deseada o no. En algunos algoritmos, con la señal de "Fracaso" se siguen modificando los pesos. Con la señal de "Éxito" el sistema ha cumplido con una salida deseada. Suele ser más lento que el aprendizaje por corrección de error ya que puede recibir señales de Fracaso consecutivas. Entre más veces se reciba una señal de refuerzo, más tiempo tardará la red en aprender
	Aprendizaje estocástico	Se realizan cambios de forma aleatoria en los pesos de la red y se analiza la salida obtenida en comparación a la salida deseada. Si la diferencia de ambas salidas es mínima, esto significa que la red ha aprendido. Si la diferencia entre las salidas obtenida y esperada es mayor, se aceptarían cambios en el peso en función de una distribución de probabilidades determinadas.
No supervisado		No se requieren de unas salidas deseadas y debidas. Por lo tanto, no se realizan comparaciones entre las salidas reales y las salidas. El algoritmo de entrenamiento modifica los pesos de la red de tal manera que se produzcan vectores de salida consistentes.

Fuente: Adaptado de Acevedo et. al (2017)

### 6.4. Deep Reinforcement Learning

El Deep Reinforcement Learning (DRL, Reforzamiento de Aprendizaje Profundo) es un subcampo de Machine Learning. Por un lado, utiliza muchos métodos bien establecidos del aprendizaje supervisado, como las redes neuronales profundas para la aproximación de funciones, descenso de gradiente estocástico y retropropagación, para aprender la representación de datos. Según Lapan, M. (2020, p. 3), para comparar RL (Reinforcement Learning) con aprendizaje supervisado y no supervisado, tomaremos un camino menos formal, pero más fácil de entender. Imagina que tienes un agente que necesita realizar acciones en algún entorno. (Tanto "agente" como "entorno" se definirán en detalle más adelante en este capítulo). Un ratón robot en un laberinto es un buen ejemplo, pero también puedes imaginar un helicóptero automático tratando de realizar una tirada, o un programa de ajedrez aprendiendo cómo vencer a un gran maestro. Vayamos con el ratón robot por simplicidad. El DRL es un enfoque computacional para aprender políticas óptimas a partir de la entrada sensorial de alta dimensión utilizando retroalimentación. Se ha utilizado con éxito para resolver una variedad de tareas, incluidas aquellas tradicionalmente consideradas difíciles para los agentes de aprendizaje, como la navegación 3D, la manipulación de objetos y los juegos estratégicos como el ajedrez y el Go.

El DRL combina dos modelos de redes neuronales: una red neuronal profunda que representa el entorno y una red neuronal recurrente que representa al agente. La red neuronal profunda está entrenada para mapear la entrada de alta dimensión (como los píxeles sin procesar de una cámara) a la salida deseada (como la siguiente mejor acción para el agente). La red

neuronal recurrente se entrena para mapear la salida de la red neuronal profunda a la recompensa esperada por tomar esa acción.

Las dos redes se entrenan juntas utilizando un algoritmo de aprendizaje por refuerzo, como Q-learning. Esto permite al agente aprender cómo interactuar mejor con su entorno para maximizar su recompensa esperada.

Se ha demostrado que el aprendizaje por refuerzo profundo es efectivo para resolver una variedad de tareas, incluidas aquellas que son difíciles o imposibles para los métodos tradicionales de aprendizaje por refuerzo. En los últimos años, se ha utilizado para resolver tareas de navegación 3D, tareas de manipulación de objetos y juegos estratégicos como ajedrez y Go. Los algoritmos de aprendizaje por refuerzo profundo se han utilizado para resolver tareas difíciles en videojuegos

Mnih et al. (2015), Schulman et al., (2015; Lillicrap et al., (2015) y Levine et al., (2015) refieren que las tareas con recompensas dispersas como "Robot, tráeme una cerveza" siguen siendo difíciles de resolver con la aplicación directa de estos algoritmos. Una razón es que el número de muestras necesarias para resolver una tarea con exploración aleatoria aumenta exponencialmente con el número de pasos para obtener una recompensa (Langford, 2011). Un enfoque para superar este problema es utilizar el CL (Bengio et al., 2009; Zaremba y Sutskever, 2014; Graves et al., 2016; Wu y Tian, 2017), donde las tareas se ordenan por dificultad creciente y el entrenamiento solo procede a tareas más difíciles una vez que se

dominan las más fáciles. El Curriculum Learning (CL) ayuda cuando después de dominar una tarea más simple, la política para una tarea más difícil se puede descubrir a través de la exploración aleatoria, el siguiente apartado describe el aprendizaje mediante el modelo de aprendizaje curriculum learning.

### 6.5. Curriculum Learning

El aprendizaje de transferencia de Lazaric (2011); Taylor y Stone (2009) es una de varias líneas de investigación que han buscado aumentar la eficiencia de la capacitación de agentes de aprendizaje por refuerzo. En el aprendizaje de transferencia, los agentes se capacitan en tareas de origen simples y transfieren el conocimiento adquirido para mejorar el aprendizaje en una tarea objetivo más difícil. Por lo general, este ha sido un proceso de una sola vez, donde la información se transfiere de una o más fuentes directamente a la tarea objetivo. Sin embargo, a medida que asignamos tareas a los agentes de aprendizaje de refuerzo los problemas se vuelven cada vez más complejos, puede ser beneficioso (e incluso necesario) adquirir gradualmente habilidades en múltiples tareas en secuencia, donde cada tarea posterior se basa en el conocimiento adquirido en una tarea anterior. Esta idea es la base para el curriculum learning (CL, aprendizaje curricular) Bengio et al. (2009); Narvekar et al. (2016).

Autores como Hachohen, G. y Weinshall, D. (2019), refieren que la imposición de un currículo para acelerar el aprendizaje se usa ampliamente en el contexto del aprendizaje humano y el entrenamiento animal (Skinner, 1958; Pavlov, 2010; Krueger & Dayan, 2009). En muchas áreas de aplicación, es una práctica común introducir conceptos en orden ascendente de

dificultad, según lo juzgue el maestro humano o de manera dependiente del problema (por ejemplo, Murphy et al., 2008; Zaremba & Sutskever, 2014; Amodei et al. al., 2016).

El CL, aborda la cuestión de cómo usar el conocimiento previo sobre la dificultad de los ejemplos de entrenamiento, para muestrear cada mini-lote de manera no uniforme y así aumentar la tasa de aprendizaje y la precisión del clasificador final. El paradigma de CL se basa en la intuición de que ayuda al proceso de aprendizaje cuando al alumno se le presentan primero conceptos simples.

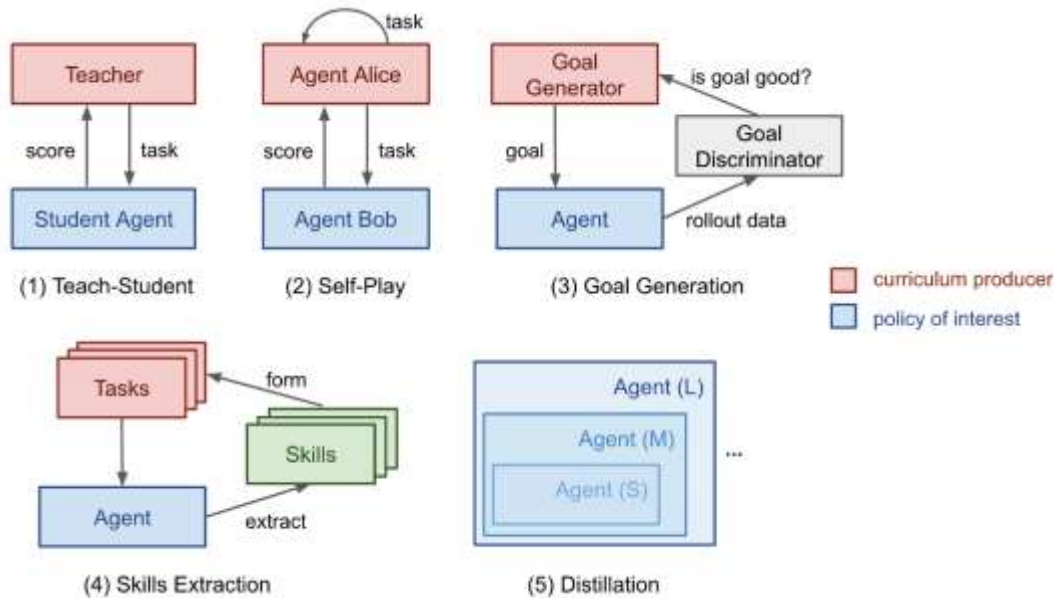
### 6.5.1. Estilos de CL por Refuerzo

En 1993, Jeffrey Elman propuso la idea de entrenar redes neuronales con un plan de estudios. Su trabajo inicial sobre el aprendizaje de la gramática del lenguaje simple demostró la importancia de tal estrategia: comenzar con un conjunto restringido de datos simples y aumentar gradualmente la complejidad de las muestras de entrenamiento.

Diseñar un currículo eficiente y eficaz no es fácil, dado que un mal plan de estudios puede incluso dificultar el aprendizaje. Algunas categorías CL, como se ilustra en la Figura 6.21 en la mayoría de los casos se aplican al aprendizaje por refuerzo, con algunas excepciones al aprendizaje supervisado.

Figura 6.21

*Estilos de Curriculum Learning por Refuerzo*



Nota: Tomado de Weng, L. (29 de enero de 2020) Curriculum for Reinforcement Learning

La descripción de cada uno de los estilos de CL y su algoritmo se dan a continuación.

### 6.5.1.1. Plan de estudios guiado por el maestro

En palabras de Weng, L. (2020), la idea del CL automático fue propuesta por Graves, et al. 2017 un poco antes. Considera un N-currículo de tareas como un N-bandido armando un problema y una política adaptativa que aprende a optimizar los rendimientos de este bandido, para este proceso se han considerado dos categorías de señales de aprendizaje:

- Progreso basado en pérdidas: la función de pérdida cambia antes y después de una actualización de degradado. Este tipo de señales de recompensa rastrea la velocidad

del proceso de aprendizaje, porque la mayor disminución de la pérdida de tareas es equivalente al aprendizaje más rápido.

- Progreso impulsado por complejos: la divergencia KL entre la distribución posterior y previa sobre los pesos de la red. Este tipo de señales de aprendizaje están inspiradas en el principio MDL, <sup>19</sup> "aumentar la complejidad del modelo en una cierta cantidad solo vale la pena si comprime los datos en una cantidad mayor". Por lo tanto, se espera que la complejidad del modelo aumente más en respuesta a la generalización del modelo a los ejemplos de entrenamiento.

Este marco de proponer currículo automáticamente a través de otro agente de RL se formalizó como CL Maestro-Estudiante (TSCL; Matiisen, et al. 2017). En TSCL, un estudiante es un agente de RL que trabaja en tareas reales, mientras que un profesor es un agente para seleccionar tareas de una política. El estudiante tiene como objetivo dominar una tarea compleja que puede ser difícil de aprender directamente. Para que esta tarea sea más fácil de aprender, configuramos el agente docente para guiar el proceso de capacitación del estudiante eligiendo las subtareas adecuadas (Weng, L. 2020).

En el proceso, el estudiante debe aprender tareas que:

1. Ayuden al estudiante a progresar más rápido en el aprendizaje, o
2. Correr el riesgo de ser olvidados.

---

<sup>19</sup> **La longitud mínima** de descripción (**MDL**) es un principio de selección de modelos donde la descripción más corta de los datos es el mejor modelo. Los métodos MDL aprenden a través de una perspectiva de compresión de datos y a veces se describen como aplicaciones matemáticas de la navaja de Occam. (Tomado de: [Longitud mínima de la descripción - Wikipedia, la enciclopedia libre](#)).

El Algoritmo de Progreso Absoluto de Aprendizaje (APL) se muestra en la Figura 6.22

**Figura 6.22**

*Algoritmo de Progreso Absoluto de Aprendizaje (APL)*

---

**Algorithm 1** Absolute Learning Progress Gaussian Mixture Model (ALP-GMM)

---

**Require:** Student  $\mathcal{S}$ , parametric procedural environment generator  $E$ , bounded parameter space  $\mathcal{P}$ , probability of random sampling  $p_{rnd}$ , fitting rate  $N$ , max number of Gaussians  $k_{max}$

- 1: Initialize parameter-ALP First-in-First-Out window  $\mathcal{W}$ , set max size to  $N$
- 2: Initialize parameter-reward history database  $\mathcal{H}$
- 3: **loop**  $N$  times ▷ Bootstrap phase
- 4:   Sample random  $p \in \mathcal{P}$ , send  $E(\tau \sim \mathcal{T}(p))$  to  $\mathcal{S}$ , observe episodic reward  $r_p$
- 5:   Compute ALP of  $p$  based on  $r_p$  and  $\mathcal{H}$  (see equation 2)
- 6:   Store  $(p, r_p)$  pair in  $\mathcal{H}$ , store  $(p, ALP_p)$  pair in  $\mathcal{W}$
- 7: **loop** ▷ Stop after  $K$  inner loops
- 8:   Fit a set of GMM having 2 to  $k_{max}$  kernels on  $\mathcal{W}$
- 9:   Select the GMM with best Akaike Information Criterion
- 10: **loop**  $N$  times
- 11:    $p_{rnd}$ % of the time, sample a random parameter  $p \in \mathcal{P}$  epsilon-greedy
- 12:   Else, sample  $p$  from a Gaussian chosen proportionally to its mean ALP value
- 13:   Send  $E(\tau \sim \mathcal{T}(p))$  to student  $\mathcal{S}$  and observe episodic reward  $r_p$
- 14:   Compute ALP of  $p$  based on  $r_p$  and  $\mathcal{H}$
- 15:   Store  $(p, r_p)$  pair in  $\mathcal{H}$ , store  $(p, ALP_p)$  pair in  $\mathcal{W}$
- 16: **Return**  $\mathcal{S}$

---

Nota: Tomada de Weng, L. (2020) citado por **Portelas, et al., 2019**

### 6.5.1.2. Plan de estudios a través del juego personal

En el aprendizaje basado en el plan de estudios a través del juego personal Weng. L: (2020) citado por Sukhbaatar, et al. (2017) propusieron un marco para el aprendizaje automático del currículo a través del auto juego asimétrico. Dos agentes, Alice y Bob, juegan la misma tarea con diferentes objetivos: Alice desafía a Bob a alcanzar el mismo estado y Bob intenta completarlo lo más rápido posible, representado en la Figura 6.23.



**Figura 6.23.**

*Plan de estudios a través del juego personal*



Nota: Representación de la configuración de autojuego al entrenar a dos agentes. Se le pide a un agente que alcance una bandera de meta en un laberinto con un interruptor de luz, una llave y una pared con una puerta. Al alternar el interruptor de la llave se puede abrir o cerrar la puerta y apagar la luz solo el interruptor de luz brillante está disponible para el agente. Tomado de Weng, L. (2020) citado por Sukhbaatar, et al. 2017).

La descripción de este algoritmo mencionada por Weng, L. (2020) refiere considerar a Alice y Bob como dos copias separadas para un agente de RL entrenado en el mismo entorno pero con cerebros diferentes. Cada uno de ellos tiene parámetros independientes y objetivo de pérdida. El entrenamiento autodidacta consta de dos tipos de episodios:

- En el *episodio de auto-play*, Alice altera el estado de  $s_0$ . Para  $s_t$  y luego se le pide a Bob que devuelva el entorno a su estado original  $s_0$  para obtener una recompensa interna.
- En el episodio de la *tarea objetivo*, Bob recibe una recompensa externa si visita la bandera objetivo.

Nótese que como B tiene que repetir las acciones entre el mismo par de  $(s_0, s_t)$  de A, este marco solo funciona en entornos reversibles o reiniciables.

Alice debería aprender a empujar a Bob fuera de su zona de confort, pero no darle tareas imposibles. La recompensa de Bob se establece como  $R_B = -\gamma t_B$  y la recompensa de Alice es  $R_A = \gamma \max(0, t_B - t_A)$ . Donde  $t_B$  es el tiempo total para que B complete la tarea,  $t_A$  es el tiempo hasta que Alice realiza la acción STOP y  $\gamma$  es una constante escalar para reescalar la recompensa para que sea comparable con la recompensa de la tarea externa. Si B falla una tarea,  $t_B = t_{\max} - t_A$ . Ambas políticas están condicionadas por objetivos. Las pérdidas implican:

1. B quiere terminar una tarea lo antes posible.
2. A prefiere tareas que toman más tiempo de B.
3. A no quiere dar demasiados pasos cuando B está fallando.

De esta manera, la interacción entre Alice y Bob construye automáticamente un plan de estudios de tareas cada vez más desafiantes. Mientras tanto, como A ha hecho la tarea ella misma antes de proponer la tarea a B, se garantiza que la tarea sea solucionable.

El paradigma de A sugiriendo tareas y luego B resolviéndolas suena similar al marco Maestro-Alumno. Sin embargo, en el auto juego asimétrico, Alice, que desempeña un papel de maestra, también trabaja en la misma tarea para encontrar casos desafiantes para Bob, en lugar de optimizar el proceso de aprendizaje de B explícitamente.

### 6.5.1.3. Plan de estudios por Generación Automática de Objetivos

La política de RL debe poder realizar un conjunto de tareas. El objetivo debe elegirse cuidadosamente para que en cada etapa de capacitación, no sea demasiado difícil o

demasiado fácil para la política actual. Un objetivo  $g \in G$  se puede definir como un conjunto de estados  $S^g$  y un objetivo se considera alcanzado cada vez que un agente llega a cualquiera de esos estados.

Según el enfoque del Aprendizaje Generativo de Objetivos (Florensa, et al. 2018) se basa en una **GAN de Objetivos** (Generative Adversarial Networks (GANs) para generar los objetivos deseados automáticamente. En su experimento, la recompensa es muy escasa, solo una bandera binaria de si se logra o no un objetivo y la política está condicionada a un objetivo.

$$\pi^*(a_t | s_t, g) = \arg \max_{\pi} \mathbb{E}_{g \sim p_g(\cdot)} R^g(\pi)$$

where  $R^g(\pi) = \mathbb{E}_{\pi(\cdot | s_t, g)} \mathbf{1}[\exists t \in [1, \dots, T] : s_t \in S^g]$

Aquí  $R^g(\pi)$  es el retorno esperado, también equivalente a la probabilidad de éxito. Dadas las trayectorias muestreadas de la política actual, siempre que cualquier estado pertenezca al objetivo establecido, el rendimiento será positivo. Su enfoque itera a través de 3 pasos hasta que la política converge:

1. Etiquetar un conjunto de objetivos en función de si están en el nivel adecuado de dificultad para la política actual.
  - El conjunto de objetivos en el nivel apropiado de dificultad se denomina **GOID** (abreviatura de "Objetivos de dificultad intermedia").

$$\text{GOID}_i := \{g : R_{\min} \leq R^g(\pi_i) \leq R_{\max}\} \subseteq G$$

- Aquí  $R_{\min}$  y  $R_{\max}$  puede interpretarse como una probabilidad mínima y máxima de alcanzar una meta en  $T$  pasos de tiempo.
2. Entrenar un modelo GAN de objetivos utilizando objetivos etiquetados del paso 1 para producir nuevos objetivos:
3. Utilizar estas nuevas metas para capacitar a la póliza, mejorando su objetivo de cobertura.

La GAN de objetivos genera un currículo automáticamente:

- El Generador  $G(z)$ : produce un nuevo objetivo. => se espera que sea un objetivo muestreado uniformemente de GOID poner.
- El Discriminador:  $D(g)$ : evalúa si se puede lograr un objetivo. => se espera que diga si un objetivo es de GOID poner.

El Goal GAN está construido de manera similar a LSGAN (Least-Squared GAN; Mao et al., (2017)), que tiene una mejor estabilidad de aprendizaje en comparación con la GAN vainilla.

Según LSGAN, debemos minimizar las siguientes pérdidas para  $D$  y  $G$  respectivamente:

$$\mathcal{L}_{\text{LSGAN}}(D) = \frac{1}{2} \mathbb{E}_{g \sim p_{\text{data}}(g)} [(D(g) - b)^2] + \frac{1}{2} \mathbb{E}_{z \sim p_z(z)} [(D(G(z)) - a)^2]$$
$$\mathcal{L}_{\text{LSGAN}}(G) = \frac{1}{2} \mathbb{E}_{z \sim p_z(z)} [(D(G(z)) - c)^2]$$

Dónde  $a$  es la etiqueta para los datos falsos,  $b$  para datos reales, y  $c$  es el valor que  $G$  Quiere  $D$  para creer en datos falsos. En los experimentos del artículo de LSGAN, usaron  $a=-1$ ,  $b=1$ ,  $c=0$ .

La GAN de Goal introduce un indicador binario adicional  $y_b$  indicando si un objetivo  $g$  es real ( $y_g=1$ ) o falso ( $y_g=0$ ) para que el modelo pueda utilizar muestras negativas para el entrenamiento:

$$\mathcal{L}_{\text{GoalGAN}}(D) = \frac{1}{2} \mathbb{E}_{g \sim p_{\text{data}}(g)} [(D(g) - b)^2 + (1 - y_g)(D(g) - a)^2] + \frac{1}{2} \mathbb{E}_{z \sim p_z(z)} [(D(G(z)) - a)^2]$$

$$\mathcal{L}_{\text{GoalGAN}}(G) = \frac{1}{2} \mathbb{E}_{z \sim p_z(z)} [(D(G(z)) - c)^2]$$

La Figura 6.24 presenta el Algoritmo de Aprendizaje por Generación de Objetivos.

