



**Universidad  
Nacional de  
La Plata**

**Minería de Textos para la extracción de conocimiento en  
actividades educativas con información proveniente  
de redes sociales. Una estrategia didáctica.**

**Tesista:** MSc. Ana Lucía Pérez Suasnavas

**Directora:** PhD. Karina Cela

**Codirector:** PhD. Waldo Hasperué

Tesis presentada para obtener el grado de:

**Doctor en Ciencias Informáticas**

**Facultad de Informática**

abril de 2024

## Resumen

La presente investigación se desarrolló en el campo de las tecnologías aplicadas a la educación, de forma particular, mediante el uso de técnicas de Minería de Datos y la integración de redes sociales. La Minería de Datos es un campo interdisciplinario, que integra diferentes áreas como la estadística y las ciencias de la computación; con el propósito de descubrir patrones de forma automática en grandes volúmenes de datos, para la posterior toma de decisiones. Por su característica, la Minería de Datos puede ser aplicada en diversas áreas como: las Finanzas, Ventas, Medicina, Educación, entre otras; donde se dispone de un variado conjunto de técnicas o métodos de Minería de Datos que son aplicadas con diferentes propósitos y objetivos, como los modelos predictivos y modelos descriptivos, con tareas de clasificación y regresión, así como de asociación y agrupamiento respectivamente.

En el área de la educación, se ha evidenciado el uso de distintas técnicas de Minería de Datos, con diferentes objetivos, entre los que se puede mencionar: detección de los estudiantes en riesgo de reprobación o deserción, análisis de los sentimientos y emociones de los estudiantes, predicción del rendimiento académico, mejora de la comunicación de docentes-estudiantes, entre otros; mediante la extracción de datos provenientes de las redes sociales. Sin embargo, pocos estudios refieren al uso de prácticas pedagógicas que integren el uso de técnicas de Minería de Datos y la red social Twitter, que permita predecir las dificultades expresadas por los estudiantes con datos provenientes de esta red, y que permita mejorar los procesos de enseñanza y aprendizaje de los estudiantes universitarios.

El objetivo de la presente tesis doctoral, consiste en proponer una estrategia didáctica que integre técnicas de Minería de Datos para predecir las dificultades que experimentan los estudiantes universitarios en una sesión de clase, mediante la extracción de datos provenientes de la red social Twitter; con el propósito de que, el docente cuente con una herramienta que le permita brindar ayuda oportuna a los estudiantes, en los temas que demandan mayor atención en la enseñanza de la asignatura de Programación 1, en la Universidad Central del Ecuador, ubicada en la ciudad de Quito.

La estrategia didáctica propuesta, denominada Justo a Tiempo para Enseñar con Twitter «Just in Time to Teach with Twitter» (JiTTwT), contempla 4 fases; cada una está compuesta por diferentes actividades y tareas, que integran tanto orientaciones pedagógicas como tecnológicas. Con estas dos orientaciones, se desarrolló una herramienta en el lenguaje de programación Python, denominada «API Issues», que cumple 4 funcionalidades: 1) extracción de los datos provenientes de Twitter; 2) preprocesamiento de los datos; 3) construcción y evaluación del modelo; y 4) predicción del tipo de dificultad.

Con la API Issues se logró automatizar las diferentes fases de la Estrategia Didáctica JiTTwT, de manera que, el docente cuente con una herramienta de apoyo en su labor docente, anticipando las dificultades que los estudiantes pueden experimentar durante las clases presenciales, mediante la visualización de un mapa de los temas más relevantes.

Para alcanzar los objetivos propuestos, se realizó una revisión sistemática de la literatura, que permitió identificar los vacíos de las investigaciones previas, de manera que, la Estrategia Didáctica JiTTwT cuente con características de innovación en el campo de la educación superior, mediante el uso de técnicas de Minería de Datos y la red social Twitter. La estrategia didáctica fue aplicada en dos instancias, de manera que permita validar su desarrollo.

Los índices de reprobación de la asignatura de Programación 1 son elevados; por lo que, se espera que la Estrategia Didáctica JiTTwT permita al docente tomar acciones anticipadas, para minimizar los problemas identificados en los estudiantes. Así, esta estrategia se constituye en un aporte en el área de las Ciencias de la Computación, donde se imparte programación en la educación superior; sin descartar la posibilidad de ser utilizada en otros niveles de educación. Además, la herramienta «API Issues» posee cuatro funcionalidades, dos de las cuales pueden ser empleadas como instrumento de automatización de algunos procesos del KDD, esto es: la extracción de los datos provenientes de Twitter y el preprocesamiento de los datos; por lo que podría ser aplicada en otras áreas de trabajo futuro, y con las otras dos funcionalidades, es posible realizar la predicción del aprendizaje o predicción de la participación estudiantil.

**Palabras claves:**

Minería de Textos; Twitter; Estrategia Didáctica; Redes Neuronales Artificiales; Algoritmos Supervisados; Procesamiento de Lenguaje Natural; APP Issues; JiTTwT.

## **Abstract**

The present research was focused on the field of technologies applied to education, specifically, using data mining and the integration of social media. Data mining is an interdisciplinary field that merge different areas of study such as statistics and computer science with the purpose of finding patterns of huge volumes of data automatically for decision making. Due to its characteristic, data mining can be applied on several fields of study such as finance, selling, medicine, education, among others, where there are several data mining techniques or methods that are used for different purposes or objectives including predictive and descriptive models containing not only classification and regression tasks, but also association and grouping respectively.

In the field of education, it has been shown the use of different data mining techniques with several targets, i.e., detection of students in risk, analysis of students' feelings and emotions, academic performance prediction, improvement of student – teacher communication, among others, through data extraction from social media. However, few studies refer to the use of pedagogic practices that combine the use of data mining techniques and the social media Twitter, which allows to predict student difficulties coming from such a social media, and to improve teaching – learning processes of college students.

The objective of this doctoral dissertation consists of proposing a didactical strategy that integrates data mining for predicting college student difficulties that undergo during a class session through extracting data from social media Twitter so that teachers can have a tool for helping students opportunely, specially, on topics that require more attention of the Programming class at the Central University of Ecuador, located in Quito.

The proposed didactical strategy, called Just in Time to Teach with Twitter (JiTTwT), is comprised of 4 phases where each one involves different activities and tasks that incorporate not only pedagogic but also technological trends. With these two trends, it was developed a computer tool by using Python software called API Issues that has 4 functionalities: 1) data extraction from Twitter; 2) data processing; 3) model construction and evaluation; and 4) type of difficulty prediction.

The API Issues allows to automate the different phases of the didactical strategy JiTTwT so that teachers have a support tool when teaching, predicting difficulties that students may undergo during face – to – face classes through the visualization of a map of the most relevant topics.

To reach the proposed goals, a systematic literature review was executed, which allowed to find gaps of knowledge in earlier studies so that the didactic strategy JiTTwT includes novel characteristics in the field of higher education using data mining and social media Twitter. The didactic strategy was applied in two instances to confirm its development.