**Figura 6.24**

*Algoritmo de Aprendizaje por Generación de Objetivos*

---

**Algorithm 1** Generative Goal Learning

---

**Input:** Policy  $\pi_0$   
**Output:** Policy  $\pi_N$   
 $(G, D) \leftarrow \text{initialize\_GAN}()$   
 $goals_{\text{old}} \leftarrow \emptyset$   
**for**  $i \leftarrow 1$  **to**  $N$  **do**  
     $z \leftarrow \text{sample\_noise}(p_z(\cdot))$   
     $goals \leftarrow G(z) \cup \text{sample}(goals_{\text{old}})$   
     $\pi_i \leftarrow \text{update\_policy}(goals, \pi_{i-1})$   
     $returns \leftarrow \text{evaluate\_policy}(goals, \pi_i)$   
     $labels \leftarrow \text{label\_goals}(returns)$   
     $(G, D) \leftarrow \text{train\_GAN}(goals, labels, G, D)$   
     $goals_{\text{old}} \leftarrow \text{update\_replay}(goals)$   
**end for**

---

Nota: Tomado de Weng, L. (2020). El algoritmo de Generative Goal Learning. (Fuente de la imagen: (Florensa, et al. 2018).

#### 6.5.1.4. Currículo Basado en Habilidades

Las habilidades adquiridas por el ser humano también pueden ser adquiridas en el aprendizaje de CL. Otro punto de vista es descomponer lo que un agente es capaz de completar en una variedad de habilidades y cada conjunto de habilidades podría ser mapeado en una tarea.

Imaginemos que cuando un agente interactúa con el entorno de una manera no supervisada (Weing, L. (2020)

Jabri, et al. (2019) desarrollaron un plan de estudios automático, **CARML** (abreviatura de "Curricula for Unsupervised Meta-Reinforcement Learning"), modelando trayectorias no supervisadas en un espacio de habilidades latentes, con un enfoque en el entrenamiento de políticas meta-RL<sup>20</sup> (es decir, pueden transferirse a tareas invisibles). El algoritmo Curriculum por Meta Refuerzo de Aprendizaje No Supervisado se muestra en la Figura 6.25

**Figura 6.25**  
*Currículo por Meta Refuerzo de Aprendizaje No Supervisado*

---

**Algorithm 1:** CARML – Curricula for Automatic Reinforcement of Meta-Learning

---

- 1: **Require:**  $\mathcal{C}$ , an MDP without a reward function
- 2: Initialize  $f_\theta$ , an RL algorithm parameterized by  $\theta$ .
- 3: Initialize  $\mathcal{D}$ , a reservoir of state trajectories, via a randomly initialized policy.
- 4: **while** not done **do**
- 5:     Fit a task-scaffold  $q_\phi$  to  $\mathcal{D}$ , e.g. by using Algorithm 2. **E-step §3.2**
- 6:     **for** a desired mixture model-fitting period **do**
- 7:         Sample a latent task variable  $\mathbf{z} \sim q_\phi(\mathbf{z})$ .      $r_{\mathbf{z}}(\mathbf{s}) = \lambda \log q_\phi(\mathbf{s}|\mathbf{z}) - \log q_\phi(\mathbf{s})$
- 8:         Define the reward function  $r_{\mathbf{z}}(\mathbf{s})$ , e.g. by Eq. 8, and a task  $\mathcal{T} = \mathcal{C} \cup r_{\mathbf{z}}(\mathbf{s})$ .     CMP + reward  $\Rightarrow$  MDP
- 9:         Apply  $f_\theta$  on task  $\mathcal{T}$  to obtain a policy  $\pi_\theta(\mathbf{a}|\mathbf{s}, \mathcal{D}_\mathcal{T})$  and trajectories  $\{\tau_i\}$ .
- 10:         Update  $f_\theta$  via a meta-RL algorithm, e.g. RL<sup>2</sup> [13]. **M-step §3.3**
- 11:         Add the new trajectories to the reservoir:  $\mathcal{D} \leftarrow \mathcal{D} \cup \{\tau_i\}$ .
- 12: **Return:** a meta-learned RL algorithm  $f_\theta$  tailored to  $\mathcal{C}$

---



---

**Algorithm 2:** Task Acquisition via Discriminative Clustering

---

- 1: **Require:** a set of trajectories  $\mathcal{D} = \{(\mathbf{s}_1, \dots, \mathbf{s}_T)\}_{i=1}^N$
- 2: Initialize  $\phi$ , the mixture model parameters.
- 3: **while** not converged **do**
- 4:     Compute  $L(\phi; \tau, \mathbf{z}) = \sum_{\mathbf{s}_t \in \tau} \log q_\phi(\mathbf{s}_t | \mathbf{z})$ .
- 5:      $\phi \leftarrow \arg \max_{\phi'} \sum_{i=1}^N L(\phi'; \tau_i, \mathbf{z})$ .
- 6: **Return:** a mixture model  $q_\phi(\mathbf{s}, \mathbf{z})$

---

Nota: Tomado Weng, L. (2020) citado por Jabri, et al (2019)

<sup>20</sup> El proceso de adaptación, ocurre durante la prueba, pero con una exposición limitada a las nuevas tareas.. Esta es la razón por la cual el metaaprendizaje también se conoce como aprender a aprender. (Weing, L. 2019)

### 6.5.1.5. Plan de Estudios a través de la Destilación

La motivación para la arquitectura de la red neuronal progresiva (Rusu et al. 2016) es transferir eficientemente las habilidades aprendidas entre diferentes tareas y, mientras tanto, evitar el olvido catastrófico. El plan de estudios se realiza a través de un conjunto de torres de redes neuronales progresivamente apiladas (o "columnas", como en el documento).

Una red progresiva tiene la siguiente estructura:

1. Comienza con una sola columna que contiene  $L$  capas de neuronas, en las que las capas de activación correspondientes se etiquetan como:

$$h_i^{(1)}, i = 1, \dots, L.$$

Primero entrenamos esta red de una sola columna para una tarea de convergencia, logrando la configuración de parámetros  $\theta^{(1)}$ .

2. Una vez que cambiamos a la siguiente tarea, necesitamos agregar una nueva columna para adaptarnos al nuevo contexto mientras congelamos  $\theta^{(1)}$  para bloquear las habilidades aprendidas de la tarea anterior. La nueva columna tiene capas de activación etiquetadas como

$$h_i^{(2)}, i = 1, \dots, L, \text{ y parámetros } \theta^{(2)}$$

3. El paso 2 se puede repetir con cada nueva tarea. El  $i$ -ésima activación de capa en el  $k$ -ésima columna depende de las capas de activación anteriores en todas las columnas existentes:

$$h_i^{(k)} = f(W_i^{(k)} h_{i-1}^{(k)} + \sum_{j < k} U_i^{(k;j)} h_{i-1}^{(j)})$$


Dónde:  $W_i^{(k)}$

$W_i^{(k)}$  es la matriz de peso de la capa  $i$  en la columna.

$U_i^{(k;j)}, j < k$  son las matrices de peso para proyectar la capa  $i-1$  (de la columna) a la capa  $i$  de la columna  $k(j < k)$ .

Las matrices de pesos anteriores deben ser aprendidas.  $f(\cdot)$  es una función de activación no lineal por elección. La Figura 6.26 muestra la Arquitectura de la Red Neuronal Progressiva.

**Figura 6.26**  
*Arquitectura de la Red Neuronal Progressiva*



Nota: Tomado de Rusu, et. al (2017)



El documento experimentó con juegos de Atari entrenando una red progresiva en múltiples juegos para verificar si las características aprendidas en un juego pueden transferirse a otro. De hecho, ese es el caso. Aunque curiosamente, aprender una alta dependencia de las características de las columnas anteriores no siempre indica un buen rendimiento de transferencia en la nueva tarea. Una hipótesis es que las características aprendidas de la tarea anterior podrían introducir sesgos en la nueva tarea, lo que llevaría a que la política quedara atrapada en una solución subóptima. En general, la red progresiva funciona mejor que solo ajustar la capa superior y puede lograr un rendimiento de transferencia similar al ajuste fino de toda la red.

Para dar continuidad a los enfoques de aprendizaje del plan de estudios descritos anteriormente, generalmente necesitamos resolver dos problemas en el procedimiento de capacitación siendo necesario diseñar una métrica para cuantificar qué tan difícil es una tarea para que podamos ordenar las tareas en consecuencia y proporcionar una secuencia de tareas con un nivel de dificultad creciente al modelo durante el entrenamiento

### 6.5.2. Clasificación de Dificultad de las Funciones de Puntuación

#### **Transferencia de Aprendizaje**

Las puntuaciones de la red de inicio previamente entrenada tomarían una red preentrenada y luego verían para qué muestras tienen puntajes de clasificación y luego usarían eso para clasificar la dificultad de cada muestra en el conjunto de entrenamiento las otras ideas de arranque donde los puntajes de una red preentrenada con la misma arquitectura como la red

en la que desea entrenar el modelo actual es el aprendizaje del plan de estudios, por lo que la diferencia clave entre estas dos funciones de puntuación es que, en lugar de usar una red preparada que no comparte los mismos parámetros que la red que se usa con el aprendizaje del plan de estudios. Los tipos aprendizaje que utilizan el CL son:

- Orden ascendente de dificultad
- Orden descendente de dificultad (anti curriculum)
- Aleatorio (similar to SGD)

### 6.5.3. Aportaciones del Curriculum Learning

#### 6.5.3.1. Minecraft basado en Curriculum Learning

En palabras de Zippo, M. (2022) los investigadores de IA abierta enseñaron a la inteligencia artificial cómo jugar Minecraft. La red neuronal fue entrenada usando videos de juego.

Para entrenar la red neuronal, los ingenieros desarrollaron un método de Video PreTraining (VPT) que permite utilizar una gran cantidad de datos sin etiquetar. La IA utilizó la emulación de un mouse y teclado estándar para el juego.


En la primera etapa de entrenamiento, los ingenieros utilizaron videos de juegos de Minecraft etiquetados con una duración total de 2,000 horas. Para el marcado fueron utilizados datos sobre las teclas que los usuarios presionaron durante el juego. Como resultado obtuvieron una red neuronal que podía procesar videos de forma independiente, adivinar pulsaciones de teclas y grabarlos. Con la ayuda de esta red neuronal, otras 70 mil horas de juego de fuentes abiertas se etiquetaron automáticamente.

La RNA aprendió a realizar no solo acciones básicas en Minecraft, sino también acciones bastante complejas que requieren una toma de decisiones consistente. Por ejemplo, una red neuronal es capaz de extraer recursos y hacer objetos de ellos, correr, nadar, evitar obstáculos, cazar animales en busca de comida y comer alimentos, reponiendo la escala de hambre. Además, la IA ha aprendido, rebotando, a poner bloques debajo del personaje, lo que le permite subir la colina.

Después de eso, los investigadores decidieron afinar la red neuronal y para ello pidieron a los usuarios participantes en el proyecto que crearan un nuevo mundo en el juego, recolectaran todos los recursos necesarios para comenzar y hacer elementos esenciales de ellos. Al mismo tiempo, los usuarios grabaron el juego y los datos resultantes se utilizaron para el entrenamiento. En la salida, la red neuronal aprendió a comenzar correctamente en el juego y ya no vagaba sin rumbo, sino que buscaba hacer un banco de trabajo con el que se puedan hacer elementos del juego. En la Figura 6.27 se muestra la predicción del número por una RNA en Minecraft

**Figura 6.27**

*Predicción del número en Minecraft mediante una RNA*



Nota: Tomado de Sathe, A. 2020. *Programmable Neural Networks in Minecraft*. [[video](#)].

### 6.5.3.2. Resolviendo El Cubo de Rubik

El uso de la IA en el cubo de Rubik descrita en OpenAI et al (2019), se refiere a la automatización del proceso que una mano robótica realiza para resolver de forma autónoma integrar en cada una de las 6 caras del cubo, los 12 cuadros de un solo color. En este proceso se tiene una dependencia aleatoria *automática de dominios* para generar un plan de estudios mediante el crecimiento de una distribución de entornos con una complejidad creciente. La dificultad de cada tarea (es decir, resolver un cubo de Rubik en un conjunto de entornos) depende de los rangos de aleatorización de varios parámetros ambientales. Incluso con una suposición simplificada de que todos los parámetros ambientales no están correlacionados, fue posible la creación de un plan de estudios para que la mano robótica aprendiera la tarea. La Figura 6.28 presenta la mano robótica resolviendo el cubo de Rubik.

**Figura 6.28**

*Mano robótica resolviendo el cubo de Rubik*



Se ha concluido con el marco teórico que define los conceptos claves y las teorías que se consideraron relevantes en el campo de las competencias digitales, el e-learning, el Machine Learning, el Deep Learning, las redes neuronales biológicas y artificiales y el Curriculum Learning. Esto ha permitido interpretar, explicar y generalizar de forma convincente a partir de los hallazgos identificados.

El contexto descrito en el marco contextual y teórico permite sentar las bases de esta investigación para proponer una relación entre ellas bajo la conceptualización y el diseño experimental de un modelo de IA basado en el curriculum learning presentado en el siguiente capítulo.



## **Capítulo 7 Propuesta de diseño- Curriculum Learning**

## Capítulo 7 Propuesta del Diseño Experimental

### 7. Propuesta de Diseño del Modelo Experimental de CL

La propuesta de diseño del modelo presenta un vínculo claro entre las teorías presentadas en el marco teórico y el objetivo de la investigación basado en una propuesta de un modelo de IA. El análisis de las competencias digitales y su evaluación permiten identificar los requerimientos, conocer por qué es necesario contar con competencias digitales fue trascendente por la constante evolución de la tecnología enfocado principalmente en la educación mediante e-learning. En opinión del autor, las competencias digitales son requeridas aun cuando la modalidad sea presencial, es una necesidad el uso y aprovechamiento de los recursos tecnológicos para optimizar y dinamizar el aprendizaje.

Para obtener información precisa y válida, es necesario conocer el proceso que considera la minería de datos ya que la información y conjunto de datos se incorpora a un modelo de IA.

#### 7.1. Minería de Datos

La minería de datos es un proceso automatizado de búsqueda de patrones en grandes conjuntos de datos que, a simple vista, los humanos no pueden identificar. Todo esto con la ayuda de la IA, el aprendizaje automático y las estadísticas.

El objetivo es encontrar patrones, correlaciones e incluso anomalías para poder predecir resultados futuros.

### 7.1.1. Fases de la Minería de Datos para el modelo

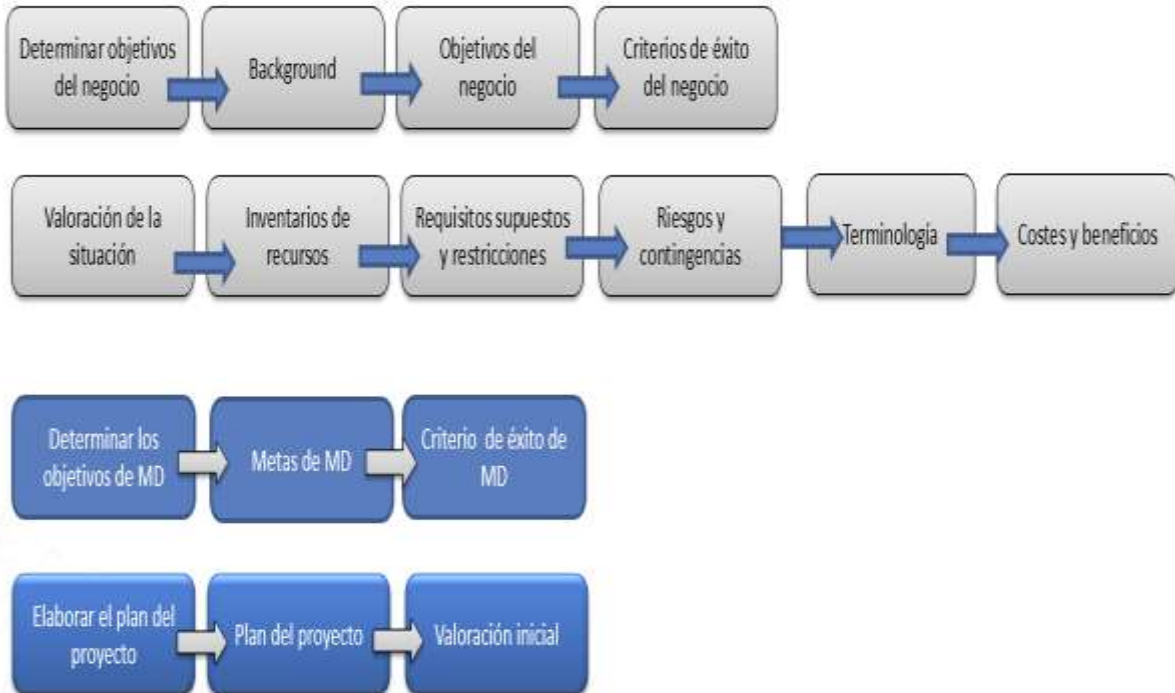
Existe una aportación propia de técnicas específicas de IA en particular sobre la integración de los algoritmos, la automatización del proceso y la optimización del costo que implica el resultado del procesamiento de millones de datos en todo momento, en la Figura 7.1 se presentan las fases de la Minería de Datos.

**Figura 7.1**  
*Línea del tiempo en la Minería de Datos*

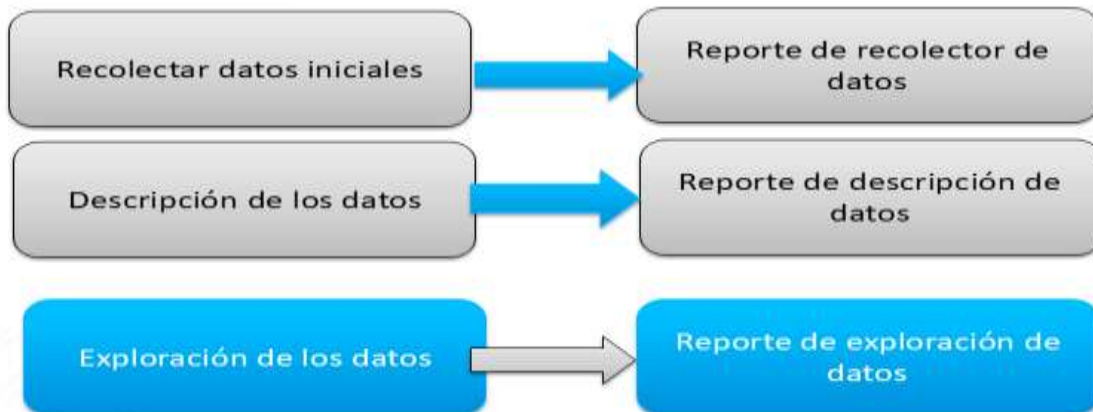




## 1 Comprensión del negocio



## 2 Comprensión de datos







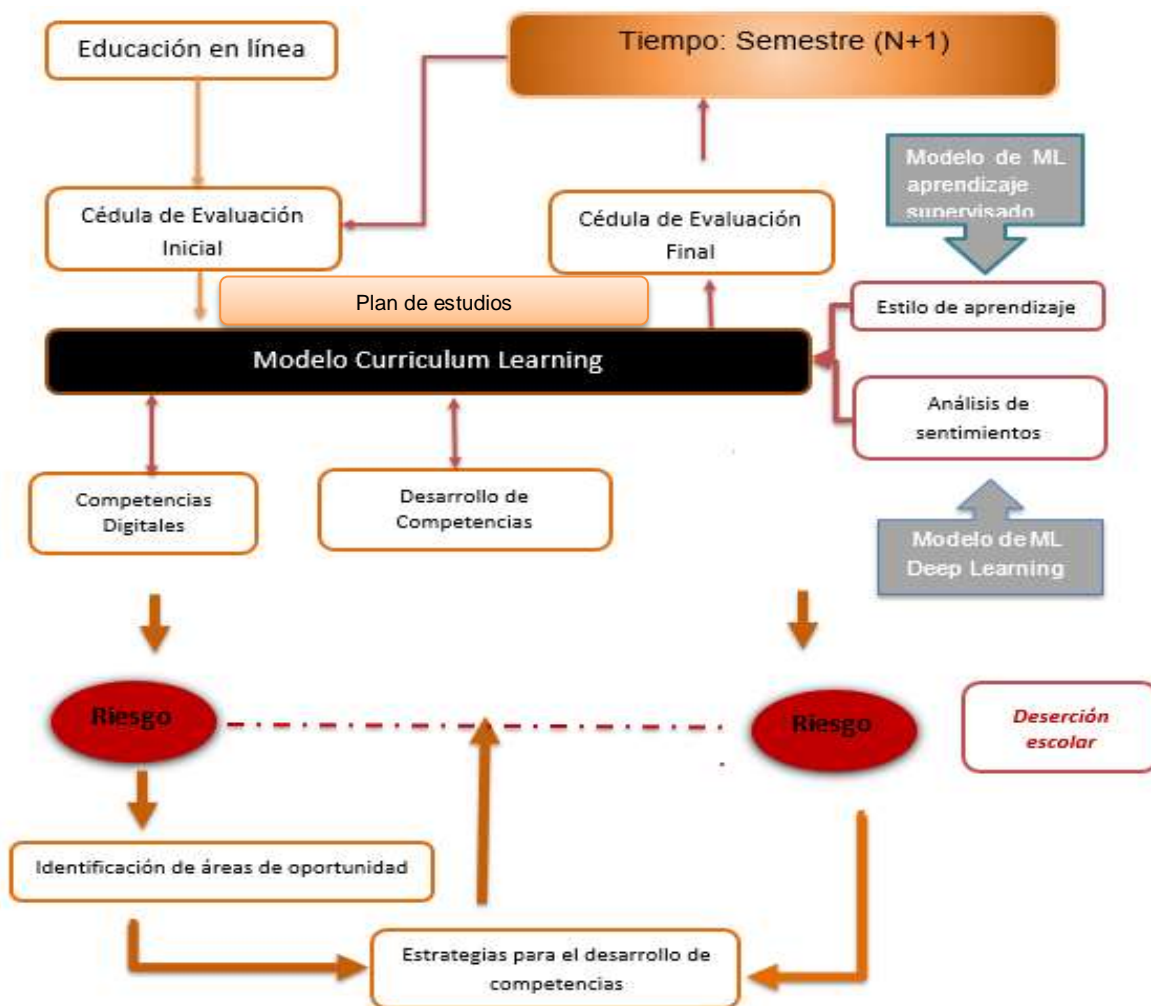
Nota: Adaptado de The CRISP-DM consortium (agosto-2020). *Step-by-step data mining guide*.

7.2. Propuesta del modelo experimental

La propuesta de diseño se basa en los saberes adquiridos mediante el estudio del marco teórico y se diseña el flujo del proceso para generar la información que alimentará al modelo basado en el Curriculum Learning (subrama de la IA) para el fortalecimiento de las competencias presentado en la Figura 7.2

Figura 7.2

*Propuesta del Modelo Experimental -Diseño de la secuencia de aprendizaje*



### 7.3. Estructura del modelo de CL basado en el plan de estudios

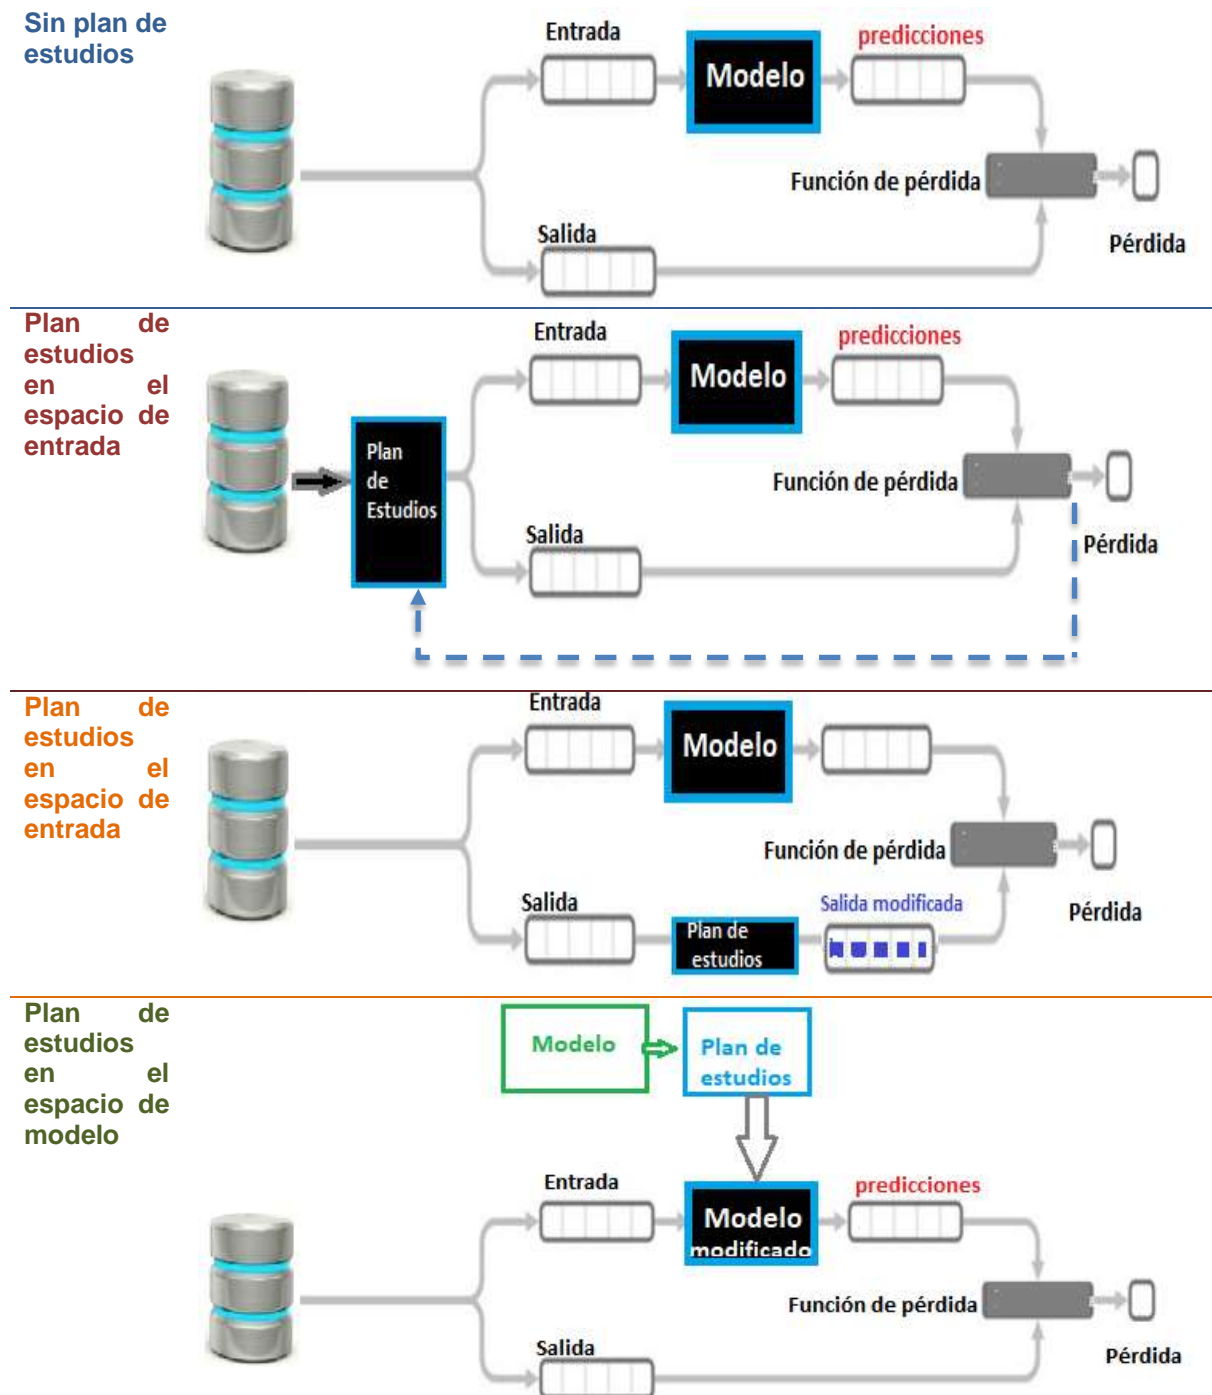
La Figura 7.3 muestra las principales características de los tipos de enfoques curriculares, en el primer caso no es considerado el plan de estudios, en los siguientes casos se considera en diferentes momentos del proceso el plan de estudios. Por ejemplo, un plan de estudios en el espacio de tareas también puede producir pequeñas modificaciones en la arquitectura del modelo (específicamente en algunos casos en la capa de salida), para poder lograr los objetivos. Del mismo modo, diferentes tipos de currículo también pueden modificar la función de pérdida o pudiera ser posible que limitaría al estudiante un plan de estudios de fácil a difícil ya que lo que es fácil para un estudiante, pudiera ser difícil para otro. En el caso que nos ocupa, partimos de un supuesto simple que nos permita ir evaluando y revisando el comportamiento de los pesos con el objetivo de fortalecer las competencias digitales.

Dado que consideramos, que el estudiante no tiene experiencia en la modalidad en línea, no cuenta con redes sociales y no tiene equipo de cómputo: estos supuestos deben producir un riesgo en nuestro modelo, para que se fortalezcan las competencias digitales.

En una óptica distinta, en la que el modelo considera el plan de estudios de fácil a difícil y se pondera primero cursar las materias de historia y al último las de matemáticas, es posible que algún estudiante tenga muchas capacidades matemáticas y le resulte complicado el aprendizaje de la historia, por lo cual el modelo complicaría su aprendizaje, porque el algoritmo no le permite avanzar hasta que no sean realizadas las actividades que para un caso particular no son fáciles, por tal motivos resulta muy importante parametrizar y definir detalladamente un plan de estudios.

**Figura 7.3**

*CL Basado en el plan de estudios*



Nota: Tomado de Stretcu, O. (2022). *Curriculum Learning*. Carnegie Mellon University. <https://doi.org/10.1184/R1/19591027.V1>

La propuesta de diseño del modelo experimental, considera la estrategia bajo el plan de estudios en el espacio de entrada conforme al diseño de propuesta del modelo experimental presentado en el apartado 7.2 de esta investigación.

### 7.4. Diseño de la Cédula Inicial de Datos

La educación mediante e-learning, representa grandes esfuerzos a nivel tecnológico, es necesario que los estudiantes cuenten con los medios tecnológicos para el aprendizaje y además los conocimientos mínimos para su incorporación al proceso. Por lo tanto, el primer paso en la propuesta del modelo será contar con la información confiable de los estudiantes

La cédula de evaluación inicial del estudiante se muestra en la Tabla 7.1 concentra información como son: datos personales, datos académicos, familiares, socio-económicos, actividades extracurriculares y su participación en las redes sociales. Por ejemplo, si el estudiante no cuenta con participación en ninguna de las redes sociales o de la modalidad presencial pasó a la formación en la modalidad en línea, se debería activar una bandera que lo identifique con riesgo para incorporarlo a los alumnos que requieren fortalecer las competencias digitales.

**Tabla 7.1**  
*Cédula de Evaluación Inicial del Estudiante.*

No.	Atributo	Tipo	Descripción	Valor
Personal	1 ID_Estudiante	entero	Número de matrícula del estudiante	1-100'000,000.
	2 Nacionalidad	binario	Tipo de nacionalidad: nacional o extranjera	Nacional Extranjera
	3 Pais_nacimiento	cadena	País de nacimiento	0-206
	4 Pais_procedencia	cadena	País de procedencia	0-206
	5 Estado	cadena	Estado de procedencia	0-4079

## Capítulo 7 Propuesta de Diseño del Modelo.

No.	Atributo	Tipo	Descripción	Valor	
6	CP.domicilio.actual	entero	Código postal del domicilio actual	5 dígitos numéricos	
7	Sexo	binario	Sexo del estudiante	1-Hombre / 2-Mujer	
8	Fecha_de_nacimiento	fecha	Fecha de nacimiento del estudiante	Dos dígitos para el día, dos para el mes, cuatro para el año dd-mm-aaaa	
9	Curp_Est	cadena	Identificador nacional	Cadena conformada con 18 caracteres alfanuméricos: 4 letras-aammdd-sexo-estado-3 letras-2 números (código verificador)	
10	Estado_civil	cadena	Estado civil del estudiante	Soltero, casado, viudo, unión libre.	
Académica anterior	11	Tipo_escuela_origen	binario	Identificador para la escuela de la que egresó.	Pública o Privada
	12	Modelo_educativo_origen	cadena	Identificador para el modelo educativo del que egreso.	Presencial, en línea, mixta o híbrida.
	13	Nivel_educativo_origen	cadena	Identificador para conocer el nivel educativo antecedente.	Preescolar, primaria, secundaria, medio superior, superior, posgrado, postdoctorado.
	14	CCT_escuela_origen	entero	Identificador de la escuela de procedencia.	Catálogo de claves de centros de trabajo
	15	Max_nivel_padre	cadena	Grado máximo de estudios del padre.	Preescolar, primaria, secundaria, medio superior, superior, posgrado, postdoctorado, sin estudios.
	16	Max_nivel_madre	cadena	Grado máximo de estudios de la madre.	Preescolar, primaria, secundaria, medio superior, superior, posgrado, postdoctorado, sin estudios.
	17	Prom.escola.ant.estud	entero	Promedio obtenido en la escuela anterior.	Valores de cero a nueve con dos decimales
Académica ingreso	18	Generac	entero	Generación a la que pertenece el alumno.	año/1 o año/2
	19	Modelo_educativo	binario	Tipo de modalidad de estudios	Presencial, en línea, mixta o híbrida.
	20	Nivel_educativo	cadena	Nivel educativo al que pertenece el estudiante.	1 al 9
	21	Beca.estudiante	binario	Tiene beca el estudiante.	si/no



## Capítulo 7 Propuesta de Diseño del Modelo.

No.	Atributo	Tipo	Descripción	Valor
22	Beca.tipo	cadena	Tipo de beca del estudiante.	Beca de gobierno/beca institucional/deportiva/cultural/emprendimiento.
23	Calif.exam.admin.estud	entero	Calificación del examen de admisión del estudiante.	0-9 con dos decimales
24	Nivel.dominio.mat	entero	Puntaje obtenido de la prueba de admisión en matemáticas.	0-9 con dos decimales
25	Nivel.dominio.español	entero	Puntaje obtenido de la prueba de admisión en español.	0-9 con dos decimales
26	Nivel.dominio.compet.digitales	entero		0-9 con dos decimales
27	Nivel.dominio.idioma	entero		0-9 con dos decimales
28	Promedio.primer.periodo	entero	Promedio del primer periodo	0-9 con dos decimales
29	Promedio.segundo.periodo	entero	Promedio del segundo periodo	0-9 con dos decimales
30	Promedio.tercer.periodo	entero	Promedio del tercer periodo	0-9 con dos decimales
31	Promedio.cuarto.periodo	entero	Promedio del cuarto periodo	0-9 con dos decimales
32	Promedio.quinto.periodo	entero	Promedio del quinto periodo	0-9 con dos decimales
33	Promedio.sexto.periodo	entero	Promedio del sexto periodo	0-9 con dos decimales
34	Promedio.septimo.periodo	entero	Promedio del séptimo periodo	0-9 con dos decimales
35	Promedio.septimo.periodo	entero	Promedio del séptimo periodo	0-9 con dos decimales
36	Promedio.octavo.periodo	entero	Promedio del octavo periodo	0-9 con dos decimales
37	Promedio.noveno.periodo	entero	Promedio del noveno periodo	0-9 con dos decimales
38	Asignatura.noaprobada	binario	Identificador de materia no aprobada.	0-5.99
39	Asignatura.noaprobada_primer.periodo	entero	Asignatura del estudiante no aprobada del primer periodo.	0-5.100
40	Asignatura.noaprobada_segundo.periodo	entero	Asignatura del estudiante no aprobada del segundo periodo.	0-5.101
41	Asignatura.noaprobada_tercer.periodo	entero	Asignatura del estudiante no aprobada del tercer periodo.	0-5.102
42	Asignatura.noaprobada_cuarto.periodo	entero	Asignatura del estudiante no aprobada cuarto periodo.	0-5.103
43	Asignatura.noaprobada_quinto.periodo	entero	Asignatura del estudiante no aprobada quinto periodo.	0-5.104
44	Asignatura.noaprobada_sexta.periodo	entero	Asignatura del estudiante no aprobada sexto periodo.	0-5.105

Historial Académico

## Capítulo 7 Propuesta de Diseño del Modelo.

	No.	Atributo	Tipo	Descripción	Valor
	45	Asignatura.noaprobada.septi.period	entero	Asignatura del estudiante no aprobada séptimo periodo.	0-5.106
	46	Asignatura.noaprobada.octavo.period	entero	Asignatura de la estudiante no aprobada octavo periodo.	0-5.107
	47	Asignatura.noaprobada.noveno.period	entero	Asignatura de la estudiante no aprobada noveno periodo.	0-5.108
Idiomas	48	Num.idiomas.estud	entero	Número de idiomas que tiene conocimiento el estudiante.	0-9
	49	Uno.idioma.estud	cadena	Idioma uno del estudiante.	catálogo de idiomas
	50	Dos.idioma.estud	cadena	Idioma dos del estudiante.	catálogo de idiomas idioma1
	51	Tres.idioma.estud	cadena	Idioma tres del estudiante.	catálogo de idiomas idioma2
	52	Nivel.uno.domi.idioma.estud	cadena	Nivel de dominio del idioma uno del estudiante.	A1, A2, B1,B2, C1,C2
	53	Nivel.dos.domi.idioma.estud	cadena	Nivel de dominio del idioma dos del estudiante.	A1, A2, B1,B2, C1,C2
	54	Nivel.tres.domi.idioma.estud	cadena	Nivel de dominio del idioma tres del estudiante.	A1, A2, B1,B2, C1,C2
Extracurriculares	55	Activid.extracurric	binario	Identificador de actividad extracurricular del estudiante.	si/no
	56	Activid.deportiva	entero	Actividad deportiva del estudiante.	si/no
	57	Activid.cultural	entero	Actividad cultural del estudiante.	si/no
	58	Activid_artist	entero	Actividad artística del estudiante.	si/no
	59	Actividad_social	entero	Actividad social del estudiante.	si/no
	60	Nivel_liderazgo	entero	Nivel de liderazgo del estudiante.	0-9
	61	Nivel_autogestivo	entero	Nivel autogestivos del estudiante.	0-9
	62	Nivel.equipo	entero	Nivel de trabajo en equipo del estudiante.	0-9
	63	Nivel.emprende.estudiante	entero	Nivel de emprendimiento del estudiante	0-9
	64	Actividades.bienestar	binario	Actividad cultural del bienestar	si/no
Redes sociales	65	Redes.facebook.estud	binario	Indicador de Redes social facebook del estudiante	si/no
	66	Redes.twitter.estud	binario	Indicador de red social twitter del estudiante	si/no

## Capítulo 7 Propuesta de Diseño del Modelo.

	No.	Atributo	Tipo	Descripción	Valor
	67	Redes.tiktok.estud	binario	Indicador de red social tiktok del estudiante	si/no
	68	Redes.instagram.estud	binario	Indicador de red social instagram del estudiante	si/no
	69	Redes.linked.estud	binario	Indicador de red social linked del estudiante	si/no
	70	Redes.pinteres.estud	binario	Indicador de red social pinterest del estudiante	si/no
	71	Redes.whatsapp.estud	binario	Indicador de red social whatsapp del estudiante	si/no
	72	Redes.telegram.estud	binario	Indicador de red social telegram del estudiante	si/no
	73	Redes.discord.estud	binario	Indicador de red social discord del estudiante	si/no
	74	Redes.youtube.estud	binario	Indicador de red social youtube del estudiante	si/no
Deserción	75	Retención	binario	Indicador si el alumno continúa estudiando	si/no
	76	Deserción.semestre	entero	Indicador de deserción dentro de qué número de semestre.	0-9
	77	Abandono.semestre	entero	Semestre de abandono del estudiante	0-9
Socio económicas	78	Zona	entero	Nivel de zona urbana del domicilio del estudiante	rural / urbana /semi urbana
	79	Nivel_socioeconm	entero	Nivel socioeconómico del estudiante	pobreza extrema /pobreza/ media/ media alta /alta
	80	Social_nivel	entero	Nivel de zonas aledañas al código postal del estudiante	pobreza extrema /pobreza/ media/ media alta /alta
	81	Tipo.vivienda	cadena	Tipo de vivienda de acuerdo a la zona y características	Casa propia / rentada / departamento propio / rentado Cuarto de estudiante.
	82	Tipo.transporte	cadena	Tipo de transporte que utiliza para ir a la escuela	automóvil, taxi, transporte escolar / metro/ metrobús/ trolebús/ microbús/ camión
	83	Num.hermanos	entero	Número de hermanos que conforman el hogar.	0-6
	84	Equipo_comp_propio	binario	Identificador del tipo de equipo de cómputo del estudiante.	si/no

De forma ilustrativa se considera el caso del ciclo escolar 2022-2023; evaluando que la institución educativa tiene 17,000 estudiantes es posible considerar a 16,000 estudiantes como datos de entrenamiento y 1,000 como datos de prueba, los cuáles servirán para conocer la precisión del modelo. En otras palabras, el modelo aprenderá con los 16,000 datos a identificar a los estudiantes en situación de riesgo durante el tiempo T, donde T es el tiempo que dure en concluir sus estudios. Lo anterior, para que se cuente con todo el historial de la cédula desde que ingresa hasta que egresa de la Institución.

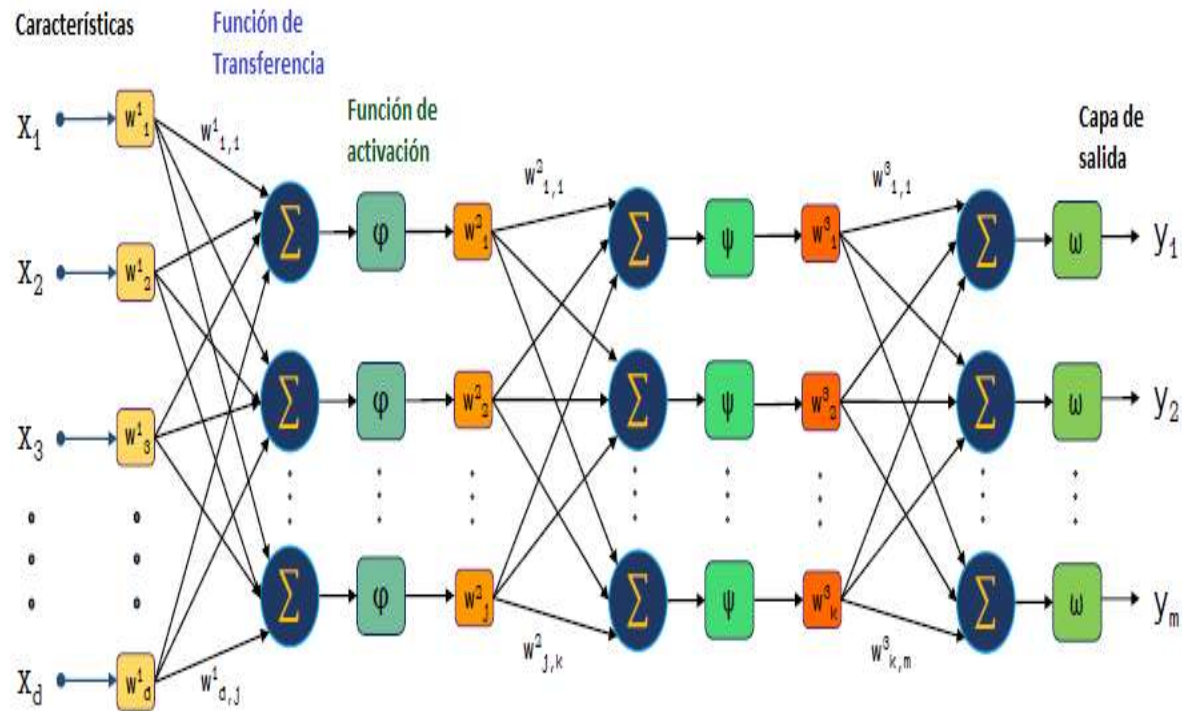
Paso siguiente, los 1,000 datos de prueba restantes permitirán validar la precisión del modelo. Es decir, selecciono del conjunto de datos denominado prueba el registro 999 y posteriormente lo ingreso al modelo. La cédula del estudiante 999 se sabe que no cuenta con competencias digitales y está marcada como probable riesgo de deserción escolar. El modelo deberá determinar el mismo resultado que tengo físicamente, en caso que ambos resultados sean iguales se obtiene un resultado correcto por parte del modelo.