The indices of failing the Programming class are high, therefore it is expected that the didactic strategy JITTWT allows teachers to make predicted decisions to minimize identified student problems. In this way, this strategy becomes a contribution to the area of computer science, where the Programming class is part of college education. Moreover, API issues have four functionalities, two of them can be applied as a tool to automate several KDD processes, and replicated in other areas of future study, another two functionalities to predictive learning and predictive student participation.

**Keywords**

Data mining; Twitter; Didactic strategy; Artificial neural networks; Supervised algorithms; Processing of natural language; APP Issues; JITTWT.

## **Agradecimiento**

La gratitud, es el acto más sublime del ser humano, es la retribución en diferentes formas a las acciones recibidas por las personas que nos rodean; por lo que es oportuno y meritorio, mencionar a quienes fueron mi apoyo en estos largos años de trabajo.

Dios, mi ser de luz y fortaleza, puso en mi camino a las personas, instituciones y momentos perfectos, para que el presente trabajo haya concluido esta etapa; no puedo decir que es el final; puesto que aquí empieza el camino por compartir todo lo aprendido, en retribución a todo lo recibido.

A mi querida Universidad Central del Ecuador, que cumplió su compromiso de apoyo al Docente, otorgándome el tiempo necesario para realizar las actividades concernientes a mis estudios doctorales.

A Karina, mi Directora, quien me brindó su ayuda en los momentos de transición más críticos, por la motivación constante y su fe en mí. A mi Codirector Waldo, quien, a pesar de la distancia y el tiempo, supo impartirme el conocimiento y la guía necesaria para el desarrollo y culminación de este trabajo.

Un agradecimiento especial a mi compadre y querido amigo Marco Eduardo Molina, quien, con su experiencia, me ha transmitido sus bastos conocimientos, con humildad, mucha paciencia, y me ha permitido reconocer mis debilidades. Gracias por cada una de nuestras charlas, no basadas únicamente en el ámbito profesional, sino las de carácter personal, aquellas que me enriquecen como ser humano. Espero algún día alcanzar su sabiduría.

A mis amigos, que en su momento y de distinta forma, me motivaron a no decaer hasta cumplir con mi objetivo, gracias por su amistad. Quiero hacer especial mención a Paty y Moni Jimbo, por su cariño sincero y acogerme en el momento indicado, y, sobre todo, cuando algunas personas me dieron la espalda, fueron ellas las que me acogieron, creyeron en mí y me aceptaron como soy.

A mi compañero de trabajo Jorge Santamaría, quien con su experiencia enriqueció mi labor y me alentó a diario en la etapa final. Gracias amigo por tu apoyo.

Aunque no de manera física, la permanencia de mis grandes amigas Lu y Sandy; gracias por sus palabras y oraciones que motivaron mi caminar en estos años; y sobre todo por comprender mis ausencias.

Y no siendo menos importante, mi familia política. A mi segunda madre, Florita, quien me ha entregado su cariño y compartido de cerca mis alegrías y tristezas. A mi suegro Fabian, por su gran estima y considerarme un “ángel” en sus vidas. Gracias por demostrarme siempre su cariño, por aceptarme como soy y por creer en mí.

## **Dedicatoria**

*A mis amadas hijas Domi y Daf, gracias porque a pesar de sus propios intereses y necesidades, aceptaron que mamá debía cumplir con el objetivo propuesto; y perdón por haberles robado tantos momentos de sus vidas, gracias por su paciencia. No fue fácil, pero aquí estoy, demostrando que, a pesar de las adversidades, todo es posible.*

*En la distancia mi amada Domi, has demostrado tu valentía frente a toda circunstancia. Creo en ti, te admiro y valoro mucho todo lo que haces. Recuerda que todo es posible, solo debes creer en ti. Más que en mi mente, llevo en mi corazón tus palabras de aliento y tu apoyo en los momentos difíciles que atravesé a lo largo de este proyecto, aun con tu corta edad fuiste mi gran consejera, mi pañito de lágrimas, fuiste y eres mi amiga fiel. Ahora, es momento de luchar por tus sueños y aquí estaré para apoyarte siempre. Sigue tu camino, con la convicción de cumplir tus objetivos, aunque a veces las cosas estén cuesta arriba, no te detengas y lleva contigo los valores y principios que posees. Recuerda tus raíces y el amor profundo que guardo por ti. Cuenta siempre conmigo. Te amodoro muñequita linda.*

*Estas líneas van dedicadas a ti mi pequeña Dafne, me disculpo porque en algún momento dudé de tu cariño, pero cuando tu papito y yo estuvimos enfermos, cuidaste de nosotros en cada momento y me alentaste a seguir con este proyecto. Son detalles que están grabados en mi corazón para toda la vida. Te quiero por lo que eres, no necesitas imitar a nadie, se tú misma. Conserva el gran espíritu de luchadora que llevas dentro de ti. Recuerda que siempre estaré contigo, cuando me necesites o aun cuando no lo creas. Espero que, en un futuro muy cercano nuestros lazos se fortalezcan. Te quiero mucho pequeña mía.*

*Lamento no poder dedicarte algunas líneas de este trabajo mi amado esposo, y no es posible hacerlo, ya que tú formas parte del mismo, tú has vivido y sentido conmigo las derrotas, y también has celebrado con profunda alegría los triunfos. Tus conocimientos, tu aporte profesional, tu sabiduría, tu lógica y tu practicidad para resolver los problemas lograron sacarme de las encrucijadas en las que muchas veces me encontré.*

*Este trabajo es nuestro mi amado Bayito, porque sin tu apoyo incondicional, tu amor profundo y desinteresado, no me habría embarcado en este proyecto, que después de varios años de muchos sinsabores, de muchas lágrimas, al fin podemos verlo hecho realidad. A Dios le pido que me de la salud y el tiempo necesario para retribuir todo lo que haces por mí. Perdón por haber sido una preocupación constante, pero aquí sigo amado mío, por muchos años más junto a ti, con la bendición de Dios y la Virgencita. Te amaré toda la vida.*

**Anilu**

*Quando pensé que había llegado el fin de este largo camino...  
me caí otra vez y me derrumbé por completo.*

*Y ahí estuviste nuevamente para alentarme a seguir,  
tomaste los pedazos de mi corazón y los reconstruiste amado mío.*

*Con Dios y la Virgencita, me levantaron  
para continuar y llegar a la ansiada meta.*

*Te amo profundamente Bayito*

---0---

*Gracias otra vez mi querida Lu,  
porque comprendes que ser madre,  
esposa, profesional, hija  
y amiga no es una tarea sencilla.  
Dios bendiga nuestra amistad.*