### 7.5. **Asignación de valores al Modelo Curriculum Learning**

La propuesta de diseño se basa en el Curriculum learning (Elman, 1993; Bengio et al., 2009), como se ha mencionado en el capítulo 6, es una línea de trabajo del aprendizaje automático que intenta diseñar estrategias de aprendizaje inspiradas en el aprendizaje humano, en las que los conceptos se aprenden en orden de dificultad, de fácil a difícil. Esto se basa en la suposición de que, al igual que los humanos, las máquinas entrenadas de esta manera pueden aprender más rápido o funcionar mejor. El fundamento para el diseño del modelo se encuentra representado por la estructura de la red neuronal incorporando las características descritas en

la tabla de la cédula de evaluación inicial desarrolladas en esta investigación, en la Figura 7.4 se presenta la simbología de la RNA.

**Figura 7.4**  
*Representación de la RNA*




Donde cada una de las características son tomadas de la cédula de evaluación inicial, para posteriormente asignar los pesos que están representados por  $W$  y que permiten ponderar la importancia que tiene cada variable para la función de activación, es decir para considerar que un estudiante tiene riesgo y requiere el fortalecimiento de las competencias digitales. En la Tabla 7.2 se asigna un peso=1 a la variable  $X_1$ , considerando que si la modalidad\_escuela\_origen es presencial, entonces se tiene una probabilidad mayor de no contar con las competencias digitales; respecto al umbral se asigna el valor a partir del cual la función de activación se activaría, tomando como referencia que sería a partir del valor mayor a 0.9:

**Tabla 7.2**

*Asignación de pesos en la RNA*

Valores asignados para la función de activación


Características	Pesos	Umbral
$X_1$ =modalidad_escuela_origen	$W_1=1$	
$X_2$ =tipo_redes_facebook	$W_2=0.5$	Asignamos un valor > 0.9
$X_3$ =nivel_educativo_origen	$W_3=0.1$	
:	:	
:	:	
$X_{84}$ = equipo_comp_estud_propio	$W_{84}= 0.7$	

Ahora realizamos la asignación de variables y pesos, con base a lo que se desea obtener como el riesgo en el estudiante para fortalecer las competencias digitales debemos asignar un valor al umbral.

Tomando como base la representación algebraica de la RNA, las variables descritas en la cédula de evaluación inicial son las características representadas por la variable  $x$ , en el siguiente caso suponemos que nos interesan 3 variables, representadas en la Figura 7.5.


**Figura 7.5**

*Asignación de valores a la representación algebraica de la RNA.*



**Características**

**Peso**



La Tabla 7.3 presenta los valores en los que la función de activación se prende o se apaga cada una de las variables, el peso asignado se refiere, como revisamos en el capítulo anterior, a que tan importante es en la investigación esa variable para encender la función de activación, es decir podría asignar a la modalidad\_escuela\_origen un valor de 2 y a la variable  $X_2$  y  $X_3$  un valor de 0.2 y 0.4 respectivamente, lo que nos permite visualizar que en el caso de que el estudiante no tenga Facebook ni equipo de cómputo propio no será candidato para fortalecer las competencias digitales.

**Tabla 7.3**

*Pesos asignados en la Red Neuronal*

Variable	Pesos	
Modalidad escuela origen	Presencial (1)	En línea (0)
Redes_sociales_facebook	No tiene (1)	Si tiene (0)
Equipo_de_comp_propio	No tiene (1)	Si tiene (0)

En este caso se condiciona para que cuando el estudiante tenga como antecedente la educación presencial o no tenga redes sociales (Facebook) o no tenga equipo de cómputo propio se dispare la función de activación generándose un riesgo y entonces se procederá al fortalecimiento de las competencias digitales.

$$y = w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n + b = w^T \cdot x + b$$

Ahora sustituimos los pesos asignados en  $w$  y obtenemos lo siguiente:

$$y = 1 \cdot x_1 + 0.5 \cdot x_2 + 0.7 \cdot x_3 + b = w^T \cdot x + b$$



Evaluando las variables tenemos lo siguiente:

1

Cuando el alumno viene de la modalidad presencial:

$1X_1$  ;  $1 > 0.9$  (umbral) entonces sería un **riesgo**, es decir el alumno requiere del fortalecimiento de las competencias digitales.

2

Cuando el alumno no tiene redes sociales como Facebook:

$0.5X_2$  ;  $0.5 < 0.9$  entonces **no es un riesgo**, es decir el alumno no requiere del fortalecimiento de las competencias digitales.

3

Cuando el alumno no cuenta con equipo de cómputo propio

$0.7X_3$  ;  $0.7 < 0.9$  entonces no es un riesgo, es decir el alumno no requiere del fortalecimiento de las competencias digitales.

4

De otro modo, si consideramos la suma de las variables  $x_2$  y  $x_3$  obtendríamos:

$0.5X_2 + 0.7X_3 = 1.2$  entonces  $1.2 > 0.9$ , lo cual activaría el resultado como **riesgo**.

Lo anterior demuestra la importancia de validar los pesos que son asignados a cada variable.

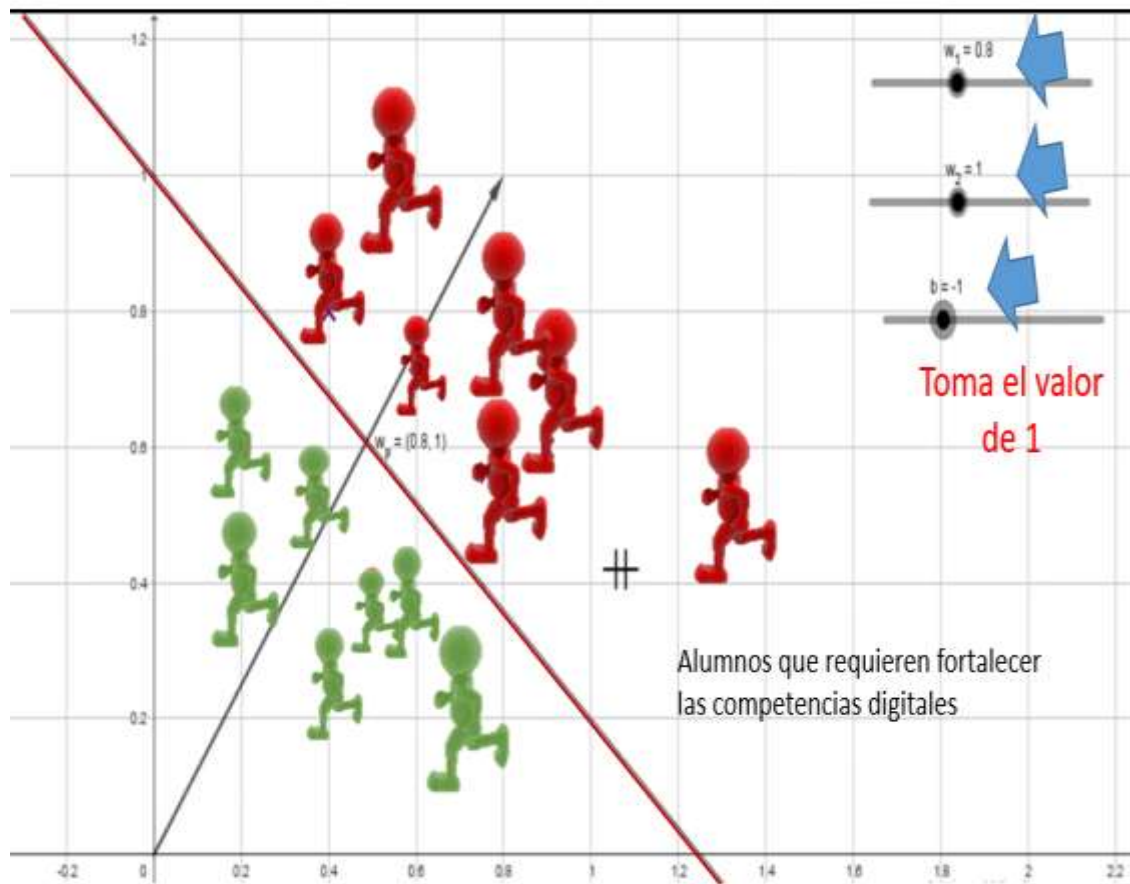
Si nuestro objetivo es conocer los alumnos que requieren desarrollo de competencias digitales, identificados como los estudiantes con riesgo en una RNA.

Tenemos  $n$  estudiantes cada uno con 84 variables. Se inicia la propuesta con el caso de dos variables para identificar la frontera de decisión, en la que con ayuda del software Matlab, se pueden identificar de lado derecho los pesos y el valor del umbral  $b=1$ , la frontera de decisión está marcada por la separación de los alumnos que requieren fortalecer las competencias y los que no requieren apoyo, según lo mostrado en la Figura 7.6.

Figura 7.6

*Función de activación*

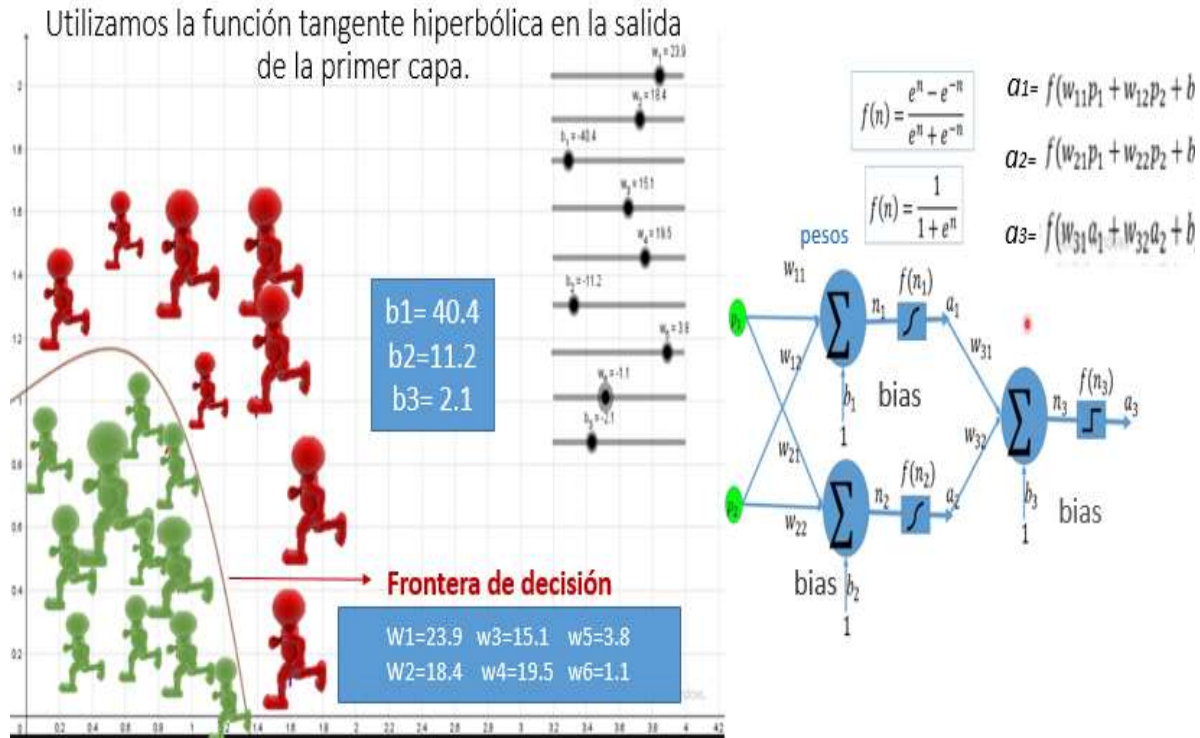
Considerando dos variables, donde  $w_1 = 0.8$ ,  $w_2 = 1$  y se encuentra  $w_p = (0.8, 1)$



En la Figura 7.7 se puede observar como la frontera que divide los dos grupos no puede ser una línea recta como en el ejemplo anterior, ya que estarían incluido otro grupo con diferentes características.

**Figura 7.7**

*Función Tangente Hiperbólica para la frontera de decisión*



### 7.6. Diseño del plan de estudios para el desarrollo de competencias digitales

Seguido de la evaluación de algunas variables mediante la asignación de los pesos, es conveniente realizar el análisis del plan de estudios, ya que en este recae la siguiente fase para la determinación de la métrica basada en lo fácil hacia lo difícil para el desarrollo de competencias digitales y dar continuidad al proceso del modelo experimental. Las fases que se consideraron en el plan curricular son: área 1: Información y alfabetización digital, área 2: Comunicación y colaboración, área 3: Crear contenidos, área 4: Seguridad, área 5: solución de problemas y área 6: Usos y aplicaciones.

**Tabla 7.4**

*Plan de Estudios para el Desarrollo de Competencias Digitales del Estudiantes*

<b>Área 1 Información y alfabetización de datos</b>		<b>Nivel de Dominio</b>					
Competencia	Navegación, búsqueda y filtrado de datos, información y contenido digital	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Identifica el uso y función de los navegadores	■	■	■	■	■	■
	Identifica el uso y función de los buscadores.	■	■	■	■	■	■
	Identifica el uso y función de las redes sociales	■	■	■	■	■	■
	Crea y actualiza estrategias de búsqueda personal bajo diferentes criterios.	■	■	■	■	■	■
Competencia	Evaluar datos, información y contenido digital	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Evalúa la importancia de los datos que comparte en las redes sociales.	■	■	■	■	■	■
	Identifica la diferencia entre datos e información.	■	■	■	■	■	■
	Identifica los derechos de autor de la información.	■	■	■	■	■	■
	Identifica la diferencia entre información pública, privada.	■	■	■	■	■	■
Competencia	Gestionar datos, información y contenido digital	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Organiza, almacena y recupera datos, información y contenidos en entornos digitales.	■	■	■	■	■	■
	Identifica el uso y ventajas de administrar datos en la nube	■	■	■	■	■	■
	Organiza y procesa en un entorno estructurado.	■	■	■	■	■	■
	Identifica diversos medios de almacenamiento en la nube.	■	■	■	■	■	■
<b>Área 2 Comunicación y colaboración</b>							
Competencia	Interactuar mediante tecnologías digitales	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Comparte datos, información y contenido digital con otros a través de tecnologías digitales apropiadas.	■	■	■	■	■	■
	Actúa como intermediario, conoce las prácticas de referencia y atribución.	■	■	■	■	■	■
Competencia	Compartir mediante tecnologías digitales	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Articula las necesidades de información, busca datos, información y contenido en entornos digitales, acceder a los datos, información y contenido y navegar entre ellos.	■	■	■	■	■	■
	Crea y actualiza estrategias de búsqueda personal	■	■	■	■	■	■
Competencia	Compromiso ciudadano con tecnologías digitales	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Participa en la sociedad a través del uso de servicios digitales públicos y privados.	■	■	■	■	■	■
	Busca oportunidades para el auto empoderamiento y la ciudadanía participativa a través de tecnologías digitales apropiadas.	■	■	■	■	■	■
Competencia	Colaborar mediante tecnologías digitales	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
	Utiliza herramientas y tecnologías digitales para procesos colaborativos, y para la co-construcción y co-creación de datos, recursos y conocimiento.	■	■	■	■	■	■

## Capítulo 7 Propuesta de Diseño del Modelo.

Competencia	Netiquette (etiqueta de la red)	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
A2C5	Conoce las normas de comportamiento y el saber-hacer en el uso de las tecnologías digitales e interactuar en entornos digitales.	■	■	■	■	■	■
	Adapta las estrategias de comunicación al público específico y ser conscientes de la diversidad cultural y generacional en entornos digitales.	■	■	■	■	■	▲
A2C6	Crea y gestiona una o varias identidades digitales, para ser capaz de proteger la propia reputación.	■	■	■	■	■	▲
	Trata los datos que se producen a través de diversas herramientas, entornos y servicios digitales.	■	■	■	■	■	▲

### Área 3 Crear contenidos digitales

Competencia	Desarrollo de contenidos	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
A3C1	Crea y edita contenidos digitales en diferentes formatos, expresarse a través de medios digitales.	■	■	■	■	■	▲
	Integrar y reelaborar contenido digital	■	■	■	■	■	▲
A3C2	Modifica, perfecciona, mejora e integra la información y los contenidos en un conjunto de conocimientos ya existente para crear contenidos y conocimientos nuevos, originales y pertinentes.	■	■	■	■	■	▲
	Copyright y licencias	■	■	■	■	■	▲
A3C3	Comprende cómo se aplican los derechos de autor y las licencias a los datos, la información digital y el contenido.	■	■	■	■	■	▲
	Programación	■	■	■	■	■	▲
A3C4	Planifica y desarrolla una secuencia de instrucciones comprensibles para que un sistema informático resuelva un problema determinado o realice una tarea específica.	■	■	■	■	■	▲

### Área 4 Seguridad

Competencia	Proteger los dispositivos	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2
A4C1	Protege los dispositivos y el contenido digital, y comprende los riesgos y amenazas en entornos digitales.	■	■	■	■	■	■
	Conoce las medidas de seguridad y protección y respeta la fiabilidad y privacidad.	■	▲	■	■	■	■
A4C2	Proteger los datos personales y la privacidad	■	■	■	■	■	■
	Protege los datos personales y la privacidad en entornos digitales.	■	■	■	■	■	■
	Entiende cómo usar y compartir información personal identificable mientras se protege así mismo y a los demás de daños y perjuicios.	■	■	■	■	■	▲

## Capítulo 7 Propuesta de Diseño del Modelo.

Entiende que los servicios digitales utilizan una "Política de Privacidad" para informar cómo se utilizan los datos personales.



Competencia	Proteger la salud y el bienestar	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Es capaz de evitar riesgos para la salud y amenazas para el bienestar físico y psicológico utilizando tecnologías digitales.



Es capaz de protegerse a sí mismo y a los demás de posibles peligros en entornos digitales (p. ej., intimidación cibernética).



Conoce las tecnologías digitales para el bienestar y la inclusión social.



Competencia	Proteger el medio ambiente	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Conoce el impacto ambiental de las tecnologías digitales y su uso.



### Área 5 Solución de problemas

Competencia	Resolver problemas técnicos	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Identifica problemas técnicos en el manejo de dispositivos y en el uso de entornos digitales, y los resuelve (desde la localización de averías hasta la resolución de problemas más complejos).



Competencia	Identificar necesidades y respuestas tecnológicas	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Evalúa las necesidades e identifica, evalúa, selecciona y utiliza herramientas digitales y las posibles respuestas tecnológicas para resolverlas.



Adapta y personaliza los entornos digitales a las necesidades personales (por ejemplo, accesibilidad).



Competencia	Uso creativo de la tecnología digital	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Utiliza herramientas y tecnologías digitales para crear conocimiento e innovar procesos y productos.



Participa individual y colectivamente en el procesamiento cognitivo para comprender y resuelve los aspectos conceptuales.



Competencia	Resolver problemas técnicos	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

Entiende dónde hay que mejorar o actualizar la propia competencia digital.



Apoya a los demás en el desarrollo de sus competencias digitales.



Busca oportunidades para el autodesarrollo y se mantiene al día con la evolución digital.



### Área 6 Usos y aplicaciones

Competencia	Campos de aplicación y aportaciones	Básico		Intermedio		Avanzado	
		A1	A2	B1	B2	C1	C2

A6C1							
------	--	--	--	--	--	--	--

## Capítulo 7 Propuesta de Diseño del Modelo.

Utiliza la competencia digital en beneficio de la humanidad, para mejora del campo profesional.							
Entiende los usos e innovaciones tecnológicas.							
<b>Competencia</b>	<b>Campos de aplicación y aportaciones</b>	<b>Básico</b>		<b>Intermedio</b>		<b>Avanzado</b>	
<b>A6C2</b>		<b>A1</b>	<b>A2</b>	<b>B1</b>	<b>B2</b>	<b>C1</b>	<b>C2</b>
Utiliza las aplicaciones para promover los valores y la equidad de género.							
<b>Competencia</b>	<b>Campos de aplicación y aportaciones</b>	<b>Básico</b>		<b>Intermedio</b>		<b>Avanzado</b>	
<b>A6C3</b>		<b>A1</b>	<b>A2</b>	<b>B1</b>	<b>B2</b>	<b>C1</b>	<b>C2</b>
Entiende que el uso y aplicaciones de tecnología deben ser inclusiva.							
Comparte y promueve aplicaciones innovadoras que aporten a los sectores más marginados.							
<b>Competencia</b>	<b>Campos de aplicación y aportaciones</b>	<b>Básico</b>		<b>Intermedio</b>		<b>Avanzado</b>	
<b>A6C4</b>		<b>A1</b>	<b>A2</b>	<b>B1</b>	<b>B2</b>	<b>C1</b>	<b>C2</b>
Entiende la responsabilidad social como individuo para contribuir en el mejoramiento del cambio climático, mediante el uso de los recursos naturales de forma responsable.							
Utiliza las aplicaciones, innovaciones o desarrollos para contribuir al mejoramiento del medio ambiente.							
Fuente: Adaptado del Marco DigiComp de la Comisión Europea (Diciembre,2020)							

### 7.6.1. Algoritmo de CL utilizado

El algoritmo de CL presentado en la Figura 7.4 considera un modelo de ML identificado con la letra “M” a través de una RNA sobre un conjunto de datos E, definido en la Cédula de Evaluación Inicial que incorpora 84 variables. Requiere además la existencia de un criterio curricular, el cual está definido en el numeral 7.6 Plan de Estudios para el Desarrollo Curricular de Competencias Digitales del Estudiante, en la que se encuentra definida la metodología de cómo aplicar el orden en el criterio curricular:

#### 7.6.1.1. Criterio Curricular (metodología)


El criterio curricular definido en el algoritmo por la letra C, presenta la metodología del plan de estudios para el desempeño de las competencias digitales conforme el diseño descrito en el

número 7.6, como se mencionó el avance progresivo será conforme la secuencia cronológica de las 6 áreas divididas de la siguiente manera:

- **Área 1 Información y alfabetización de datos**
- **Área 2 Comunicación y colaboración**
- **Área 3 Crear contenidos digitales**
- **Área 4 Seguridad**
- **Área 5 Solución de problemas**
- **Área 6 Usos y aplicaciones**

Posteriormente, resulta necesario considerar dentro del algoritmo a utilizar el enfoque de desempeño del CL a través de una reclasificación de fácil a difícil de aprendizaje. La métrica de calidad y criterio está definida en el algoritmo con la letra “I” (nivel curricular) considerando 6 niveles como se muestra en la Figura 7.8.

**Figura 7.8**  
*Nivel de desempeño*



La Figura 7.9 muestra el algoritmo de CL propuesto para el desarrollo del modelo.



**Figura 7.9**

*Algoritmo para el Curriculum Learning*

---

**Algoritmo 1 Algoritmo de aprendizaje del currículo general**

---

M: un modelo de machine learning;  
E: conjunto de datos de entrenamiento;  
P: medida de desempeño;  
I: nivel curricular;  
S: programación del currículo;

1: **for**  $t \in 1, 2, \dots, n$  **hacer**  
2:  $p \leftarrow P(M)$   
3:     **if**  $S(t, p) = \text{verdadero}$  **entonces**  
4:      $M, E, P, \leftarrow C(I, M, E, P)$   
5:     **termina if**  
6:  $E^* \leftarrow \text{seleccionar}(E)$   
7:  $M \leftarrow \text{entrena}(M, E^*, P)$   
8: **final for**

---

Fuente: Adaptado de Soviany (2022)

La forma de currículo a utilizar depende del significado obtenido y los resultados esperados. Autores como Soviany (2022) consideran que la interpretación vinculada al suavizado de la función de pérdida, desarrollada de forma manual una taxonomía de currículo, métodos de aprendizaje, considerando perspectivas ortogonales para agrupar los métodos: tipo de datos, tarea, plan de estudios, estrategia, criterio de clasificación y calendario curricular tal como se considera de forma física en el entorno educativo.

Posteriormente, resulta necesario corroborar la taxonomía construida manualmente con un árbol jerárquico de currículo construido automáticamente mediante los métodos del algoritmo. Como hemos demostrado, el uso del álgebra y métodos de investigación de operaciones así como el uso de ecuaciones diferenciales representan la base en la representación matemática para la IA.

La arquitectura de las redes neuronales artificiales está basada en el cerebro humano y consideran el proceso de aprendizaje, inspirado en la forma en que el ser humano aprende. Una diferencia esencial de cómo se entrenan normalmente las máquinas, es que los humanos aprenden los conceptos básicos (fáciles) antes y los avanzados (difíciles) posteriormente (Soviany, 2022).

En consecuencia, desarrollar e implementar un modelo de aprendizaje similar en una máquina consideraría los siguientes beneficios:

- (i) Incremento de la velocidad de convergencia del proceso de entrenamiento.
- (ii) Mejora en la precisión.

Un preliminar estudio en esta dirección ha sido realizado por Leman (1993) y los propuestos por Bengio et al. (2009) pioneros en formalizar las estrategias de entrenamiento con una secuencia de fáciles a difíciles en el contexto del aprendizaje automático, proponiendo el paradigma del CL).

En palabras de Soviany (2022) refiere otra combinación interesante bajo el enfoque CL, siendo el uso de marcos docente-alumno junto con enfoques basados en la complejidad (Hacohen y Weinshall, 2019; Huang y Du, 2019; Kim y Chai, 2018). Por ejemplo, Kim y Chai (2018) en su modelo refiere que entrena al profesor y el estudiante se conectan en rojo usando un SPL (Sistema de Programación Lingüística) enfoque basado en la pérdida del estudiante. Metodologías relacionadas con el enfoque estándar de fácil a difícil empleado en CL; empleando otras estrategias diferentes en la forma de construir el plan de estudios.

---

El modelo propuesto de curriculum learning para reducir la deserción escolar, en palabras de Mitchell (1997) precisa: “se dice que un modelo  $M$  aprende de la experiencia  $E$  con respecto a alguna clase de tareas  $T$  y mide el desempeño  $P$ , si su desempeño en las tareas en  $T$ , medido por  $P$ , mejora con la experiencia  $E$ .

En palabras de Soviany (2022), otro elemento clave de cualquier estrategia curricular es la función de programación  $S$ , que especifica cuándo actualizar el proceso de formación. El algoritmo de aprendizaje del plan de estudios se aplica sobre el ciclo de aprendizaje tradicional utilizado para entrenar modelos de aprendizaje automático. Calculamos el nivel de rendimiento actual  $P$ , que podría ser utilizado por el programador  $S$  para determinar el momento adecuado para aplicar el plan de estudios. Observamos que el planificador  $S$  también puede determinar el ritmo  $r$  necesitado únicamente en la iteración/tiempo  $t$  de entrenamiento actual.

El criterio del plan de estudios modifica alternativamente el conjunto de datos  $E$  (p. ej., clasificándolos en orden creciente de dificultad), el modelo  $M$  (p. ej., aumentando su capacidad de modelado) o la medida de desempeño  $P$  (por ejemplo: la función objetivo). Destacamos una vez más que la función de criterio  $C$  opera sobre  $M$ ,  $E$  o  $P$ , según el valor de  $I$ . Al mismo tiempo, no deberíamos eliminar la posibilidad de emplear el currículo en múltiples niveles, de forma conjunta.

Se ha concluido con la propuesta de diseño experimental del modelo de CL, incluyendo además las teorías que sustentan el modelo y otras aportaciones relacionadas al sector

educativo bajo esta premisa que fortalecen el diseño experimental. Ha quedado plasmado el aporte de la IA en el campo de la innovación y la transformación mediante modelos que aprenden de forma automática y la obtención de resultados predictivos para mejorar las competencias digitales en el aprendizaje basado en e-learning. En el siguiente capítulo se integran los saberes obtenidos en la investigación bajo los enfoques del modelo cualitativo y cuantitativo.



## Capítulo 8 **Resultados**

## Capítulo 8 Resultados de la Investigación

### 8. Resultados de la Investigación

En este capítulo se presentan los hallazgos bajo la complejidad del objeto de investigación, basados en la metodología del método de investigación mixto, estos han proporcionado información sobre el entorno del modelo de enseñanza aprendizaje e-learning y los campos de acción para el fortalecimiento de las competencias; atendiendo el objetivo planteado en la investigación al identificar los factores que impactan en el aprendizaje bajo la modalidad e-learning.

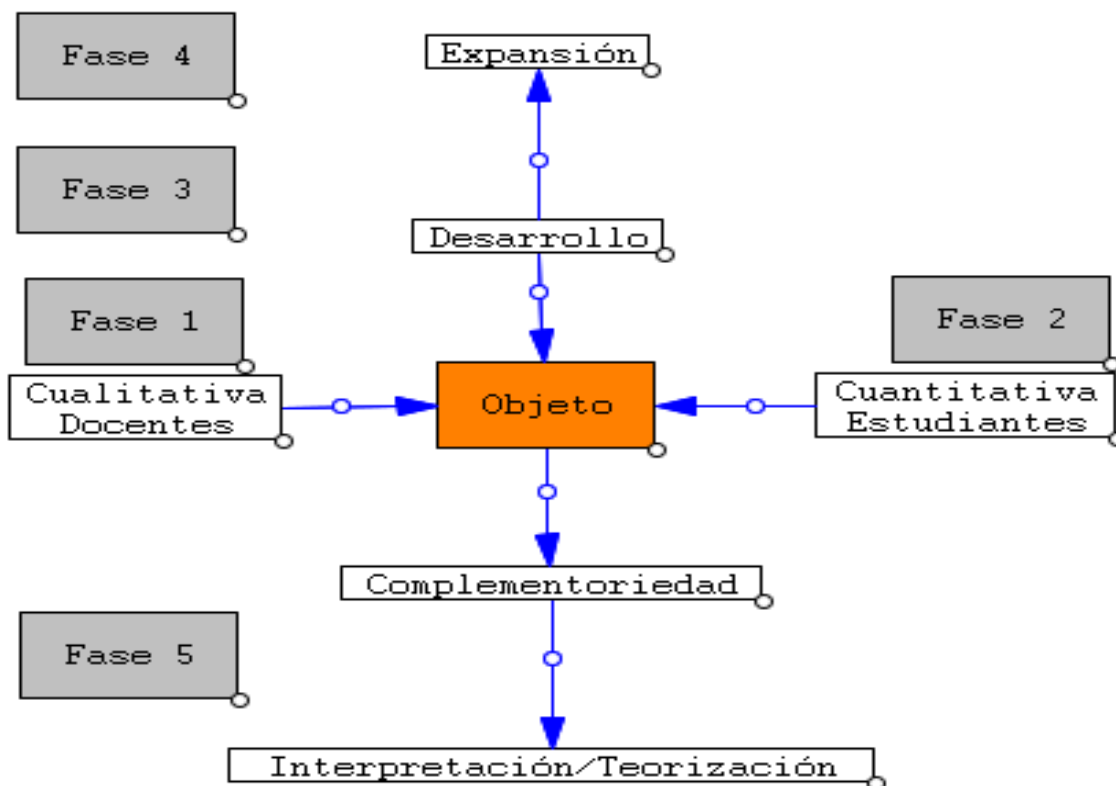
Fueron atendidas las preguntas planteadas en el capítulo de metodología de la investigación: ¿es posible identificar los factores que impactan en el aprendizaje de los estudiantes en el e-learning (modalidad en línea) de nivel superior? y ¿es posible evaluar las competencias digitales para proponer un modelo de Inteligencia Artificial para mejorar el aprendizaje?, al desarrollar una metodología robusta y secuencial.

En primer lugar, bajo el enfoque mixto de investigación se empleó la modalidad de “complementariedad” que permitió pensar los métodos más adecuados para una primera etapa exploratoria a distancia (cualitativa) y una segunda etapa presencial (cuantitativa). Ellas operaron de modo “secuencial”; primero la cualitativa para luego dar paso a la cuantitativa, operando de manera dialógica por “desarrollo” (la parte cuantitativa informó a la parte cualitativa con respecto al aprovechamiento de los estudiantes y por “complementariedad” (ambas participaron de la interpretación y teorización), en la Figura 8.1. se presenta el flujo del

proceso que permitió el desarrollo del método mixto de investigación, es de señalar que en esta se presentan los enfoques considerados y el sujeto de estudio:

**Figura 8.1**

*Proceso del método mixto de investigación*



Nota: Adaptado de Núñez Moscoso (2013, p. 143).

### 8.1. Resultados bajo el Enfoque Cualitativo

#### 8.1.1. Resultados de la Recolección de Datos.

El instrumento aplicado fue mediante la creación de una encuesta en línea con Microsoft Forms, durante el periodo de investigación. Cabe aclarar que la encuesta fue realizada de

forma voluntaria, anónima y sin fines de lucro. Se obtuvieron 258 respuestas de estudiantes en modalidad en línea. El uso de la tecnología, permitió obtener la información de forma inmediata; en un esquema de recolección presencial, la recolección de información sería más tardada.

### 8.1.2. Resultados del Análisis de Datos.

El resultado obtenido del enfoque cualitativo se centra en la observación y recogida de información, utilizando la herramienta tecnológica Tactiq.io que permite la transcripción e incorporación de información de aplicativos utilizados en videoconferencias como Zoom, Meet, Microsoft teams, drive, Dropbox, entre otros. Esta herramienta, administra los datos del nombre de la conferencia, los integrantes, la participación de cada uno, la duración total. El detalle de los resultados obtenidos se muestra en el apartado.

### 8.1.3. Resultados del Análisis de las Instituciones Educativas de Nivel Superior.

En seguida, se presentan los resultados respecto a las fortalezas y oportunidades de las instituciones educativas analizadas. Citado por García Vargas (s/f) para Porter (1998), el estudio de fortalezas y oportunidades busca evaluar aspectos fuertes tanto como débiles en las organizaciones o en empresas competidoras: cuestiones como productos, distribución, comercialización y ventas, operaciones, investigación e ingeniería, costos generales, estructura financiera, organización, habilidad directiva, etc. Es decir, situaciones que puedan generar en la organización una posición competitiva vulnerable o protegerla. Dado que no se



trata de un producto comercializable como tal; en opinión del autor la educación debe ser medida y mejorable para que los estudiantes cubran las necesidades del marco laboral<sup>21</sup>.

### 8.1.4. Modalidad Presencial: Fortalezas y Oportunidades.

El análisis realizado a la modalidad presencial bajo el enfoque cualitativo consideró los rubros presentados en la cédula de evaluación de la calidad e-learning definida en el capítulo 3 E-learning. En la Tabla 8.1 quedan expuestas las fortalezas y oportunidades identificadas en las instituciones educativas analizadas en modalidad presencial durante el ciclo escolar 2020-2021 en la pandemia y son descritas de forma general.

- Caso 1. Instituciones de Educación Superior en modalidad presencial transferida a la modalidad en línea.

**Tabla 8.1**  
*Modalidad Presencial Fortalezas y Oportunidades*

Modalidad presencial transferida a la modalidad en línea		
Institución Educativa	Fortaleza	Oportunidad
IESRC, Nivel Superior	En su mayoría los docentes mostraban tolerancia en las clases, propiciaban la participación y utilizaban diferentes estrategias durante la clase.	La IESRC no proporcionó los recursos de la modalidad en línea, solamente se utilizaba la video conferencia y en algunos casos el power point.
	Se incorporaba de forma virtual observadores por	Ausencia de competencias digitales y del contenido del mapa curricular.
		Presentan de forma extemporánea la rúbrica.

<sup>21</sup> El marco laboral está constituido por las condiciones de empleo, la situación y la trayectoria laboral, así como las competencias generales y específicas requeridas en los perfiles de ingreso y logradas en los perfiles de egreso.

Modalidad presencial transferida a la modalidad en línea		
Institución Educativa	Fortaleza	Oportunidad
	parte la institución para monitorear las clases.	Falta de dominio en los temas impartidos.
IPN, Nivel Superior	<p>El uso de simuladores y tecnología para prácticas experimentales.</p> <p>La integración de varios docentes en una sola clase.</p>	<p>Falta de organización en los horarios, clases encimadas, problemas para la inscripción que retrasa la incorporación oportuna del alumno y en ocasiones el docente no tiene flexibilidad para permitirles integrarse al curso de forma tardía.</p> <p>Exceso de contenido en las clases.</p> <p>Clases demasiado largas sin descanso o sin intervalos para descansar</p> <p>Reducción en el cupo de lugares en los grupos en cada semestre, lo cual reduce la posibilidad de inscripción y esto con lleva a considerar que los alumnos desertan fácilmente o alarguen la duración de su formación.</p> <p>Continuidad en la apertura de grupos conforme la demanda estudiantil.</p> <p>El grado de dificultad en los ejercicios no corresponde a lo enseñado por los docentes.</p>
UNAM. Nivel Superior	<p>Integración de recursos tecnológicos, plataforma, internet, tabletas.</p> <p>El contenido presentado es actual y presentan casos reales y sucesos políticos, económicos y tecnológicos actuales.</p>	<p>Falta de estrategias para dinamizar la clase.</p> <p>En algunos casos no promueven la participación.</p>
IESRC, Nivel Posgrado (Híbrida)	Se identifica que en la plataforma existe un equipo de trabajo que integra contenidos actuales, innovadores y fomentan el trabajo en equipo y la colaboración.	<p>No existe coherencia entre el contenido de la plataforma y lo que solicita el docente.</p> <p>Falta de organización y preparación de la clase.</p> <p>Improvisación de la clase, falta de recursos tecnológicos y dominio de estos.</p>

Modalidad presencial transferida a la modalidad en línea		
Institución Educativa	Fortaleza	Oportunidad
		<p>No se proporciona realimentación al alumno en tiempo y forma.</p> <p>La plataforma presenta fallas y no existe atención por la mesa de servicio o mesa de soporte técnico.</p> <p>Los docentes desconocen el material que se presenta en la clase y no existe congruencia entre lo que solicita el docente y lo que se solicita en la plataforma.</p>
UAM, Nivel Posgrado	Los docentes dominan los temas, reflejan gran experiencia y presentan material actualizado e innovador.	<p>Los trámites estudiantiles en la plataforma tienen varios problemas.</p> <p>Los comunicados para los procesos estudiantiles no son muy claros, provocando que los estudiantes no sean informados en tiempo para su reinscripción.</p> <p>Ausencia de plataforma para las clases en línea.</p>

### 8.1.5. Modalidad en línea: Fortalezas y Oportunidades.

Dando continuidad a los resultados, bajo el enfoque cualitativo y mediante la misma cédula de evaluación de la calidad de e-learning se obtuvieron los resultados para la modalidad en línea. La Tabla 8.2 expone las fortalezas y oportunidades identificadas en las instituciones educativas analizadas en modalidad en línea durante el ciclo escolar 2020-2021 en la pandemia y son descritas de forma general

- Caso 2. Instituciones de Educación Superior que con anterioridad a la pandemia proporcionaban clases en modalidad en línea.
  - IESRC, Nivel Superior.

- IPN, Nivel Superior.
- Caso 3. Empresa (Microsoft), proporcionó clases en línea a estudiantes de nivel superior en la modalidad en línea.

**Tabla 8.2**  
*Modalidad en línea Fortalezas y Oportunidades*

Institución Educativa	Modalidad en línea antes y durante la pandemia	
	Fortaleza	Oportunidad
IESRC, Nivel Superior	Se identifica el monitoreo y la mejora continua.	El contenido del material de algunas materias, tiene faltas de ortografía.
	Establecen estrategias para el seguimiento y retención de los alumnos.	Las autoridades institucionales que responden a las redes sociales, no tienen una comunicación apropiada.
	Modifican las estrategias para la evaluación de los estudiantes.	Falta de definición de procesos respecto a trámites escolares.
	Implementan nuevos modelos de recuperación en las materias.	Falta de difusión de medios de comunicación. Supervisión en el contenido de los trabajos o tareas solicitados, en algunos casos resultan en exceso. Tareas repetidas en diferentes materias. Claridad en sus procesos académicos Falta de respuesta de las solicitudes en la mesa de servicio
IPN, Nivel Superior	Gran colaboración del equipo de trabajo, en los contenidos.	Programas curriculares y trabajos académicos demasiado cargados con tareas repetitivas en diversas materias.
	Soporte técnico o mesa de servicio con métricas de calidad altas.	El nivel de lo requerido en las tareas o actividades de aprendizaje no corresponde con el nivel de lo enseñado.
	Estrategias motivacionales. En algunos casos si se entregan las actividades los días lunes, el docente realimenta al siguiente día, teniendo oportunidad de corregir los trabajos y mejorar las calificaciones, de esta forma se logra la realimentación oportuna y	Actividades integradoras demasiado extensas.

	la motivación del estudiante para cumplir de manera temprana.	
Microsoft	<p>Estructura de forma organizada el material que presenta.</p> <p>Integración y colaboración de los participantes.</p> <p>Diseño de contenidos innovadores, alegres, diferentes, agregan música antes de iniciar las clases.</p> <p>Estrategias de comunicación y participación.</p> <p>Respuestas inmediatas a las preguntas asíncronas y síncronas.</p> <p>La motivación y la empatía de los instructores hacia los estudiantes por distintos medios de comunicación, tanto en las clases como redes sociales (Instagram, Tik tok, twitter, Facebook).</p> <p>Videgrabaciones en repositorios organizadas.</p> <p>Logran mantener a grandes volúmenes de estudiantes atentos y participativos.</p> <p>Conversaciones informales durante la clase.</p> <p>Presentación de líderes y hojas de ruta en el campo de la tecnología.</p>	<p>Algunas fallas en los procesos para inscripción a certificaciones.</p> <p>La dinámica de estudio es muy rápida e impacta en la integración de estudiantes que no dominan las herramientas tecnológicas.</p> <p>Algunos conceptos son muy técnicos y no utilizan un lenguaje común.</p>

---

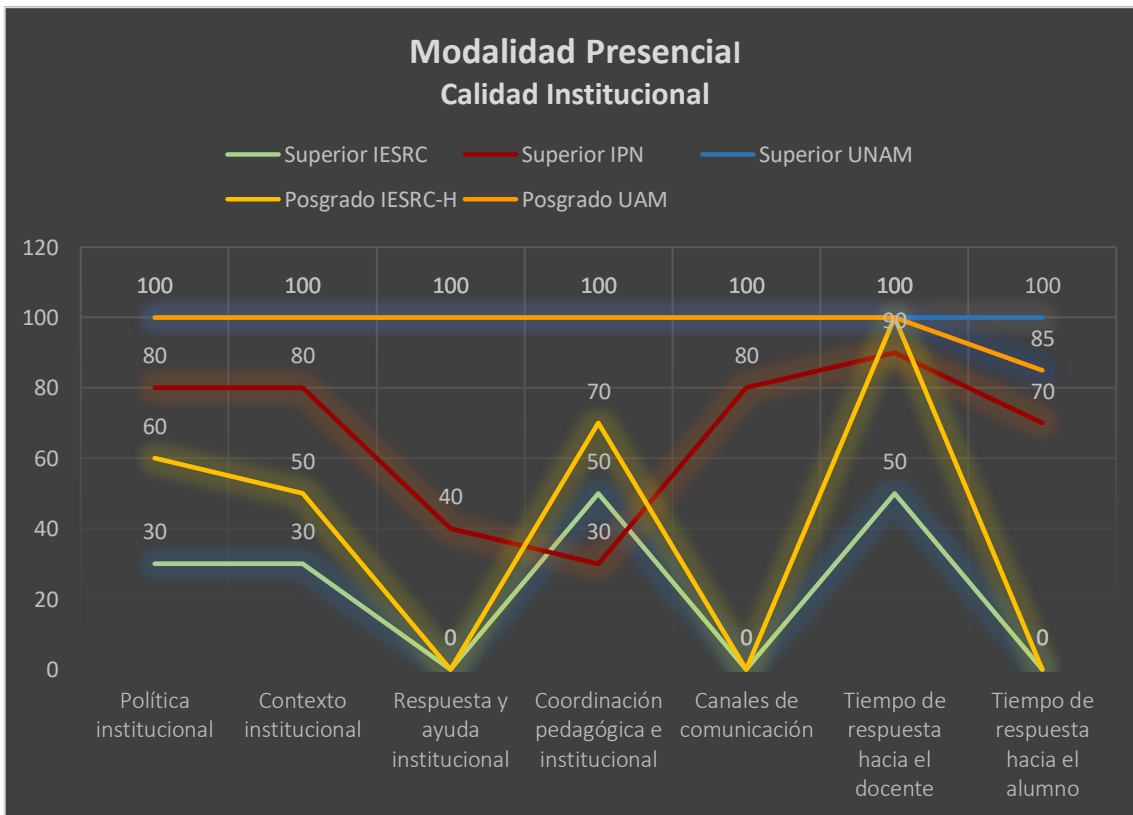
### 8.1.6. Resultados del Análisis Cualitativo

Respecto a los resultados obtenidos en el análisis calidad de la institución, calidad docente, calidad de la plataforma, calidad del alumno, calidad de la evaluación del programa y mejora continua, en la Figura 8.2. Calidad Institucional se identificó que la UNAM y la UAM obtuvieron

los mejores resultados (cercanos al 100%) en los rubros de política institucional, contexto institucional, respuesta y ayuda institucional, coordinación pedagógica institucional, canales de comunicación, tiempo de respuesta hacia el docente y tiempo de respuesta hacia el alumno, identificando además que el IESRC, en su modalidad semi presencial (híbrida) tiene mayores áreas de oportunidad en las categorías de: respuesta y ayuda institucional, canales de comunicación y tiempo de respuesta al alumno obteniendo una puntuación de cero.