## Índice de Contenido

Capítulo 1 – Introducción .....	18
1.1    Motivación.....	18
1.2    Planteamiento del problema .....	20
1.3    Objetivos .....	23
1.3.1    Objetivo general .....	23
1.3.2    Objetivos específicos .....	23
1.4    Hipótesis.....	24
1.5    Metodología .....	24
1.6    Estructura de la tesis .....	26
Capítulo 2 – Marco teórico.....	28
2.1    Minería de Datos .....	28
2.1.1    Origen.....	28
2.1.2    Definición .....	28
2.1.3    Aplicaciones.....	30
2.2    Procesos del KDD.....	31
2.3    Técnicas de Minería de Datos.....	33
2.3.1    Aprendizaje supervisado .....	36
2.3.1.1    Clasificación .....	36
2.3.1.2    Regresión.....	38
2.3.2    Aprendizaje no supervisado .....	39
2.3.2.1    Asociación.....	39
2.3.2.2    Agrupamiento.....	40
2.3.3    Aprendizaje reforzado .....	41
2.3.4    Aprendizaje Profundo.....	41
2.4    Redes Sociales .....	41
2.4.1    Origen de las redes sociales.....	41
2.4.2    Definición de las redes sociales .....	43
2.4.3    Clasificación de las redes sociales.....	43
2.4.3.1    Redes de propósito general.....	44
2.4.3.2    Redes sociales generales o de ocio .....	44
2.4.3.3    Redes profesionales .....	44
2.4.4    Aplicación de las redes sociales .....	45
2.4.5    Las redes sociales en la educación.....	47
2.4.5.1    Facebook .....	48

2.4.5.2	Twitter .....	48
2.4.5.2.1	Usos de Twitter .....	49
2.5	Estrategias didácticas .....	52
2.5.1	Definiciones .....	52
2.5.2	Clasificación de las estrategias didácticas.....	54
2.5.3	Estrategias de enseñanza .....	54
2.5.4	Estrategias de aprendizaje.....	55
Capítulo 3 – Revisión sistemática de la Literatura .....		57
3.1	Importancia de la revisión .....	57
3.2	Método utilizado .....	58
3.2.1	Identificar la necesidad de realiza la revisión .....	58
3.2.2	Especificar las preguntas de investigación.....	59
3.2.3	Identificar y determinar los términos de búsqueda.....	60
3.2.4	Establecer las estrategias de búsqueda .....	61
3.2.5	Delimitar los criterios de inclusión .....	61
3.2.6	Realizar el proceso de extracción de los datos .....	62
Capítulo 4 – Diseño de la estrategia didáctica.....		77
4.1	Antecedentes .....	77
4.2	Desarrollo .....	79
4.2.1	Encuesta – Parte 1 .....	80
4.2.1.1	Pregunta 1: ¿Qué red social utilizas con más frecuencia? .....	82
4.2.1.2	Pregunta 2: ¿Con qué objetivo utilizas la red social?.....	83
4.2.1.3	Pregunta 3: ¿Qué red social utilizas o utilizarías con fines educativos, investigación o consulta académica? .....	84
4.2.1.4	Pregunta 4: ¿En qué lugar buscas información académica? .....	84
4.2.2	Uso de Twitter como herramienta de participación estudiantil .....	86
4.2.3	Propuesta de estrategia didáctica, para fomentar la participación estudiantil universitaria .....	87
4.2.4	Evaluación de la participación estudiantil .....	88
4.2.5	Encuesta – Parte 2 .....	90
4.2.5.1	Pregunta 5: Si no comprendes algún concepto o explicación del profesor, ¿Qué haces? 90	
4.2.5.2	Pregunta 6: Si no preguntas al profesor ¿En dónde buscas solventar la duda con mayor frecuencia?.....	91
4.2.5.3	Pregunta 7: ¿Cuál es la razón de no realizar preguntas en clase? .....	92
4.2.5.4	Pregunta 8: Consideras que lo más importante de asistir a clases es.....	93
4.2.5.5	Pregunta 9: ¿Cómo consideras que aprendes más? .....	94

4.2.5.6	Pregunta 10: Si fueras profesor ¿cómo solventarías las dudas de los estudiantes? 95	
4.2.6	Fundamentación para el diseño de la estrategia didáctica.....	100
4.2.6.1	Razón de innovación.....	100
4.2.6.2	Razón pedagógica y tecnológica.....	101
4.2.7	Diseño de la estrategia didáctica.....	102
Capítulo 5 – Validación de la Estrategia Didáctica JiTTwT .....		110
5.1	Caso de estudio 1 – mejorar participación estudiantil.....	110
5.1.1	Método.....	110
5.1.2	Muestra .....	111
5.1.3	Análisis previo del entorno – Caso 1.....	111
5.1.4	Instrumento.....	113
5.1.5	Desarrollo .....	113
5.1.5.1	Determinar en qué medida la estrategia didáctica incrementa la participación de los estudiantes durante las sesiones de clases presenciales. ....	113
5.1.5.2	Aplicación de la Estrategia Didáctica JiTTwT.....	114
5.1.6	Validación del cuestionario .....	116
5.1.6.1	Fase 1: Diseño del instrumento basado en un modelo.....	116
5.1.6.2	Fase 2: Determinación de los ítems del instrumento de acuerdo con el modelo propuesto.....	117
5.1.6.3	Fase 3: Validación de los instrumentos basado en el criterio de expertos .....	119
5.1.6.4	Fase 4: Aplicación de la prueba piloto y análisis estadístico .....	120
5.1.6.5	Fiabilidad del instrumento.....	120
5.1.6.6	Validez del instrumento.....	121
5.1.6.7	Análisis descriptivo .....	121
5.1.6.8	Correlación entre secciones .....	122
5.1.7	Aplicación del instrumento.....	123
5.1.8	Precisar si la estrategia didáctica genera un cambio de actitud favorable en los estudiantes hacia el aprendizaje. ....	123
5.1.9	Describir la incidencia de la aplicación de la metodología en la autopercepción del pensamiento crítico de los estudiantes.....	127
5.1.10	Análisis estudiantes “Retirados” .....	132
5.1.11	Análisis posterior del entorno – Caso 1 .....	133
5.2	Caso de estudio 2 – mejorar rendimiento académico .....	135
5.2.1	Introducción .....	135
5.2.2	Muestra .....	135
5.2.3	Análisis previo del entorno – Caso 2.....	135