**Figura 8.2**

*Caso 1. Evaluación de la Calidad Institucional*




La Figura 8.3. presenta los resultados respecto de la Calidad Docente, se utilizaron los criterios de: función docente, materiales y recursos tecnológicos, canales de comunicación, estrategias docentes, tutoría y seguimiento estudiantil y tiempo de respuesta hacia el alumno, identificando que la UNAM y la UAM tienen un resultado de 100 en canales de comunicación

y como área de oportunidad para el IESRC-H, los canales de comunicación con un 30% y la tutoría y seguimiento estudiantil con 40% y el IESR con 40%.

**Figura 8.3**

*Caso 1. Evaluación de la Calidad Docente*




En la evaluación correspondiente a la plataforma, es pertinente señalar que las instituciones que obtuvieron la evaluación de cero, se debe a que las clases evaluadas no fueron transmitidas haciendo uso de una plataforma, y únicamente utilizaron la videoconferencia para transmitir las clases. La Figura 8.4 muestra que la UNAM en su modalidad presencial transferida en línea durante la pandemia dotó a sus docentes de los recursos para hacer uso de la plataforma, obteniendo puntaje de 100%, y el IESRC-H con un resultado de 80% en

promedio, evaluando las métricas de calidad de soporte técnico de la plataforma, nivel de satisfacción del alumno con el uso de la plataforma, nivel de satisfacción del docente con el uso de la plataforma, tiempos fuera de conexión (en este rubro se otorgó calificación del 100 cuando no se hubiera presentado desconexión o problemas con el acceso), adaptabilidad, accesibilidad y funcionamiento.

**Figura 8.4.**

*Caso 1. Calidad en el Sistema de Aprendizaje o Plataforma*



Nota: En la modalidad presencial durante la pandemia, en los casos estudiados se identificó que únicamente la UNAM y el IESRC utilizaron la plataforma para impartir clases en línea.

En la modalidad presencial se evaluó la calidad del programa y contenidos, respecto a los rubros: evaluación de la pedagogía incorporada, evaluación de los recursos tecnológicos




## Capítulo 8 Resultados de la Investigación

integrados, evaluación del contenido del programa, evaluación de la calidad del programa, evaluación procesal, evaluación previa al programa. Se presenta el resultado en la Figura 8.5, identificando que tanto la UAM como la UNAM en general logran los mayores resultados (100%) y el IERSC-H presenta áreas de oportunidad en los recursos tecnológicos integrados con un puntaje obtenido de 30%.

**Figura 8.5**

*Caso 1. Calidad de la Evaluación del Programa (Contenidos)*




En la modalidad presencial se evaluó la calidad de aprovechamiento del alumno, mostrada en la Figura 8.6, considerando los rubros: participación, trabajo en equipo, motivación, calidad en los trabajos, autonomía, entrega en tiempo, mejora en el aprendizaje. En este caso se identificó que la UAM y la UNAM obtuvieron los mejores puntajes cercanos al 85% en

promedio y el IESRC-H tiene como áreas de oportunidad el trabajo en equipo y la mejora en el aprendizaje cercano al 30 y 40% respectivamente.

**Figura 8.6**


*Caso 1. Calidad del Aprovechamiento del Alumno.*



Los resultados referentes a la modalidad presencial en la mejora continua fueron evaluados los aspectos de: preparación y recursos del programa, seguimiento del programa, retroalimentación docente e institucional, mostrados en la Figura 8.7, se ven fortalecidas la UAM y la UNAM con puntuaciones de 60% y 80% respectivamente en el rubro de preparación y recursos del programa y las áreas de oportunidad identificadas son en el IESRC-H con un puntaje de 20% preparación y recursos del programa y 30% en el rubro de seguimiento del programa, retroalimentación docente e institucional.

**Figura 8.7**


*Caso 1. Calidad de la Mejora Continua*



En la evaluación de la calidad institucional en la modalidad en línea se obtuvieron resultados para los siguientes rubros: política institucional, contexto institucional, respuesta y ayuda institucional, coordinación pedagógica institucional, canales de comunicación, tiempo de respuesta hacia el docente y tiempo de respuesta hacia el alumno, mostrados en la Figura 8.8. Calidad Institucional muestran que el IPN obtiene un puntaje cercano al 100% en casi todos los rubros, identificando además que el IESRC, tiene mayores áreas de oportunidad en las categorías de: respuesta y ayuda institucional, canales de comunicación y tiempo de respuesta al alumno obteniendo una puntuación de cero.

**Figura 8.8**


*Caso 2. Calidad de la Institución.*



Los resultados obtenidos respecto de la Calidad Docente presentados en la Figura 8.9., consideran los criterios de: función docente, materiales y recursos tecnológicos, canales de comunicación, estrategias docentes, tutoría y seguimiento estudiantil y tiempo de respuesta hacia el alumno; son: Microsoft, IPN y el IESRC obtuvieron puntajes altos y el IESRC tiene como área de oportunidad el tiempo de respuesta hacia el alumno con un puntaje obtenido del 20%.


**Figura 8.9**

*Caso 2. Calidad del Docente.*




La evaluación correspondiente a la plataforma, presentada en la Figura 8.10 muestra que el IPN y MICROSOFT en su modalidad en línea obtuvieron puntajes de 100%, y el IESRC con un resultado de 0% en las métricas de calidad técnicas de soporte de la plataforma, evaluando también el nivel de satisfacción del alumno con el uso de la plataforma, nivel de satisfacción del docente con el uso de la plataforma, tiempos fuera de conexión (en este rubro se otorgó calificación del 100 cuando no se hubiera presentado desconexión o problemas con el acceso), adaptabilidad, accesibilidad y funcionamiento.

**Figura 8.10**  
*Calidad en el Sistema de Aprendizaje o Plataforma.*



En la modalidad en línea se evaluó la calidad del programa y contenidos, respecto a los rubros: evaluación de la pedagogía incorporada, evaluación de los recursos tecnológicos integrados, evaluación del contenido del programa, evaluación de la calidad del programa, evaluación procesal, evaluación previa al programa. Se presenta el resultado en la Figura 8.11, identificando que MICROSOFT obtiene los mayores resultados (100%), seguido del IPN y el IERSC presenta áreas de oportunidad en la evaluación previa del programa con un puntaje obtenido de 50%

**Figura 8.11**  
*Caso 2 y 3. Calidad del Programa (Contenidos).*



En la modalidad en línea se evaluó la calidad de aprovechamiento del alumno, mostrada en la Figura 8.12, considerando los rubros: participación, trabajo en equipo, motivación, calidad en los trabajos, autonomía, entrega en tiempo, mejora en el aprendizaje. Se obtuvo que en general todas las instituciones obtienen puntajes de 80% o más.

**Figura 8.12**  
*Caso 2 y 3. Calidad del Aprovechamiento del Estudiante*



Los resultados referentes a la modalidad en línea en la mejora continua fueron evaluados los aspectos de: preparación y recursos del programa, seguimiento del programa, retroalimentación docente e institucional, mostrados en la Figura 8.13; el IPN y Microsoft obtuvieron los puntajes cercanos al 100% y el IESRC tiene como área de oportunidad el seguimiento del programa, retroalimentación docente e institucional con 70% como resultado.



**Figura 8.13**


*Caso 2 y 3. Calidad en la Mejora Continua.*



El resumen total del puntaje obtenido por cada Institución de Educación Superior o Posgrado se muestra en la tabla 8.14, la cual refiere que el IPN modalidad en línea obtuvo 6,340 puntos; la UNAM 6,300 puntos; Microsoft 6,140 puntos, la UAM obtuvo 4,720 puntos; el IESRC de nivel superior modalidad en línea obtuvo 4,560 puntos; el IPN modalidad presencial obtuvo 3,865 puntos; el IESRC-H de Nivel Posgrado modalidad híbrida obtuvo 2,990 puntos y el IESRC modalidad presencial nivel superior obtuvo 2,880 puntos.

**Figura 8.14**

*Caso 1, 2 y 3. Evaluación final.*



Como resultado de esta etapa se evidencia la necesidad de analizar el ecosistema que involucra a la educación en línea y no centrar la obligación y la carga curricular en el docente, dado que es necesario un esfuerzo mayor en las estrategias, diseño de contenido y recursos tecnológicos.

Las oportunidades para desarrollar el conocimiento y las habilidades necesarias para aprovechar la tecnología conectada para el aprendizaje y al desarrollo de competencias digitales deben intensificarse tanto para docentes como para educandos y fortalecer en la medida de lo posible el desarrollo tecnológico institucional acorde a la demanda laboral para que los egresados logren incorporarse rápidamente a la vida productiva.

### 8.2. Resultados bajo el Enfoque Cuantitativo

El resultado de la segunda vertiente bajo el enfoque cuantitativo explora los resultados de los estudiantes de nivel superior en la educación en línea durante el ciclo escolar 2020-2021 y confirma la hipótesis respecto a identificar los factores que afectan el desempeño para proponer un modelo adaptativo de IA que fortalezca las competencias digitales.

Se efectuó la recolección, limpieza y análisis de las respuestas obtenidas, conforme al proceso descrito en el apartado 7.1. Minería de Datos. En este análisis se obtuvo la participación de 128 mujeres y 130 hombres. De estas 221 corresponden a instituciones públicas y 37 a privadas. Solamente el 8% considera que el material presentado en las clases en línea es excelente y el 19 % se mantiene participativo. Los resultados obtenidos del instrumento de medición son presentados en la Tabla 8.3. Consulta de la encuesta completa en el siguiente link: <https://bit.ly/3tPCIGs>

**Tabla 8.3**  
*Resultados del instrumento de medición*

No.	Pregunta	Respuesta
1	Género	Participaron 128 mujeres y 130 hombres
2	Selecciona el rango de tu edad:	En el rango de 17-18, 20 participantes, de 19-20, 73 participantes, de 21-22, 12 participantes, de 23-24, 11 participantes, de 25-26, 5 participantes, de más de 26, 137 participantes. (Se agrupó el de más de 26 y otro).
3	¿Durante los meses anteriores hasta octubre de 2021, tus estudios fueron a distancia?	Los participantes respondieron 239 estudiantes respondieron que sí y 19 que no fueron a distancia sus estudios en los meses anteriores.
4	¿Cuántos años pasaron de tu bachillerato para	Quienes no interrumpieron sus estudios (0) años 158 estudiantes, de 1-2 años 46 estudiantes, de 3-4 años 32 estudiantes, más de 4 años 16 estudiantes y de 6 estudiantes es la segunda carrera 6

## Capítulo 8 Resultados de la Investigación

No.	Pregunta	Respuesta
	continuar estudiando en la Universidad?	
5	Tipo de escuela en la que estudiaste el nivel bachillerato:	El nivel bachillerato lo cursaron 221 en escuela pública y 37 en escuela privada.
6	Selecciona el nivel de satisfacción con la Universidad a distancia (1 estrella poco agrado)	El promedio de satisfacción en la universidad a distancia fue de 3.8%, en una escala de 1 a 5.
7	Tipo de escuela en la que estudias la Universidad:	En el nivel universitario 239 lo cursaban en escuela pública y 19 en privada.
8	Frecuencia con las que visualizas las sesiones grabadas (en caso de que sean grabadas)	Se obtuvo que 51 estudiantes siempre visualizan las sesiones grabadas, 155 en algunas ocasiones las visualizan y 52 nunca visualizan las sesiones grabadas.
9	¿Cómo consideras el contenido de los cursos a distancia?	Respecto al contenido de los cursos a distancia 21 estudiantes respondieron que es excelente, 50 que muestra contenido innovador, 174 lo consideran aceptable y 13 aburrido.
10	Selecciona como es tu personalidad en clase:	Solamente 49 estudiantes son participativos, 105 estudiantes algunas veces participan, 68 estudiantes participan solamente cuando les preguntan, 3 estudiantes se salen de la sesión cuando les preguntan y 33 se mantienen en clase pero no participan.
11	Cuándo estoy tomando la clase, regularmente estoy	43 estudiantes tomaban clase acostados, 61 consultando su celular mientras la clase, 35 se encontraban trabajando y 71 haciendo otras actividades.
12	¿Qué es lo que más te gusta hacer en tu tiempo libre?	Las actividades que realizan son: 60 estudiantes prefieren ver series, películas, o ir al cine (se agrupó ir al cine y ver series, películas), 70 otras actividades, 35 escuchan música, 28 prefieren reunirse con sus amigos, 21 señalaron no contar con tiempo libre, 19 en leer, 19 en redes sociales y en actividades deportivas.
13	Qué recursos te gusta utilizar en las clases a distancia	Los recursos preferidos de los estudiantes son: 130 requieren que expliquen casos prácticos, 122 prefieren utilizar recursos como Kahoot, 97 que el profesor explique con ejemplos, 96 solicitan videos de solución de ecuaciones, paralelamente 96 señalaron que se proporcionen ejercicios prácticos, 83 estudiantes prefieren que el profesor explique en el pizarrón y solamente 17 estudiantes mostraron interés en que los alumnos expongan.

## Capítulo 8 Resultados de la Investigación

No.	Pregunta	Respuesta
14	Cómo consideras tu desempeño académico en la modalidad en línea (1 estrella bajo - 5 estrellas alto)	El promedio de satisfacción en la modalidad en línea fue de 3.46%, en una escala de 1 a 5.
15	¿Cuándo tomas clases a distancia lo haces mediante?	El medio por el que toman clase a distancia es: 222 con la computadora o laptop, 77 con el celular y 20 con la tableta.
16	¿Cuándo tomas clase a distancia enciendes tu cámara?	Durante la clase 68 estudiantes encienden su cámara y 190 no la encienden.
17	¿Qué medio activas para tus clases?	En la clase a distancia 218 estudiantes activan el micrófono y 40 no lo activan.
18	¿Cómo podrías mejorar tu desempeño académico?	Las frases con mayor impacto para mejorar el desempeño académico de los estudiantes fueron: Acabando la carrera participando más en clase, realizando más actividades prácticas.
19	¿Cuál es la modalidad educativa que más te gusta?	La modalidad preferida de los estudiantes fue 187 prefieren la modalidad presencial y 71 la modalidad a distancia.

Los datos obtenidos en la encuesta realizada en línea mediante Microsoft Forms, destacan que en una escala de 1 a 5, el grado de satisfacción con la modalidad en línea es de 3.8. Además se identificó que a pesar de representar ventajas en cuanto a tiempo y gastos que puedan surgir en la modalidad presencial 187 estudiantes prefieren estudiar bajo el esquema presencial. En la Tabla 8.4 se detalla el grado de aceptación de cada una de las modalidades.

**Tabla 8.4**

*Resumen del desempeño académico*

Etiquetas de fila			
<b>A distancia</b>		Estudiantes	
Bueno		32	
Malo		1	
Muy bueno		30	
Regular		8	71
<b>Presencial</b>			
Bueno		58	
Malo		27	
Muy bueno		14	
Muy Malo		16	
Regular		72	187
<b>Total general</b>		258	258

### 8.2.1. Resultados e Interpretación de los Datos.

Los datos recabados nos permitieron realizar un análisis con la Prueba de Independencia de Ji-Cuadrado para determinar la relación que existe entre las variables, es decir comprueba si es probable que dos variables estén o no relacionadas. En la tabla 8.5 se calcula la contingencia respecto al tipo de modalidad de procedencia y su desempeño. En la tabla 8.6 se realizan los cálculos que permiten obtener la frecuencia porcentual o probabilidad y en la Tabla 8.7 se obtiene la frecuencia esperada de Ji-Cuadrado.

**Tabla 8.5**

*Contingencia para el cálculo de Ji-cuadrado.*

Tabla de Contingencia Desempeño						
Modalidad	Muy Malo	Malo	Regular	Bueno	Muy bueno	Total
Presencial	16	27	72	58	14	187
A distancia	0	1	8	32	30	71
	16	28	80	90	44	258

**Tabla 8.6**

*Frecuencia porcentual o de probabilidad.*

Frecuencia porcentual o probabilidad						
Desempeño						
Modalidad	Muy Malo	Malo	Regular	Bueno	Muy bueno	Total
Presencial	1.00	0.96	0.90	0.64	0.32	0.72
A distancia	0.00	0.04	0.10	0.36	0.68	0.28
	1.00	1.00	1.00	1.00	1.00	1.00

**Tabla 8.7**

*Frecuencia esperada para el cálculo de Ji-cuadrado*

Frecuencia esperada						
Desempeño						
Modalidad	Muy Malo	Malo	Regular	Bueno	Muy bueno	Total
Presencial	11.597	20.295	57.984	65.233	31.891	187
A distancia	4.403	7.705	22.016	24.767	12.109	71
	16	28	80	90	44	258

El cálculo del estadístico Ji-cuadrado que nos permitirá conocer el valor crítico se presenta en la Tabla 8.8

**Fórmula de Ji-cuadrado**

$$\chi^2 = \sum_{(i=1)}^k (O_i + E_i)^2 / E_i = 65.8234$$

**Tabla 8.8**

*Cálculo del estadístico Ji-cuadrado*

Desempeño					
Cálculo Estadístico de Ji-Cuadrado					
Modalidad	Muy Malo	Malo	Regular	Bueno	Muy bueno
Presencial	1.6718	2.2155	3.3877	0.8019	10.0373
A distancia	4.4031	5.8352	8.9225	2.1120	26.4363

65.8234

Grados de libertad =  $(r-1) * (c-1) = 4$

Nivel de significancia  $\alpha = 0.05$

Valor crítico= 9.487729

### 8.2.2. Reporte de Resultados de la Prueba Ji-Cuadrado.

En la prueba Ji cuadrado calculada, se establecen las hipótesis de la siguiente forma:

Ho: La modalidad educativa es independiente del desempeño

H1: La modalidad educativa es dependiente del desempeño

En cuanto a la conclusión, dado que **Ji cuadrado calculado es mayor que el valor crítico entonces se rechaza Ho**. Es decir:  $65.8234 > 9.487729$

Por tanto: La modalidad educativa y el desempeño son dependientes, es decir, la modalidad educativa influye en el desempeño.

Entonces, se rechaza la hipótesis nula y se concluye que las variables están relacionadas.

La relación determinada entre las variables de desempeño académico y la modalidad de estudio antecedente considera aquellos estudiantes que habían tomado clases en línea y aquellos que venían de la modalidad presencial, siendo que el desarrollar las competencias digitales en los estudiantes puede mejorar el desempeño y en consecuencia reducir la deserción escolar mediante un modelo de machine learning.





## Conclusión y discusión

## Conclusión y discusión.

### 9. Conclusión

Las instituciones de educación superior que proporcionan servicios bajo el modelo e-learning están obligados a la formación de educando bajo la dinámica del uso acelerado de la tecnología y su constante actualización para lograr que los estudiantes cuenten con las competencias digitales que demanda el mercado laboral, aunque no debería ser exclusivo de la educación en línea, dado que cualquier modelo educativo debe adoptar el fortalecimiento de las competencias digitales.

La investigación desarrollada en este trabajo tomo como referencia el ciclo escolar 2020-2021 por la disrupción que se presentó en el sector educativo debido a la transferencia de la educación presencial a la modalidad en línea, haciendo énfasis en el análisis de 3 casos respecto a la modalidad presencial, la modalidad en línea y el caso de la empresa Microsoft en modalidad en línea para estudiantes de nivel superior y posgrado.