5.2.4	Instrumento.....	136
5.2.5	Desarrollo .....	136
5.2.5.1	Análisis Cuantitativo en el 1° Hemi .....	137
5.2.5.2	Aplicación de la Estrategia Didáctica JITTWT.....	138
5.2.5.3	Análisis Cuantitativo en el 2° Hemi .....	138
5.2.5.4	Análisis Cuantitativo entre el 1° y 2° Hemi sobre participación vs rendimiento y estudiantes retirados .....	139
5.2.5.5	Análisis Cuantitativo sobre participación, rendimiento y aprobación .....	140
5.2.5.6	Correlación de las variables .....	141
5.2.6	Análisis posterior del entorno – Caso 2 .....	142
5.3	Aportes de la Estrategia Didáctica JITTWT .....	143
Capítulo 6 – Clasificación y predicción de las dificultades académicas .....		145
6.1	Introducción .....	145
6.2	Método.....	146
6.3	Participantes.....	148
6.4	Instrumentos .....	149
6.5	Desarrollo .....	150
6.5.1	Extracción y clasificación de los datos .....	150
6.5.1.1	Descomposición del problema .....	150
6.5.1.2	Abstracción.....	150
6.5.1.3	Generalización de patrones .....	150
6.5.1.4	Diseño algorítmico.....	150
6.5.2	Descripción de las intervenciones .....	151
6.5.2.1	Primera intervención .....	151
6.5.2.1.1	Diseño de la aplicación para extracción de datos .....	151
6.5.2.1.2	Depuración de registros de Twitter .....	153
6.5.2.1.3	Análisis y clasificación de tweets .....	155
6.5.2.2	Segunda, tercera y cuarta intervención .....	158
6.5.2.2.1	Diseño del cuestionario para extracción de datos .....	159
6.5.2.2.1.1	Depuración de registros del Formulario .....	159
6.5.2.2.2	Análisis y clasificación de los comentarios.....	160
6.5.2.3	Análisis de las intervenciones .....	162
6.5.2.3.1	Análisis cualitativo por modalidad de estudio .....	163
6.5.2.3.2	Análisis cualitativo antes y durante la pandemia.....	165
6.5.3	Creación del modelo predictivo.....	167
6.5.3.1	Construcción del modelo.....	168

6.5.3.1.1	Arquitectura de los modelos .....	169
6.5.3.1.2	Configuración de parámetros e hiperparámetros .....	170
6.5.3.2	Entrenamiento.....	174
6.5.3.3	Prueba del modelo .....	175
6.5.4	Aplicación del modelo sobre nuevos datos .....	180
6.5.4.1	Visualización .....	183
Capítulo 7	– Conclusiones, trabajos futuros y aportes .....	187
7.1	Conclusiones.....	187
7.2	Limitaciones.....	195
7.3	Trabajos futuros .....	196
7.4	Aportes .....	198
7.5	Publicaciones científicas generadas.....	199
7.6	Méritos obtenidos .....	201
Referencias	.....	203
Anexos	.....	225
Anexo A	225	
Anexo B	241	
Anexo C	243	
Anexo D	248	
Anexo E	255	
Anexo F	257	
Anexo G	261	

## Índice de Figuras

Figura 1 – Aporte de otros dominios a la Minería de Datos .....	29
Figura 2 – Proceso del descubrimiento del conocimiento en bases de datos – KDD.....	32
Figura 3 – Paradigma de la Minería de Datos .....	33
Figura 4 – Clasificación del Aprendizaje Automático.....	35
Figura 5 – Ejemplo de una regla de clasificación .....	37
Figura 6 – Ejemplo de reglas de asociación .....	40
Figura 7 – Logotipo SixDegrees .....	41
Figura 8 – Logotipo MySpace .....	42
Figura 9 – Redes sociales.....	42
Figura 10 – Uso de las redes sociales. ....	45
Figura 11 – Número de artículos publicados por año.....	63
Figura 12 – Número de artículos publicados por continente .....	64
Figura 13 – Número de artículos publicados por continente y por país .....	65
Figura 14 – Usos de Twitter por actor .....	73
Figura 15 – Criterios de innovación educativa.....	78
Figura 16 – Fases de MIE .....	78
Figura 17 – Porcentaje de participación por período y por Hemi.....	80
Figura 18 – Frecuencia de uso de las redes sociales.....	82
Figura 19 – Objetivo del uso de las redes sociales .....	83
Figura 20 – Redes sociales que utilizan los estudiantes con fines académicos.....	84
Figura 21 – Análisis de participación estudiantil .....	87
Figura 22 – Registro de participaciones por estudiante .....	88
Figura 23 – Opciones de consulta estudiantil.....	91
Figura 24 – Otras opciones de consulta .....	92
Figura 25 – Motivos de falta de participación en clase .....	93
Figura 26 – Porcentaje de importancia de asistencia según factores.....	94
Figura 27 – Preferencias de aprendizaje .....	95
Figura 28 – Resolver dudas en el rol como docente.....	96
Figura 29 – Diagrama de Flujo de la Estrategia Didáctica JiTTwT .....	109
Figura 30 – Tabulación de datos por grupo .....	136
Figura 31 – Diagrama del diseño algorítmico .....	151
Figura 32 – Sección del código de “API Issues” para la extracción de datos .....	153
Figura 33 – Porcentaje de dificultades por período y por categoría.....	163
Figura 34 – Dificultades antes de la pandemia.....	164
Figura 35 – Dificultades durante la pandemia.....	165
Figura 36 – Arquitectura de los modelos.....	169
Figura 37 – Evaluación de los modelos.....	173
Figura 38 – Valor de la Exactitud y Pérdida del Modelo RNN .....	176
Figura 39 – Matriz de confusión, modelo RNN.....	177
Figura 40 – Valor de la Exactitud y Pérdida del Modelo RN .....	178
Figura 41 – Matriz de confusión, modelo RN .....	180
Figura 42 – Número registros por clase.....	184
Figura 43 – Nube de palabras con mayor incidencia de dificultad .....	184
Figura 44 – Flujo de trabajo.....	186
Figura 45 – Diploma Mérito .....	202
Figura 46 – Creación de Apps en Twitter.....	261

Figura 47 – Pestaña de configuración de Apps en Twitter .....	262
Figura 48 – Ejemplo de objetivo codificado en formato JSON.....	264