#### 9.1. Conclusión del Marco Contextual y el Marco Teórico

El estado del arte abordado permitió conocer los avances e identificar las aportaciones en el sector educativo. El marco teórico estuvo orientado a los temas claves de la investigación, realizando un análisis de las competencias digitales; recurso necesario para el aprendizaje en la modalidad en línea; el e-learning es la base en la que se enfocó el análisis del ecosistema de enseñanza aprendizaje; el estudio de las recomendaciones internacionales para fortalecer la educación basados en IA consideró el machine learning, Deep Learning y el Curriculum

Learning; dado el soporte teórico fue posible proponer un diseño experimental basado en IA mediante CL que fortalece las competencias digitales.

### 9.2. Conclusión de la Metodología de la Investigación

La implementación de un modelo de investigación mixto (MIM) logró la complementariedad y aportación mediante el enfoque cualitativo y el cuantitativo, surgiendo así la amplitud en la utilización de recursos para indagar sobre el estudio de caso evaluado durante la pandemia en la educación a nivel superior mediante el e-learning y la obligatoriedad de desarrollar competencias digitales.

El MIM permitió ampliar las preguntas y las teorías para dar cuenta de la realidad presentada durante el distanciamiento social, respecto de la transferencia de la educación presencial a la modalidad en línea, la transformación acelerada e incidir en los procesos de enseñanza y aprendizaje. Se consideró adecuado utilizar este modelo de investigación ya que permite abordar problemas complejos derivados del uso y adaptación de la tecnología en el proceso de enseñanza aprendizaje mediante e-learning y da sentido de orientación hacia una investigación de mayor profundidad. Se ha dado respuesta a las preguntas planteadas motivo de esta investigación; ofreciendo la oportunidad de descubrir nuevas estrategias para el desarrollo de competencias digitales mediante un modelo adaptativo de Machine Learning.

### 9.2.1. Conclusión del Enfoque Cualitativo

El enfoque cualitativo permitió indagar sobre el ecosistema del e-learning realizando las observaciones y evaluando los datos obtenidos en las instituciones educativas y no centrar únicamente en el docente la carga del aprendizaje, toda vez que resulta necesario contar con los recursos tecnológicos, como computadora, altavoz, audífonos, conexión de internet y las licencias de software correspondientes para procesadores de textos, hojas de cálculo entre otros además de las competencias digitales. Es cierto que existen recursos gratuitos, pero con la sobre demanda, se implementaron restricciones en tiempo y recursos a utilizar, lo cual también representó limitantes para los docentes y los estudiantes.

El enfoque cuantitativo dio muestra del esfuerzo que deben realizar los docentes para motivar al estudiante dado la falta de autogestión y actitud ante el aprendizaje en línea dado que durante la clase están realizando otra actividad y evidentemente su aprovechamiento será menor. El estudiante que no cuente con las competencias digitales para el aprendizaje en línea, tendrá doble carga académica desde el inicio de su formación superior, por tanto el riesgo de deserción será mayor. Asimismo, ha quedado de manifiesto la importancia que tiene el apoyo institucional, la colaboración y el trabajo en equipo para la elaboración, integración y el diseño de contenido.

### 9.2.2. Conclusión del Enfoque Cuantitativo

Respecto al enfoque cuantitativo, el instrumento de medición permitió obtener la información suficiente; mediante la aplicación del estadístico Ji-Cuadrado ya que se obtuvo información

respecto de la dependencia de la modalidad de estudio y el aprovechamiento, logrando el objetivo establecido.

Resultado de ello, es la confirmación de la hipótesis planteada siendo posible identificar los factores que impactan en el aprendizaje y la viabilidad del desarrollo de un modelo basado en IA para fortalecer las competencias digitales mediante el uso de la IA, debido a que el estadístico utilizado permitió definir la relación que existe entre las variables mediante la prueba Ji-Cuadrado, definiendo las hipótesis como sigue:

Ho: La modalidad educativa es independiente del desempeño

H1: La modalidad educativa es dependiente del desempeño

Dados los cálculos realizados en las Tablas 8.5 a 8.8 para obtener el valor crítico de Ji-Cuadrado. Se concluyó que Ji-Cuadrado calculado es mayor que el valor crítico por lo tanto, se rechaza Ho (Hipótesis nula). Es decir:  $65.8234 > 9.487729$

Por tanto: La modalidad educativa y el desempeño son dependientes, es decir, la modalidad educativa influye en el desempeño y las variables están relacionadas.

### 9.3. Aportaciones del Diseño Experimental

El ML basado en el análisis de datos y en el algoritmo para identificar la ausencia de competencias digitales, presenta un análisis predictivo de aquellos estudiantes identificados con riesgo, dado que no cuentan con las competencias digitales necesarias para el aprendizaje mediante e-learning. Tal vez si te regalan un carro y no sabes manejar, nunca lo

utilices, pero si en principio tiene un volante como simulador y una palanca al menos intentes probarlo. Mediante esta analogía se pretende describir que quienes no están inmersos en el mundo de la tecnología deben contar con los recursos para ingresar en un modelo de fácil a difícil y así lograr ser competitivos profesionalmente.

La principal aportación ha sido la propuesta del modelo curriculum learning planteada ya que el análisis de grandes volúmenes de información que generan modelos predictivos permiten la toma de decisiones oportuna y en el campo de la visualización de la información se logra identificar patrones que de otra manera sería imposible analizar.

Por otro lado, la transformación digital no debe verse como un problema técnico sino como una oportunidad para facilitar los procesos y mediante el uso de la tecnología enfocar los esfuerzos para automatizar tareas repetitivas, reducir cargas administrativas o académicas y mejorar la calidad de vida tanto de docentes como de educandos.

El trabajo analizado de los docentes bajo el enfoque cualitativo presentó información respecto a la evaluación realizada en 5 instituciones educativas de nivel superior y 1 empresa de tecnología (Microsoft) que impartió cursos a estudiantes de nivel superior durante la pandemia; considerando el ecosistema del e-learning mediante la evaluación del apoyo institucional, la calidad del docente, del programa, del contenido, de la plataforma, del aprovechamiento del estudiante y la mejora continua.

Ha quedado demostrado que identificar los factores que impactan en el e-learning permite desarrollar un modelo adaptativo de aprendizaje mediante IA que fortalece las competencias digitales. Los resultados obtenidos conducen a tomar acciones en los procesos de enseñanza aprendizaje mediante el e-learning y dar atención prioritaria al fortalecimiento de las competencias digitales tanto a docentes para la formación eficaz como a educandos para la inmersión en un mercado laboral en el que la tecnología es la principal herramienta, aún en carreras profesionales que no están relacionadas con la Tecnología, Información y Comunicación (TIC).

### 9.4. **Discusión**

El uso de la tecnología ha dado grandes aportaciones a la humanidad sin embargo su adopción no siempre se ha presentado de forma inmediata. Algunos autores como Alatríste (2021) realizaron un acercamiento del Blended Learning mediante un seminario impartido a docentes y como resultado se reconoce la necesidad de actualizar a los docentes en aspectos didácticos y tecnológicos.

La IA en el sector educativo fortalece el aprendizaje y no desplaza ni sustituye la actividad docente, por el contrario, la complementa. El ejercicio docente requiere de muchas estrategias para lograr el aprendizaje, no basta con el conocimiento del docente por los cambios que ha sufrido en el comportamiento el estudiante y en cuanto a la concentración que en muchas ocasiones no presenta el estudiante; los modelos de IA pueden incorporarse para dinamizar la educación.

El creciente uso de datos y tecnología ha logrado vislumbrar investigaciones en torno a la IA que benefician los procesos humanos. Bengio et al (2009) introdujo un conjunto de estrategias de aprendizaje de fácil a difícil para modelos automáticos.

Los modelos CL han sido implementados en los últimos años y algunos autores como Chen y Gupta (2015) presentaron múltiples trabajos: parámetros por descenso de gradiente, utilizando los valores logrando así más datos de alta frecuencia en dos tareas diferentes: localización de objetos con supervisión débil y clasificación de objetos semi supervisada, mostrando la superioridad de la estrategia de lo fácil a lo difícil.

Otros autores como Ganesh y Corso (2020) proponen un enfoque de dos etapas en el que se realiza un entrenamiento incremental en la clase. Primero, se utiliza un plan de estudios basado en etiquetas. En una segunda fase, la función de pérdida se optimiza a través de la compensación adaptativa en muestras mal clasificadas. Este enfoque no es considerado por Soviany (2020) como clasificable del todo y como aprendizaje incremental ya que todos los datos anteriores están disponibles en cada paso del entrenamiento. Sin embargo, el plan de estudios se aplica en forma de etiquetas, agregando una cierta etiqueta al entrenamiento que considera la secuencia de lo más fácil a lo más difícil.

Los modelos de IA permiten esta secuencia de lo fácil a lo difícil que puede ser adaptado a ambas líneas de enfoque de investigación, tanto a los docentes como a los estudiantes, por lo que representa las competencias digitales en el e-learning o la modalidad en línea.



El impacto generado en los docentes llevó a una transformación en su práctica pedagógica y a una actualización de los recursos digitales, en cuanto a los estudiantes, se evidencia que estos recursos presentan para ellos una ventaja en productividad y habilidades, pero desafortunadamente la dependencia a la instrucción presencial genera un obstáculo en el crecimiento de su aprendizaje y la autogestión. La educación tanto presencial como en línea deben incluir métodos pedagógicos y tecnológicos que desarrollen educandos autónomos y lograr la trazabilidad de los estudiantes mediante el curriculum learning desde la educación básica incorporando otros datos como los descritos en la cédula inicial de evaluación y no centrarnos únicamente en las calificaciones.

Las generaciones de educación básica deben ser instruidas mediante el apoyo de competencias digitales, siendo que han nacido con la tecnología, lo que considera una mejor adaptación a estos recursos. Aquellos educandos que durante la pandemia no iniciaron su vida escolar en una escuela sino mediante clases a distancia y lograron permanecer en esta modalidad, pudieran ser prueba piloto para dar continuidad a su trayectoria escolar mediante los modelos adaptativos de aprendizaje de curriculum learning y de esta forma lograr toda la hoja de ruta y su evolución para que los datos permitan la mejora continua en el proceso de aprendizaje.

El e-learning rompe las barreras geográficas y el conocimiento puede ser compartido desde cualquier país, por tanto, también podría ser una nueva línea de investigación una cédula electrónica de estudiante única que represente la hoja de ruta del estudiante y sea aceptada

## Capítulo 8 Conclusión, discusión y futuras líneas de investigación.

---

a nivel mundial con lo que lograríamos ir empatando el conocimiento y la formación académica y personal de los estudiantes.

## Bibliografía

Acevedo M., E., Serna A., A., & Serna M., E. (2017). *Desarrollo e innovación en ingeniería* [\[link\]](#)

ADefinitivas (2019, mayo 21). *Inteligencia Artificial en China*. A definitivas. Publicación editada en Palma, con número de ISSN: 2605-485X [\[link\]](#)

Aguerrevere, G. (2020). *Frente a COVID-19, desarrollar nuevas habilidades es más importante que nunca. Factor Trabajo*. [\[link\]](#)

Aguerrevere, G., Amaral, N., Bentata, C., y Rucci, G. (2020, 30 abril). *Frente a COVID-19, desarrollar nuevas habilidades es más importante que nunca*. Banco Interamericano de Desarrollo. [\[link\]](#)

Akdere, M., Acheson, K., & Jiang, Y. (2021). *An examination of the effectiveness of virtual reality technology for intercultural competence development*. International Journal of Intercultural Relations: *IJIR*, 82, 109–120. [\[link\]](#)

Alatraste, Y. y López B. R. (2021). *Acercamiento al Blended Learning como una Mirada Alternativa para Impartir Docencia en la División de Ciencias y Artes para el Diseño de la UAM-A*. *Academia Journals Tabasco 2021*. [\[link\]](#)

Alatraste, Y. (2013). *El paradigma del libro*. *Taller Servicio 24 Horas revista semestral de investigación en diseño*. [\[link\]](#)

Alonso, A., Guijarro B., Lozano, A. Taboada, M.J. (2004). *Ingeniería del Conocimiento. Aspectos Metodológicos*. Prentice-Hall.

Álvarez Cruz, L. P. (s/f). *Revista de Información, Tecnología y Sociedad*. *Revista de Información, Tecnología y Sociedad*, 54. [\[link\]](#)

- Ángel J.J. (s/f) *De Turing y la Criptografía*. Uam.mx. [\[link\]](#)
- Aqueveque, L. T. (2022). *Transhumanismo e inteligencia artificial: el problema de un límite ontológico*. Redalyc.org. [\[link\]](#)
- Area, M. (2018). De la enseñanza presencial a la docencia digital. Autobiografía de una historia de vida docente. *RED*. [\[link\]](#)
- Area, M. y Adell, J. (2009). *e-Learning: enseñar y aprender en espacios virtuales*, en J. De Pablos (coord.), *Tecnología Educativa. La formación del profesorado en la era de Internet*. Málaga: Aljibe. [\[link\]](#)
- ASALE, R.-, & RAE. (s/f.). *Arquetipo | Diccionario de la lengua española*. «Diccionario de la lengua española» - Edición del Tricentenario. [\[link\]](#)
- Asfaw, A. (2020). *Quantum Computing Education Must Reach a Diversity of Students*. IBM. [\[link\]](#)
- Avramova, V. (2015). *Curriculum Learning with Deep Convolutional Neural Networks*. Kith Royal Institute of Technology School of Computer Science and Communication. [\[link\]](#)
- Azoulay, A. (2022). *Mensaje de la Sra. Audrey Azoulay*, Directora General de la UNESCO. [\[link\]](#)
- Banco Interamericano de Desarrollo (13 de septiembre de 2021). *BID y organismos internacionales promueven la cooperación en inteligencia artificial*. Iadb.org. [\[link\]](#)
- Banco Mundial. (2017, 28 septiembre). *El Banco Mundial advierte sobre una “crisis del aprendizaje” en la educación a nivel mundial*. World Bank. [\[link\]](#)
- Barberá, E. (2008): *Aprender e-learning*. Paidós, Barcelona. BARBERA, E. y BADIA, A. (2004): *Educación con aulas virtuales: orientaciones para la innovación en el proceso de enseñanza y aprendizaje*. Visor distribuciones, S.A. [\[link\]](#)

- Barberá, E. y Badia, A. (2004): *Educación con aulas virtuales: orientaciones para la innovación en el proceso de enseñanza y aprendizaje*. Visor distribuciones, S.A.
- Barberá, E. y Badia, A. (2005). Hacia el aula virtual: actividades de enseñanza y aprendizaje en la red. *Revista Iberoamericana de Educación*, 36(9). Universidad Oberta de Catalunya. [\[link\]](#)
- Barnett, R. y Ortíz, X. (2008). *Los límites de la competencia: El conocimiento, la educación superior y la sociedad*. Investigación Bibliotecológica Archivonomía Bibliotecología e Información, 22(46), 229–235. [\[link\]](#)
- Barrón, M. C. (2 junio 2020,). *La educación en línea: transiciones y disrupciones*. Instituto de Investigaciones Sobre La Universidad y La Educación (pp. 66-74) [\[link\]](#)
- Bartolomé, A. (2004). Blended Learning. *Conceptos básicos, en Pixel-Bit, Revista de Medios y Educación*, 23, 7-20.
- Bartolomé, A. (2008): *Entornos de aprendizaje mixto en educación superior*. Revista Iberoamericana de Educación a Distancia. v. 11: 1, 2008, pp 15-51. [\[link\]](#)
- BBVA Ch (18 de agosto de 2021,) *Historia de la inteligencia artificial*. Bbva.ch. [\[link\]](#)
- Begoña G. S. (2018). Universidad de Barcelona (España) (s/f). *Vista de La evolución del e-learning: del aula virtual a la red*. Uned.es [\[link\]](#)
- Beijing, (11 de marzo de 2019). *Tribunales chinos utilizarán inteligencia artificial en juicios y ejecución de sentencias*. Spanish Xinhuanet. [\[link\]](#)
- Bensusán, G., Eichhorst, W., & Rodríguez, J. M. (2017). Las transformaciones tecnológicas y sus desafíos para el empleo, las relaciones laborales y la identificación de la demanda de cualificaciones. *Comisión Económica para América Latina y el Caribe (CEPAL)*, 191.
- Bonaccorso, G. (2018). *Machine Learning Algorithms: Popular Algorithms for Data Science and Machine Learning, 2nd Edition*. Packt Publishing Ltd.

- Bonaccorso, G. (2020). *Mastering Machine Learning Algorithms* (Second Edition). Packt Publishing.
- Bragazzi, N. L., Dai, H., Damiani, G., Behzadifar, M., Martini, M., & Wu, J. (2020). *How Big Data and artificial intelligence can help better manage the COVID-19 pandemic. International Journal of Environmental Research and Public Health*, 17(9), 3176. [\[link\]](#)
- Brunete, A., San Segundo, P. y Herrero, R. (2020). *Introducción a la Automatización Industrial*. [\[link\]](#).
- Caridad, J. & Ceular, N. (2001). *Un análisis del mercado de la vivienda a través de redes neuronales artificiales*. *Estudios de economía aplicada* (18), pp. 67-81. [\[link\]](#)
- Calvo, D. (2017). *Estructura de red neuronal artificial*. [\[link\]](#)
- Calvo, D. (2017a). *Red Neuronal Convucional* [\[link\]](#)
- Cabrero, J. y Llorente, C. (2008): *Del eLearning al Blended Learning: nuevas acciones educativas*. [\[link\]](#)
- Castañón, L. (2019). *El modelo de competencias en educación superior, análisis, funcionalidad e importancia*. *Edu.mx*. [\[link\]](#)
- Chapelle, O., Schölkopf, B., & Zien, A. (Eds.). (2006). *Semi-supervised learning*. MIT Press.
- China daily (13 de octubre de 2017) *Robot gives guidance in Beijing court* .China - *Chinadaily.com.cn*.
- Comisión Europea. Dirección General de Educación y Cultura (2003): *Better e-learning forEurope*. [\[link\]](#)
- Córdova, L. C., Solis, M. E., y Solis, L. A. (2017). *Aplicación de los sistemas e-Learning en las Universidades* [Tesis Doctoral, Universidad Estatal de Milagro]. [\[link\]](#)

- Coursera (sin fecha). *Los inicios-El pensamiento de la inteligencia artificial*. Coursera.org. [\[link\]](#)
- Creswell, J. (1997). *Qualitative inquiry and research designs: Choosing harmony among five traditions*. Thousand Oaks, CA: Sage Publications
- Creswell, JW (2007). *Investigación cualitativa y diseño de investigación: elegir entre cinco tradiciones* (2ª ed.). Publicaciones de salvia.
- De-La-Hoz, E. J., De-La-Hoz, E. J., Fontalvo, T. J., De-La-Hoz, E. J., De-La-Hoz, E. J., & Fontalvo, T. J. (2019). Methodology of Machine Learning for the classification and Prediction of users in Virtual Education Environments. *Información tecnológica*, 30(1), 247-254. [\[link\]](#)
- Dell Technologies. (2021, enero 25). *La era digital: La nueva era de las relaciones hombre-máquina*. Delltechnologies.com. [\[link\]](#)
- Delors, J. (Preside). (1996). *Los cuatro pilares de la educación (Cap. 4)*. En J. Delors (preside), *La educación encierra un tesoro* (pp. 95-109). Santillana. Ediciones UNESCO. [\[link\]](#)
- Deloya, J. (29 de septiembre de 2021,). *Las redes sociales como estrategia de aprendizaje* • Red Forbes FORBES México. [\[link\]](#)
- Dickson, B. (13 de marzo de 2017,). *How Artificial Intelligence enhances education*. The Next Web. [\[link\]](#)
- Digión, L. B., & Álvarez, M. M. (2021). *Experiencia de enseñanza-aprendizaje con aula virtual en el acompañamiento pedagógico debido al Covid-19*. *Apertura* (Guadalajara, Jal.), 13(1), 20- 35. [\[link\]](#)
- Downes, S. (2012). *E-Learning generations*. [\[link\]](#)
- Dutt, A., Ismail, M. A., & Herawan, T. (2017). *A Systematic Review on Educational Data Mining*. *IEEE Access*, 5, 15991-16005. [\[link\]](#)

Educativa, R. (12 de abril de 2021,). *COVID-19: El número de niños con dificultades para leer aumentó en cien millones debido al cierre mundial de escuelas*. Redem.Org. [\[link\]](#)

Escrig, A. (2014). *El reloj Milagroso*. Editorial Almuzara. Flores, B. (s.f). *Grandes inventores*. [\[link\]](#)

Estadística UNAM. (2018). UNAM. [\[link\]](#)

Faculty as EdTech innovators: *Moving beyond stereotypes to promote institutional change college innovation network EdTech faculty survey*. (sin fecha.). Wgulabs.Org. [\[link\]](#)

Feiner, S., Macintyre, B. y Seligmann, D. (1993). "Knowledge-based augmented reality," *Communications of the ACM*, vol. 36, no. 7, pp. 53–62, 1993. [\[link\]](#)

Fernández, B., Alonso, E., Reboloso, E., y Pozo, C. (1999). Evaluación de la calidad en la educación superior. *Papeles del psicólogo*, 74, 1886-1415. ´

Flowers, J.C. (2019). *Strong and Wak AI. Deweyan Considerations Worcester*. State University, Worcester, Massachusetts [\[link\]](#)

Fullan, M., Quinn, J., Drummy, M., Gardner, M. (2020), "*La reinención de la educación: El futuro del aprendizaje*". Un documento expositivo colaborativo entre New Pedagogies para el aprendizaje profundo y Microsoft Education. [\[link\]](#)

García Aretio, L. (2007). *De la educación a distancia a la educación virtual*. Ariel, Barcelona.