## Índice de Tablas

Tabla 1 – Actividades realizadas.....	25
Tabla 2 – Principales usos de Twitter .....	49
Tabla 3 – Ejemplos de método, estrategia y técnica .....	53
Tabla 4 – Preguntas de investigación .....	59
Tabla 5 – Términos de búsqueda .....	61
Tabla 6 – Artículos encontrados, seleccionados e incluidos.....	62
Tabla 7 – Artículos por intervalo de usuarios .....	66
Tabla 8 – Artículos por intervalo de tweets.....	67
Tabla 9 – Artículos por técnicas de Minería de Datos .....	67
Tabla 10 – Artículos por herramientas .....	70
Tabla 11 – Artículos por utilidad de Twitter .....	72
Tabla 12 – Artículos por prácticas pedagógicas.....	74
Tabla 13 – Resumen de hallazgos en la literatura vs. aportes de la estrategia propuesta .....	76
Tabla 14 – Frecuencia de uso de redes sociales .....	83
Tabla 15 – Búsqueda de información académica .....	85
Tabla 16 – Etapas del pre-experimento.....	86
Tabla 17 – Escala de medición de participación estudiantil .....	88
Tabla 18 – Porcentaje y nivel de participación por período y por Hemi .....	89
Tabla 19 – Medidas de tendencia central y dispersión .....	89
Tabla 20 – Criterios de innovación y actividades previas .....	100
Tabla 21 – Fases de una innovación educativa y actividades realizadas por el docente .....	101
Tabla 22 – Fases de la estrategia didáctica.....	103
Tabla 23 – Participación estudiantil, 1° Hemi .....	114
Tabla 24 – Participación estudiantil, 1° y 2° Hemi .....	115
Tabla 25 – Ítems de la sección actitud.....	117
Tabla 26 – Ítems de la sección autopercepción del pensamiento crítico .....	119
Tabla 27 – Análisis descriptivo .....	121
Tabla 28 – Estadística descriptiva pre-test, sección Actitud .....	123
Tabla 29 – Estadística descriptiva pos-test, sección Actitud.....	125
Tabla 30 – Análisis pre-test y pos-test, sección Actitud.....	126
Tabla 31 – Estadística descriptiva pre-test, sección Autopercepción del Pensamiento Crítico	127
Tabla 32 – Estadística descriptiva pos-test, sección Autopercepción del Pensamiento Crítico	129
Tabla 33 – Análisis pre-test y pos-test, sección Autopercepción del Pensamiento Crítico .....	130
Tabla 34 – Porcentaje de estudiantes retirados por grupo de estudio.....	132
Tabla 35 – Medidas de tendencia central 1° Hemi .....	137
Tabla 36 – Medidas de tendencia central 2° Hemi .....	138
Tabla 37 – Comparativo de promedios entre 1° y 2° Hemi .....	139
Tabla 38 – Análisis comparativo entre la participación estudiantil y el rendimiento académico .....	140
Tabla 39 – Correlación entre participación, rendimiento y estado .....	142
Tabla 40 – Categorización de dificultades .....	156
Tabla 41 – Dificultades detectadas antes de la pandemia.....	157
Tabla 42 – Dificultades detectadas durante la pandemia.....	160
Tabla 43 – Análisis por período y categoría de dificultad .....	162
Tabla 44 – Análisis cualitativo antes y durante la pandemia .....	165
Tabla 45 – Estructuras de los modelos de Red Neuronal Básica (RN) .....	172



Tabla 46 – Afinamiento del modelo .....	174
Tabla 47 – Métricas del modelo RNN .....	176
Tabla 48 – Métricas del modelo RN .....	179
Tabla 49 – Muestra de comentarios etiquetados.....	182
Tabla 50 – Métricas del modelo RNN para nuevos datos.....	183

## Capítulo 1 – Introducción

Este capítulo describe la motivación del trabajo doctoral y el planteamiento del problema que fundamentan la presente tesis; y que permite describir el objetivo general, los objetivos específicos. Se realiza el planteamiento de las hipótesis que serán verificadas a lo largo del trabajo y una parte importante de este capítulo, es la descripción general de la metodología utilizada. Al final del capítulo se presenta la estructura de la tesis, que brinda al lector, una guía para el seguimiento del trabajo realizado.

### 1.1 Motivación

Con el acelerado desarrollo y uso de las redes sociales, el almacenamiento de datos y el manejo de diferentes medios digitales; el volumen de la información en la Web ha incrementado rápidamente (Fan y Bifet, 2013); de manera que, la extracción de los datos en la actualidad, ha superado la capacidad para procesar, analizar, y almacenar el conjunto de datos recolectados con herramientas o procesos tradicionales, debido a que son datos no estructurados, están en constante crecimiento, poseen datos heterogéneos, y están vinculados a múltiples fuentes (Matas Terrón et al., 2020; Tiwari y Kumar, 2020; Zong et al., 2021).

En este contexto, el contenido de las redes sociales no siempre constituye una información relevante para los usuarios, debido a la forma en que esta se presenta. Sin embargo, gran parte de esta información presentada en forma de datos, puede ser aprovechada en distintos ámbitos como las finanzas y el sistema bancario, marketing, salud, educación, industria, entre otros (Aggarwal, 2011). Para el aprovechamiento de estos datos, existen diferentes métodos utilizados con distintos propósitos como: el análisis estadístico de redes, detección de comunidades, clasificación de la información, análisis de evolución, extracción de datos para preservar la privacidad, inferencia de enlaces y visualización, entre otros.

Para alcanzar un uso efectivo de los medios sociales, es necesario que los datos dispuestos en estos espacios, pasen por diferentes tareas como la extracción, depuración y entrenamiento, para conseguir el descubrimiento de la información; un proceso más conocido como «Knowledge Discovery in Databases» (KDD) (Hernández Orallo et al., 2004; Kantardzic, 2020; Tan et al., 2014). El KDD incluye diferentes etapas como: la selección, preprocesamiento y transformación de los datos, la obtención de patrones; para posteriormente ser evaluados, interpretados y convertidos en conocimiento.

Respecto del campo educativo, se ha evidenciado que el uso de las redes sociales se ha incrementado en los últimos años, como herramienta que permite mejorar los procesos de enseñanza y aprendizaje en los diferentes niveles educativos (Anisimova et al., 2019; Chugh y

Ruhi, 2018; Lemay et al., 2019; Tejedor et al., 2021); ya que fomentan el desarrollo de nuevas destrezas y habilidades técnicas, necesarias en el contexto tecnológico actual (Rodríguez Gallego et al., 2017). Entre las redes sociales más utilizadas en el ámbito académico, se encuentran Facebook y Twitter (Froment et al., 2022; Marín-Díaz y Cabero-Almenara, 2019), siendo esta última la más utilizada en la educación superior (Fernández-Ferrer y Cano, 2016).

Twitter o también conocida como herramienta de microblogging, es una red social con gran aceptación por parte de los miembros de la comunidad académica (Letierce et al., 2010; Tang y Hew, 2017). No obstante, Malik et al. (2019) concluyen que, la mayoría de estudios relacionados con el uso de Twitter en la educación en algunos países de América del Norte y Europa, son estudios de casos descriptivos, y destacan la importancia de ampliar el espectro de la investigación a otras partes del mundo, en las que se utiliza asiduamente esta red social.

Entre las principales aplicaciones de Twitter en la educación se puede mencionar la identificación de estilos de aprendizaje, la caracterización de los sentimientos y comportamientos; además el permitir compartir información y recursos; generar comunicación y participación; fomentar habilidades de pensamiento crítico, promulgar el trabajo en equipo; mejorar el rendimiento académico, mejorar la argumentación oral y escrita; entre otras (Pérez-Suasnavas et al., 2020a). Aunque se evidencia el amplio espectro de uso de Twitter en la educación superior; debido a la diversidad de las áreas de estudio, no ha sido posible determinar estrategias didácticas comunes para su aplicación (Marín-Díaz y Cabero-Almenara, 2019; Tejedor et al., 2021).

Por su parte, Zeballos (2020) manifiesta que, el uso de medios tecnológicos implica la superación de algunas barreras por parte de los actores de la educación; también destaca que, la inclusión de las Tecnologías de la Información y las Comunicaciones (TIC) en el aula, supone el desarrollo y aplicación de estrategias didácticas que estén en concordancia con el entorno y los objetivos que se persigue.

En este contexto, Salinas Ibáñez y Marín Juarros (2019) denotan la falta de trabajos que cuenten con una visión crítica, y un análisis profundo de las prácticas académicas, así como la inclusión de los medios digitales como parte de los procesos de enseñanza y aprendizaje; por lo que, es necesario generar propuestas de mejora que incluyan, tanto procesos automatizados para la extracción de los datos provenientes de las redes sociales, así como el desarrollo de estrategias didácticas, que permitan fomentar una cultura digital entre los docentes, estudiantes y la institución, con el objetivo de mejorar la calidad de la educación.

## 1.2 Planteamiento del problema

En el área de las ciencias de la computación, tanto la enseñanza como el aprendizaje de la asignatura Programación o cátedras afines en las Carreras de Ingeniería, han sido considerados con un alto grado de dificultad, como lo expresan Compañ-Rosique et al. (2015) e Insuasti (2016), debido a diversos factores que suceden dentro del aula de clase; y que están relacionados tanto por habilidades cognitivas, como por la motivación de los estudiantes (Fuentes-Rosado y Moo-Medina, 2017; Oviedo Galdeano y Ortiz Uribe, 2002). La motivación en el aprendizaje de Programación, no depende únicamente de la carrera que cursan los estudiantes (Azmi et al., 2017; Hoffbeck et al., 2016), pues la mayor parte de carreras de ingeniería, tienen como eje transversal la asignatura Programación, como parte de su malla curricular, y que generalmente se imparte en los primeros niveles de formación (Campillay Briones y Meléndez Araya, 2015; Compañ-Rosique et al., 2015; Fuentes-Rosado y Moo-Medina, 2017; Griffiths et al., 2016; Pérez Angulo y Pedroza Palomar, 2018; Pérez-Suasnavas et al., 2020b).

Para Díaz (2006), un primer curso de Programación, debe concentrarse en ofrecer a los estudiantes los siguientes propósitos:

- Conocimientos de los conceptos de Programación y un vocabulario para discutirlos.
- Habilidades de análisis y de programación.
- Un marco de referencia para la teoría y disciplina para aprender programación.

Dado que la programación implica un proceso mental complejo (Oviedo Galdeano y Ortiz Uribe, 2002; Zuleta Medina y Chaves Torres, 2011), los programadores requieren desarrollar diferentes habilidades como: creatividad, abstracción, disciplina, razonamiento lógico, entre otras; no obstante, programación no significa aprender un lenguaje, pues implica que los estudiantes aprendan lógica para programar en cualquier herramienta.

El estudio realizado por Pérez-Suasnavas y Cela (2022), entre el año 2015 y 2019 en el Sistema Integral de Información Universitaria (SIIU), de la Universidad Central del Ecuador (UCE), en la carrera de Ingeniería Civil, perteneciente a la Facultad de Ingeniería y Ciencias Aplicadas, se registra un promedio del 36.63% de estudiantes que reprueban la asignatura Programación; sin que hasta la presente fecha se evidencien estudios relacionados a identificar las causas del alto índice de reprobación, o existan propuestas de mejora frente a la problemática. Sumado a este problema, en la investigación realizada por Pérez-Suasnavas et al. (2020b) evidencia que, los estudiantes de esta carrera denotan una reducida participación durante las sesiones de clases presenciales, similar hallazgo a lo identificado por Griffiths et al. (2016), quienes destacan que

la mayoría de los estudiantes de la carrera de Ingeniería Civil Informática, se dedican a tomar notas y no tienen una participación activa.

La participación estudiantil, es un factor que incide en el rendimiento académico, así como lo señalan Carlos-Martínez et al. (2018), Jenaro-Río et al. (2018) y Pérez-Suasnavas y Cela (2022); hallazgos que son comparables con los resultados obtenidos en el estudio realizado por Beltrán et al. (2015), en otras carreras que forman parte de la misma facultad; este estudio concluye que, existe un 48,75% de estudiantes que reprueban la asignatura, y el factor principal que incide en el rendimiento académico, está relacionado con la metodología de enseñanza del docente.

Por otra parte, la masiva cantidad de estudiantes matriculados en los primeros niveles de formación universitaria, y la reducida participación estudiantil durante las sesiones de clase; constituye un verdadero reto para el docente la enseñanza de la programación, así como, brindar un seguimiento íntegro a todos los estudiantes, e identificar las dificultades que pueden derivarse durante una sesión de clase.

En este contexto, varios autores han demostrado el interés por implementar diferentes estrategias didácticas, en el proceso de enseñar y aprender Programación; con el propósito de mejorar el rendimiento académico de los estudiantes (Benítez Cortés et al., 2017; Molina Izurieta et al., 2019; Pérez Angulo y Pedroza Palomar, 2018). Entre estas estrategias se puede citar el uso de las redes sociales, que han sido objeto de estudio por la comunidad científica, por su impacto en el campo de la educación (Anisimova et al., 2019; Chávez Márquez y Gutiérrez Diez, 2015; Chávez Martínez, 2015; Rodríguez Gallego et al., 2017; Roig-Vila y Álvarez Herrero, 2019; Salinas Lozano, 2021).

Las redes sociales constituyen un espacio de acopio de gran cantidad de información, utilizada por personas de diferentes edades, y en mayor porcentaje por los jóvenes de la sociedad; sin embargo, no ha logrado alcanzar su inserción definitiva en la educación formal; ya sea por sus características, o por la cualificación de los docentes en el aprovechamiento de estos espacios (Morales, 2015).

El uso de las redes sociales en la educación implica diferentes desafíos que permitan un verdadero aprovechamiento, puesto que, es preciso dar respuesta a ciertas preguntas: ¿cómo extraer la información?, ¿qué material se debe utilizar?, ¿qué información se debe compartir?, ¿cuándo se debe utilizar?, ¿qué resultados se debe esperar?

Debido a los datos heterogéneos que caracterizan a las redes sociales, éstas deben pasar por un proceso de extracción, depuración y análisis de los datos, – tareas propias del Procesamiento de Lenguaje Natural «Natural Language Processing» (NLP) y de Minería de Datos «Data Mining»

(DM) –, para poder ser utilizados eficientemente en los diferentes contextos, en este caso, en el campo de la educación.

Frente a estos escenarios, este trabajo plantea la necesidad de desarrollar una estrategia que permita integrar aspectos pedagógicos, medios tecnológicos y técnicas de Minería de Datos para el aprovechamiento de los datos provenientes de las redes sociales; para la inserción en el contexto educativo, de forma que, se derive una propuesta didáctica que logre alcanzar una mejora de los procesos de enseñanza y aprendizaje.