García Aretio, L. (2020). LMS. *Plataformas virtuales o entornos virtuales de aprendizaje. Ventajas y funcionalidades*. Hypotheses. [\[link\]](#)

García Ortiz, O. A. (2021). *Aplicación del sistema de Machine Learning para aumentar la eficiencia de las organizaciones*. [\[link\]](#)

García Portela, Sara (2022) *El Metaverso y su influencia en el futuro del sector turístico*. Trabajo Fin de Grado [\[link\]](#)



- García Rodríguez, L. (2017, diciembre 15). *Algunas cuestiones notables sobre el modelo de Hopfield en optimización*. Universidad Complutense de Madrid. [\[link\]](#)
- García Varga, M. de L. (s/f). *El Análisis FODA como Herramienta Estratégica para Analizar la Pertinencia de Programas Educativos*. Universidad del Estado de Hidalgo. Edu.Mx. [\[link\]](#)
- Godoy, A. F. G. (2017). Técnicas de aprendizaje de máquina utilizadas para la minería de texto. *Investigación bibliotecológica*, 31(71), 103-126. [\[link\]](#)
- González Arencibia, M. y Martínez Cardero, D. (2020). *Dilemas éticos en el escenario de la inteligencia artificial*. *Economía y sociedad*, 25(57), 1-18 [\[link\]](#)
- González, F., & Cruz, A. (2008). *Aprendizaje Transductivo para la Clasificación de Imágenes Médicas de Radiología*. [\[link\]](#)
- González, R. y Tobar, F., (2018). *¿Cuán débil ha sido la IA débil?* Libro de resúmenes JRCK 2018 - Universidad de Concepción (Concepción) Jornadas Rolando Chuaqui Kettlun de filosofía y ciencias. [\[link\]](#)
- Grinnell, R. (1997). *Social work research & evaluation: Quantitative and qualitative approaches*. E.E. Peacock Publishers, 5.ed. Illinois.
- Gros Salvat, B. (2018). La evolución del e-learning: del aula virtual a la red. *RIED-Revista Iberoamericana De Educación a Distancia*, 21(2), pp. 69–82. [\[link\]](#).
- Gurukkal, R. (2021). Techno-pedagogy needs mavericks. *Higher Education for the Future*, 8(1), 7–19. [\[link\]](#)
- Guterres, A. (2022). *La educación debe estar en el centro de la recuperación*. Noticias Organización de Las Naciones Unidas. [\[link\]](#)

- Hacohen, G. y Weinshall, D. (2019). *On The Power of Curriculum Learning in Training Deep Networks* [\[link\]](#)
- Hernández Díaz, C. A., Rincón Remolina, E. P., y Morantes Franco, C. F. (2020). *Una Mirada tras la Ventana del Constitucionalismo Democrático*. Editores Académicos - Docplayer.es. [\[link\]](#)
- Hernández-Sampieri, R. y Mendoza, C. (2018). *Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta*. ISBN: 978-1-4562-6096-5, p.609-696
- Herrera, L. y Muñoz, D. (2017). *Inteligencia Artificial y lenguaje natural. Lenguas Modernas, vol. 19*, p. 157-165. [\[link\]](#)
- Half an hour (s/f). *Elearning generations*. [\[link\]](#)
- IBE-UNESCO (s/f). *Enfoque por competencias*. Oficina Internacional de Educación. [\[link\]](#)
- IBM Cloud Education (2020). *¿Qué es la inteligencia artificial (IA)?* Ibm.com. [\[link\]](#)
- INEGI. (2021). *Encuesta para la Medición del Impacto COVID-19 en la Educación (ECOVID-ED) 2020*. ECOVID-ED 2020. [\[link\]](#)
- Insider Intelligence. (2022). *Applications of IoT technology in the education sector for smarter schooling*. Insider Intelligence. [\[link\]](#)
- Jones, B.F.; Palincsar, A.S. Ogle, D.S. y Carr, E.G. (1987) *Strategic teaching and Learning: Cognitive instruction in the content areas*. Alexandria, VA, Association for Supervision and Curriculum Development.
- Juanes, G. (2017) *Deep Learning. La Revolución Tecnológica del videoanálisis* [\[link\]](#)
- Kaluza, B. (2016). *Machine Learning with Java*. PACKT.
- Kaku, M.. (2014, p. 45). *El futuro de nuestra mente*. Debate. pp. 42-45.

- Klopfer, E. y Squire, K. (2008). *Environmental detectives-the development of an augmented reality platform for environmental simulations*. Educ Technol Res Dev, vol. 56, no. 2, pp. 203–228. [\[link\]](#)
- Kubat, M. (2017). *An Introduction to Machine Learning*. Springer International Publishing. [\[link\]](#)
- Lapan, M. *Deep Reinforcement Learning Hands-On. Apply modern RL methods to practical problems of chatbots, robotics, discrete optimization, web automation, and more*. ISBN 978-1-83882-699-4, pp. 3, 367
- Leiva, G. M. (10 de enero de 2017). *Autómatas: la ciencia se convierte en arte* -Investigart. [\[link\]](#)
- León De Herdó, R. E., y Zerpa, M. M. (2022). Socio formación y el diseño curricular en la construcción de saberes. Areté. *Revista Digital del Doctorado en Educación de la Universidad Central de Venezuela*. Vol. 8, N° 15, 85 – 105, enero – junio, 2022. ISSN: 2443 – 4566.8(15), 85–105. <https://doi.org/10.55560/arete.2022.15.8.4> [\[link\]](#)
- Leontiev, A. N. (1981). *“Actividad, conciencia, personalidad”*. La Habana: Pueblo y Educación.
- Liao, L., & Gu, F. (2022). 5G and artificial intelligence interactive technology applied in preschool education courses. *Wireless Communications and Mobile Computing*. 1–11. [\[link\]](#)
- Llamas, J. (2022). *Metaverso*. Economipedia. [\[link\]](#)
- IoT (2020). *Internet de las cosas en la educación: Aplicaciones y ventajas* [\[link\]](#)
- Mahesh, Huddar. (2022). *Backpropagation Solved Example Train Neural network predict output Updates Weights*. [\[video\]](#)

Marco europeo de competencias digitales DIGCOMP | EPALE. (16 de diciembre de 2020).

Comisión Europea. [\[link\]](#)

Márquez, I.V. (2011). Metaversos y educación: Second Life como plataforma educativa.

*Revista ICONO14. Revista científica de Comunicación y Tecnologías emergentes*, 9(2), 151. [\[link\]](#)

Matich, D. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Documento de trabajo. Universidad Tecnológica Nacional. [\[link\]](#)

Mathlab (s/f) *Which Machine Learning Algorithm Is Right for You?* (2022).

<https://explore.mathworks.com/choosing-machine-learning-algorithms>.

McCall B (2020). COVID-19 and artificial intelligence: Protecting health-care workers and curbing the spread. *Lancet Digit. Health*. 2020; 2:e166–e167. [\[link\]](#).

McClelland, D. C. (1973). *Testing for competence rather than for "intelligence"*. *American Psychologist*, 28(1), 1–14. [\[link\]](#)

Mena Araya, Aarón Elí. (2022). *Evaluación integrada de pensamiento crítico y conciencia ciudadana como competencias ATC21s en Costa Rica y en Japón*. *Revista Actualidades Investigativas en Educación*, 22(1), 1-39. Doi. [\[link\]](#)

Meng Yu y Guodong Du (19 de enero de 2019). *Why are Chinese courts turning to AI (2019)?*

TheDiplomat.Com. [\[link\]](#)

Mesa, L. F., & Yate E, C. A. (2022). *Chatbot en la enseñanza de infecciones de transmisión sexual | Tecnología Investigación y Academia*. 8(2), 15-28.

Meseguer, P. y López De Mántaras, R. (2017). *Inteligencia Artificial*. Madrid: Csic.

Metrotribune (3 de abril de 2022). *Smart courts in China provide efficient, convenient judicial services online*. Metrotribune [\[link\]](#)

- Mitchell, T. (1997). *Machine Learning* [C]. [\[link\]](#)
- Mohammadi, M., Dawodi, M., Tomohisa, W., & Ahmadi, N. (2019). Comparative study of supervised learning algorithms for student performance prediction. *International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*, 124-127. [\[link\]](#)
- Moñux, D. (2001). *Historia de la Automática*. [\[link\]](#)
- Mukminin, A. (2012). *Experiencias de aculturación entre estudiantes de posgrado indonesios en la educación superior de los EE. UU: choque académico, ajuste, crisis y resolución*. *Excelencia en la Revista de Educación Superior*, 3(1), 14-36
- Mukminin, A. (2012). *Experiencias de aculturación entre estudiantes de posgrado indonesios en la educación superior de los EE. UU.: choque académico, ajuste, crisis y resolución*. *Excelencia en la Revista de Educación Superior*, 3(1), 14-36
- N+1 (8 de julio de 2018). *China: Una IA vence a 15 médicos en el diagnóstico de tumores cerebrales*. (s/f). Nmas1.org. [\[link\]](#)
- Newar, B. (28 de febrero de 2022). Corea del Sur invertirá USD 187 millones en un proyecto de Metaverso nacional. Cointelegraph.com, [\[link\]](#)
- NMC - New Media Consortium (2017). *NMC Horizon Report: Higher Education Edition*. [\[link\]](#)  
<http://cdn.nmc.org/media/2017-nmc-horizon-report-he-EN.pdf>
- ONU (27 enero de 2022,). *La educación debe estar en el centro de la recuperación*. Noticias ONU. [\[link\]](#)
- ONU, UNESCO. (2017). *Hay Que Educar en Competencias*. Competencias personales y profesionales para el Siglo XXI. [\[link\]](#)
- Oppy, G., & Dowe, D. (2020). *The Turing Test*. En E. N. Zalta (Ed.), *The Stanford Encyclopedia of Philosophy*. Metaphysics Research Lab, Stanford University.

- Orellana, M., & Cedillo, P. (2020). Detección de valores atípicos con técnicas de minería de datos y métodos estadísticos. *Enfoque UTE*, 11(1), 56-67.
- Ortiz-López, A., Olmos-Migueláñez, S., y Sánchez-Prieto, J. C. (2021). *Calidad en e-Learning: Identificación de sus dimensiones, propuesta y validación de un modelo para su evaluación en Educación Superior*. RIED. Revista Iberoamericana de Educación a Distancia, 24(2), pp. 225-244. [\[link\]](#)
- Palma, J.T. y Marín, R. (2008). *Inteligencia Artificial. Técnicas, métodos y aplicaciones*. McGrawHill (pp.3-7).
- Pinkasz, D., & Romero, N. (2011). *Continuidades y rupturas en la escuela y el currículum de la modernidad*. En Pensar la educación. Homo Sapiens, FLACSO.
- Polo, J. D. (2013, 19 julio). *Nuevo juego de Realidad Aumentada para niños: dibujos de colores que cobran vida*. WWWhat's new. [\[link\]](#)
- Prendes Espinosa, C. (2014). *Realidad aumentada y educación: análisis de experiencias prácticas*, *Píxel-Bit Rev Medios y Educ*, vol. 46, no. 46, pp. 187–203, 2014. [\[link\]](#)
- Pringle, J. K., Stimpson, I. G., Jeffery, A. J., Wisniewski, K. D., Grossey, T., Hobson, L., Heaton, V., Zholobenko, V., & Rogers, S. L. (2022). *Extended reality (XR) virtual practical and educational eGaming to provide effective immersive environments for learning and teaching in forensic science*. *Science & Justice: Journal of the Forensic Science Society*. [\[link\]](#)
- Porter, M. (1998). *Técnicas para el análisis de los sectores industriales y de la competencia*, México: CECSA.
- Ramón, S. (1905). *Manual de histología normal y de técnica micrográfica para uso de estudiantes*. Moya [\[link\]](#)

- Ramírez-Díaz, J. L. (2020). *El enfoque por competencias y su relevancia en la actualidad: Consideraciones desde la orientación ocupacional en contextos educativos*. Revista Electrónica Educare, 24(2), 1–15. [\[link\]](#)
- REDEM (2021, 10 abril). *COVID-19: El número de niños con dificultades para leer aumentó en cien millones debido al cierre mundial de escuelas*. RED EDUCATIVA MUNDIAL. [\[link\]](#)
- Rivero, N. (2000). *Enfoques epistemológicos y estilos de pensamiento*. [Tesis Doctoral, Universidad Nacional Experimental Simón Rodríguez].
- Romer, P. (26 de septiembre de 2017,). El Banco Mundial advierte sobre una “crisis del aprendizaje”. *Banco Mundial*. [\[link\]](#)
- Romero, C. (2020). Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. [\[link\]](#)
- Romero, V. (2021). La red neuronal de base radial (RBF). [\[link\]](#)
- Rose, N. (7 de septiembre de 2016,). *Students to play virtual reality game to learn about criminal law*. Legal Futures. [\[link\]](#)
- Rosenblueth, A. (2018). *El mexicano que ayudó a dar forma a la cibernética*. Americaeconomia.com. [\[link\]](#)
- Russell, R. (2018). *Machine Learning Guía paso a paso para implementar algoritmos con Python*.
- Russell, S. J., Norvig, P., & Rodríguez, J. M. C. (2004). *Inteligencia artificial*. Pearson Educación.
- Saavedra, E. (2019). *Inteligencia artificial en educación*. Vermislab.com. [\[link\]](#)

- Salazar, J., & Silvestre, S. (2017). Internet de las Cosas. *TechPedia European Virtual Learning Platform for Electrical and Information Engineering*.
- Sales, D., Cuevas-Cerveró, A., & Gómez-Hernández, J.-A. (2020). Perspectives on the information and digital competence of Social Sciences students and faculty before and during lockdown due to Covid-19. *El Profesional de La Información*. [\[link\]](#)
- Sathe, A. 2020. *Programmable Neural Networks in Minecrat*. [\[video\]](#).
- Silas Casillas, J. C., y Vázquez Rodríguez, S. (2020). El docente universitario frente a las tensiones que le plantea la pandemia. *Revista Latinoamericana De Estudios Educativos*, 50(ESPECIAL), 89-120. [\[link\]](#) [\[link revista\]](#)
- Sotolongo, G. & Guzmán, M. (2001). Aplicaciones de las redes neuronales. El caso de la Bibliometría. *Ciencias de la Información* 32 (1), pp. 27-34.
- Soviany, P., Ionescu, R. T., Rota, P., & Sebe, N. (2022). Curriculum Learning: A Survey. *International Journal of Computer Vision* [\[link\]](#)
- Statista (2022, mayo). *Estadísticos Redes Sociales*. Statista.com. [\[link\]](#)
- Stretcu, O. (2022). *Curriculum Learning*. Carnegie Mellon University. [\[link\]](#)
- Sun, Y. (2018). *A AI could alleviate China's doctor shortage*. The MIT Technology. [\[link\]](#)
- Tam, V., Lam, E. Y., Fung, S. T., Fok, W. W. T., & Yuen, A. H. K. (2015). Enhancing educational data mining techniques on online educational resources with a semi-supervised learning approach. *2015 IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALE)*, 203-206. [\[link\]](#)
- Teigens, V., Skalfist, P., Mikelsten D., (2022). *Inteligencia artificial: la cuarta revolución industrial*.



Torra, V. (2011, p. 1-6). *La inteligencia artificial*. Lychnos. Cuadernos de la Fundación General CSIC, n. 07.

Torres, D. (2020) *Python Deep Learning. Introducción práctica con Keras y Tensor Flow*. Alfaomega.

UNAM (2020). *60 años de Inteligencia Artificial*. Coursera. [\[link\]](#)

UNAM. (2019). *Portal de Estadísticas Universitarias*. Numeralia. [\[link\]](#)

UNESCO. (2021a). *Declaración Global de Conectividad - Dirigir la Transformación Digital*. Unesco.org. [\[link\]](#)

UNESCO. (2021b). *Inteligencia Artificial en la educación*. Unesco.org. [\[link\]](#)

UNESCO. (2022). *Artificial intelligence in education*. [\[link\]](#)

UNESCO. (2022,). *Interrupción y respuesta educativa*. Seguimiento global del cierre de escuelas. [\[link\]](#)

UNIR. (17 de diciembre de 2020,). *La metodología TPACK: en qué consiste este modelo y cuáles son sus ventajas*. UNIR. [\[link\]](#)

Universal. (7 de agosto de 2020). *¿Qué es TikTok y por qué corre el riesgo de ser prohibida?* El Universal. [\[link\]](#).

Universidad Europea. (18 de marzo de 2022,). *¿Qué es el metaverso en Educación?* Universidad Europea Online. [\[link\]](#)

University of San Diego (2020). *43 Examples of Artificial Intelligence in Education* – [\[link\]](#)

University of San Diego Online Degrees, (7 de diciembre de 2021). *43 examples of artificial intelligence in education*. [\[link\]](#)

- Unión Europea, (22 de mayo de 2018). *Diario Oficial de la Unión Europea* 4.6.2018 C189/6, p. 4)
- Unsupervised Learning. (2017). En M. Kubat, *An Introduction to Machine Learning* (pp. 273-295). Springer International Publishing. [\[link\]](#)
- Valdemar, E., Avalos, O., Primitivo, E., Valdivia, A., & Pérez, M. A. (2021). *Introducción al machine learning con MATLAB*. [\[link\]](#)
- Vásquez Carbonell, M. A., & Silva-Ortega, J. I. (2020). Tendencias y características de la realidad virtual. *Computer and Electronic Sciences: Theory and Applications*, 1(1), 36–70. [\[link\]](#)
- Vázquez, C. (22 de diciembre de 2021,). *Las Ramas De La Inteligencia Artificial: Tipos De Inteligencia Artificial Suave*. Avansis. [\[link\]](#)
- Vilchis, N. (2022). *Docentes piden tiempo y capacitación para aplicar EdTech* — Observatorio. Observatorio Instituto para el Futuro de la Educación. [\[link\]](#)
- Weber, R. H. (2010). Internet of Things – New security and privacy challenges. *Computer Law & Security Review*, 26(1), 23–30. [\[link\]](#)
- Wen, X. (2017). *Robot gives guidance in Beijing court - China*. Chinadayli.com.cn. [\[link\]](#)
- Weng, L. (29 de enero de 2020) Curriculum for Reinforcement Learning. [\[link\]](#)
- Yang, D, Zhou, J., Chen, R., Song, Y., Zhenju, S., Zhang, X. Wang, Q., Wang, K, Zhou, Ch., Sun, J., Zhang, L., Bai, L., Wang, Y., L., Wang, X., Lu, Y., Xin, H., Powell, Ch.A., Thüemmler, C., Chavannes, N.H., Chen, W., Wu, L., Bai, Ch. (2022). *Expert consensus on the metaverse in medicine*. (Clinical eHealth), KeAi, Global Impact [\[link\]](#)
- Yang, Z., Zeng, Z., Wang, K., Wong, S.-S., Liang, W., Zanin, M., Liu, P., Cao, X., Gao, Z., Mai, Z., Liang, J., Liu, X., Li, S., Li, Y., Ye, F., Guan, W., Yang, Y., Li, F., Luo, S., He, J.

(2020). Modified SEIR and AI prediction of the epidemics trend of COVID-19 in China under public health interventions. *Journal of Thoracic Disease*, 12(3), 165–174. [\[link\]](#)

Yau, E. (2018, octubre 19). *Virtual reality helps Chinese medicine students learn acupuncture and doctors treat cancer*. South China Morning Post. [\[link\]](#)

Yulianti, K., & Mukminin, A. (2021). Teaching and learning during COVID-19 pandemic: A qualitative study on elementary school teachers in Indonesia. *The Qualitative Report*, 26(12), 3900-3910. [\[link\]](#)

Yulianti, K., & Mukminin, A. (2021). Teaching and learning during COVID-19 pandemic: A qualitative study on elementary school teachers in Indonesia. *The Qualitative Report*, 26(12), 3900-3910. [\[link\]](#)

Zippo, M. (2022, junio 25). *Investigadores de IA abierta enseñaron a una red neuronal a jugar Minecraft* [\[link\]](#)



## *María Elena Chávez Solís*

---

### **Curriculum Vitae**

Estudió la Maestría en Ingeniería en Sistemas en la Universidad del Valle de México, la Licenciatura en Matemáticas Aplicadas y Computación en la Universidad Nacional Autónoma de México, FES Acatlán. Ha cursado los Diplomados en Sistemas Dinámicos para la Sustentabilidad 2022 (Escuela ERASME, Francia), Comercio Electrónico (UNAM), Administración de Proyectos (UNAM), Automatización de Impuestos (ITAM), Regulación (Secretaría de Economía), Regulación Económica (Secretaría de Economía), Finanzas (SHCP) y Abogado en Comercio Exterior (Servicio de Administración Tributaria). Cuenta con la certificación en la NOM-ISO 27001, Seguridad de la Información. Es miembro de la Association of Certified Fraud Examiners.

Participó como ponente en la Organización Mundial de Aduanas (OMA) en Bruselas en 2021 con la ponencia Fraud in the Pandemic, PICARD 2021; obtuvo reconocimiento durante 2015 por la misma organización en el 66 Fellowship en Bruselas con el trabajo: “Estudio de Tiempos de Despacho en la Aduana de México”, ganó el Premio Nacional de Administración Pública 2014, con la investigación México: una Aduana de Clase Mundial (2014).

A nivel académico ha sido Presidente de Jurado para obtener el grado de Maestro en Comercio Exterior y ha sido Coordinador de la Academia de Informática. Catedrático a nivel Posgrado y Licenciatura en durante casi 10 años.

Cuenta con más de 10 años de experiencia en el sector gubernamental administrando proyectos a nivel federal en materia aduanera, de comercio exterior y de seguridad nacional, gestionando grandes grupos de trabajo externos e internos para la implementación de soluciones tecnológicas.

Se ha capacitado en cursos de inteligencia artificial: Matemáticas para Machine Learning, Deep Learning y Deep Reinforcement Learning con Registro STPS: ZAGE-810930-FW2-0005, entre otros.