En el presente estudio se consideró como red social a Twitter, por los siguientes motivos:

- Twitter es la red social más utilizada en la educación superior (Belanche Gracia et al., 2014; Fernández-Ferrer y Cano, 2016; Froment et al., 2022; Martínez-Rodrigo y Raya-González, 2013; Tejedor et al., 2021).
- Es una red aceptada por la comunidad académica (Junco et al., 2011; Letierce et al., 2010; Malik et al., 2019; Marcelo y Marcelo, 2021; Roig-Vila y Álvarez Herrero, 2019; Santoveña-Casal y Bernal-Bravo, 2019; Tang y Hew, 2017).
- Twitter es usado en estudios que incluyen técnicas de Aprendizaje Automático supervisado y lenguaje natural (Díaz-Mendivelso y Suarez-Baron, 2019; Hasan et al., 2014; Patel y Mistry, 2015).
- Twitter es la plataforma de microblogging más propicia para el diálogo público continuo; ayuda a involucrar a los estudiantes y movilizar a los profesores hacia un papel más activo y participativo; permite compartir información, recursos y comentarios (Junco et al., 2011; Veletsianos, 2011).
- Twitter fomenta diferentes habilidades en los estudiantes, por ejemplo: capacidad de síntesis, pensamiento reflexivo, debate, social, de comunicación, diálogo (Altrabsheh et al., 2015; Calabuig i Serra y Donaire Benito, 2012; Cetintas et al., 2011; Gallardo-López y López-Noguero, 2020; Kimmons et al., 2017; Veletsianos, 2011).

Mediante el desarrollo y aplicación de la estrategia didáctica, se pretende alcanzar diferentes logros que beneficien a los actores de la educación. Al considerarse una propuesta, los actores que intervienen en este estudio son: el docente y los estudiantes. A continuación, se procede a describir brevemente los principales beneficios que obtendrían cada uno:

**a) Beneficios para el Docente**

- Conseguir la motivación en el aula.
- Usar efectivamente las redes sociales en el aula.
- Conseguir que el porcentaje de estudiantes reprobados en la asignatura disminuya.

- Anticipar las dificultades que los estudiantes puedan expresar, y brindar ayuda oportuna en los temas que demanden más atención.

**b) Beneficio para los Estudiantes**

- Población beneficiada: estudiantes de los primeros niveles de formación, esto es 2° a 3° nivel, de carreras de Ingeniería, donde se imparta la cátedra de Programación 1.
- Conocer los conceptos generales de Programación 1.
- Desarrollar diferentes habilidades cognitivas (análisis, razonamiento lógico, abstracción, creatividad, etc.); y habilidades de trabajo en equipo; que pueden ser aplicadas a cualquier asignatura.
- Participar activamente dentro y fuera del aula.
- Focalizar el aprendizaje basado en el estudiante.
- Usar las redes sociales con fines académicos.
- Mejorar el rendimiento académico y aprobar la asignatura.

## 1.3 Objetivos

### 1.3.1 Objetivo general

Proponer una estrategia didáctica que incluya técnicas de Minería de Textos, para predecir las dificultades que experimentan los estudiantes durante una sesión de clase, a través de la extracción de datos provenientes de la red social Twitter; que permita al docente contar con una herramienta de apoyo en el proceso de enseñanza y aprendizaje.

### 1.3.2 Objetivos específicos

1. Realizar una revisión sistemática de la literatura sobre las técnicas de Minería de Datos existentes para la extracción de la información de las redes sociales.
2. Identificar estudios relacionados con la extracción de datos provenientes de la red social Twitter, enmarcado en la educación superior, que incluyan estrategias didácticas.
3. Diseñar una estrategia didáctica, que involucre la utilización de técnicas de Minería de Datos, para la extracción de datos provenientes de los comentarios realizados por estudiantes universitarios, en la red social Twitter.
4. Desarrollar un estudio de caso que valide la estrategia aplicada.
5. Diseñar el prototipo de una herramienta que permita predecir las dificultades que experimentan los estudiantes, durante una sesión de clase, mediante técnicas de Minería de Datos.

6. Validar la herramienta predictiva para identificar las dificultades experimentadas por los estudiantes.

## 1.4 Hipótesis

Para la presente tesis, se plantearon las siguientes hipótesis:

H1: La Estrategia Justo a Tiempo para Enseñar con Twitter, del inglés «Just in Time to Teach with Twitter» (JiTTwT) permite fomentar la participación estudiantil, durante las sesiones de clases presenciales, en la asignatura de Programación 1.

H2. La extracción de datos existentes en la red social Twitter, en el marco de una actividad educativa específica, junto con su clasificación, análisis e interpretación permitirán generar un Corpus Especializado Ad-hoc para el beneficio del docente y los estudiantes en la asignatura de Programación 1.

H3. El desarrollo y aplicación de una estrategia didáctica que utilice técnicas de Minería de Datos, para la extracción y/o análisis de datos provenientes de Twitter en el ámbito de la educación superior, permite predecir las dificultades estudiantiles.

H4. El aprovechamiento de los datos existentes en las redes sociales, en el marco de una actividad educativa específica, junto con su clasificación, análisis e interpretación permiten generar mapas de temas, que posibilitará al docente contar con una herramienta que brinde estrategias para enriquecer procesos de enseñanza y aprendizaje.

## 1.5 Metodología

Por su enfoque, la investigación será tanto cuantitativa como cualitativa. Por una parte, en el enfoque cuantitativo se recopilarán datos provenientes de encuestas, se realizarán mediciones de las diferentes variables de estudio, como: participación estudiantil, rendimiento académico, Estrategia Didáctica JiTTwT, para aceptar o rechazar las hipótesis planteadas; y por otra, en el enfoque cualitativo experimental, se pretende determinar el grado de efectividad de la aplicación de las diferentes técnicas del modelo descriptivo del proceso KDD en la extracción de datos, provenientes de la red social Twitter e identificar el estado actual de la literatura.

La investigación será aplicada, ya que se pretende resolver el problema de la interpretación del lenguaje humano, de forma que pueda ser aprovechada en el marco de procesos de enseñanza y aprendizaje.

Por su alcance, la metodología de la investigación será exploratoria, ya que, en el campo de la extracción de información de tweets académicos, no existe una estrategia que satisfaga de manera integral las necesidades planteadas.



El método a ser utilizado es el inductivo, se pretende particularizar la muestra y replicar el proceso en nuevas muestras, con similares características; para determinar el grado de efectividad de la estrategia utilizada.

En la Tabla 1 se resumen las principales actividades desarrolladas en la investigación, para el cumplimiento de los objetivos específicos.

Tabla 1 – Actividades realizadas

Orden	Objetivo	Actividad: Descripción	Capítulo
1	1 y 2	<p>Revisión de la literatura:</p> <p>La revisión de la literatura realizada permitió: a) identificar las investigaciones que han aplicado técnicas de Minería de Datos, para la extracción y análisis de datos de Twitter en la educación superior; y b) identificar las estrategias didácticas que han incorporado Twitter y Minería de Datos para mejorar los procesos educativos.</p>	3
2	3	<p>Diseño de la estrategia para predecir las dificultades:</p> <p>La evidencia de la reducida participación estudiantil por parte de los estudiantes durante las sesiones de clases presenciales motivó la propuesta de una estrategia didáctica para reducir el problema identificado.</p> <p>La propuesta de la Estrategia Didáctica JiTTwT, permitió cumplir con los siguientes objetivos: a) evaluar el nivel de participación estudiantil; b) determinar los factores asociados a la baja participación estudiantil; y c) proponer una estrategia didáctica para mejorar la participación estudiantil en el aula.</p>	4
3	4	<p>Validación de la estrategia didáctica:</p> <p>El uso de Twitter como herramienta de participación estudiantil en la educación superior, permitió incrementar la participación estudiantil durante las sesiones de clases presenciales del aula universitaria; y constatar los cambios generados en las habilidades de los estudiantes mediante la aplicación de la Estrategia Didáctica JiTTwT.</p> <p>La Estrategia Didáctica JiTTwT fue aplicada por segunda ocasión, para determinar si la participación estudiantil durante las sesiones de clases presenciales incide en el rendimiento académico de los estudiantes universitarios.</p> <p>Mediante la validación del instrumento para evaluar la actitud y la autopercepción del pensamiento crítico de los estudiantes de ingeniería de la Universidad Central del Ecuador (UCE), permitió determinar los cambios generados en los grupos de control y</p>	5

		experimentación, con la aplicación de la Estrategia Didáctica JITTwT.	
4	5	<p>Diseño de la herramienta predictiva:</p> <p>Con la aplicación del pensamiento computacional, se pudo identificar y comparar las dificultades de los estudiantes en la asignatura de Programación 1, mediante un estudio longitudinal no experimental. Se diseñó una herramienta que permita extraer los datos provenientes de la red social Twitter, denominada «API Issues».</p> <p>Se desarrollaron varias funcionalidades de la herramienta, para entrenar y probar el modelo con los datos iniciales, mediante la creación de un flujo de trabajo, que integra técnicas de extracción de datos provenientes de la red social Twitter, Minería de Textos, Procesamiento de Lenguaje Natural y Aprendizaje Profundo, usando Algoritmos Supervisados y Redes Neuronales.</p>	6
5	6	<p>Validación del modelo:</p> <p>El modelo entrenado, permitió realizar la predicción de las dificultades de los estudiantes universitarios con el ingreso de nuevos datos, que permite determinar la validez del modelo. Luego, con los temas más representativos de las dificultades se obtuvo el mapa de temas.</p>	6

## 1.6 Estructura de la tesis

Esta tesis se encuentra estructurada en 7 capítulos, cuyo contenido se describe a continuación:

### Capítulo 1 – Introducción

Este capítulo corresponde a la introducción del trabajo doctoral, se detalla la motivación, el planteamiento del problema, el objetivo general, los objetivos específicos, las hipótesis, la metodología y finalmente se presenta la estructura de la tesis.

### Capítulo 2 – Marco teórico

El segundo capítulo corresponde al desarrollo del marco teórico, respecto de los principales conceptos que conforman el presente trabajo, como son: Minería de Datos, red social Twitter y estrategias didácticas.

### **Capítulo 3 – Revisión sistemática de la literatura**

En este capítulo se revisa la literatura relacionada al tema central del presente trabajo, esto es: técnicas de Minería de Datos para la extracción de conocimiento con datos provenientes de la red social Twitter y su aplicación en la educación superior.

### **Capítulo 4 – Diseño de la estrategia didáctica**

El cuarto capítulo describe el desarrollo de la estrategia didáctica, que permite incluir la red social Twitter en el contexto educativo, con información extraída de los tweets realizados por estudiantes universitarios.

### **Capítulo 5 – Validación de la Estrategia Didáctica JiTTwT**

En este capítulo, mediante la aplicación de dos casos de estudio, se valida el diseño de la Estrategia Didáctica JiTTwT y su incidencia en las aulas universitarias.

### **Capítulo 6 – Clasificación y predicción de las dificultades estudiantiles**

El capítulo sexto describe todas las etapas que conformaron el proceso de la clasificación y predicción de las dificultades de estudiantes universitarios, con datos provenientes de la red social Twitter, mediante el uso de técnicas de Minería de Datos.

### **Capítulo 7 – Conclusiones, aportes y trabajos futuros**

El séptimo capítulo presenta las conclusiones del trabajo, en función de los resultados obtenidos, limitaciones encontradas en el trabajo y se exponen las líneas de investigación futuras. Se presentan los principales aportes derivados del trabajo y se realiza un resumen de las publicaciones realizadas a lo largo de la presente investigación.

## Capítulo 2 – Marco teórico

En este capítulo se definen brevemente los conceptos de Minería de Datos, el paradigma, la clasificación, las diferentes técnicas y tareas; así como su relación con otras disciplinas. Se realiza una introducción a las redes sociales y de forma particular la red social Twitter. Por otra parte, se describen los conceptos sobre estrategias didácticas y conceptos afines que utilizan las redes sociales para mejorar los procesos de enseñanza y aprendizaje, todo esto enmarcado dentro de la educación superior.

### 2.1 Minería de Datos

#### 2.1.1 Origen

El término dato es el plural del latín datum, proviene del verbo dar, utilizada por primera vez en el escrito realizado por Euclides: Data (de la primera palabra griega en el libro, dedomena [“dado”]); una colección de 94 proposiciones geométricas avanzadas (Leendert et al., 2021). Con esta breve introducción, se puede evidenciar que a lo largo de la historia ha existido el continuo interés por recolectar y usar la información oculta de los datos (Gorunescu, 2011).

En la era de la información, existe una masiva cantidad de datos disponibles en los medios digitales, provenientes tanto de industrias, organizaciones y personas. Gran parte de estos datos no cuentan con una estructura, son heterogéneos y están vinculados a diferentes fuentes (Bhatia, 2019; Matas Terrón et al., 2020); de manera que, la disponibilidad de estos datos no se consideran útiles, a menos que estos sean transformados en información válida para los usuarios.

La capacidad para extraer datos de diferentes medios y obtener un conocimiento útil, se ha constituido en un tema de interés tanto por investigadores de la comunidad científica, como por el campo de la ingeniería, y de las diferentes empresas y organizaciones, en la búsqueda de obtener una mejor competitividad en el mercado, a través del descubrimiento de la información.

#### 2.1.2 Definición

La Minería de Datos es un campo interdisciplinario, que integra conceptos de áreas afines como los sistemas de bases de datos, la Estadística, el Aprendizaje Automático y el reconocimiento de patrones (Han et al., 2011; Zaki y Meira, 2014), por lo que, es posible definirla de diferentes maneras. Ver Figura 1.

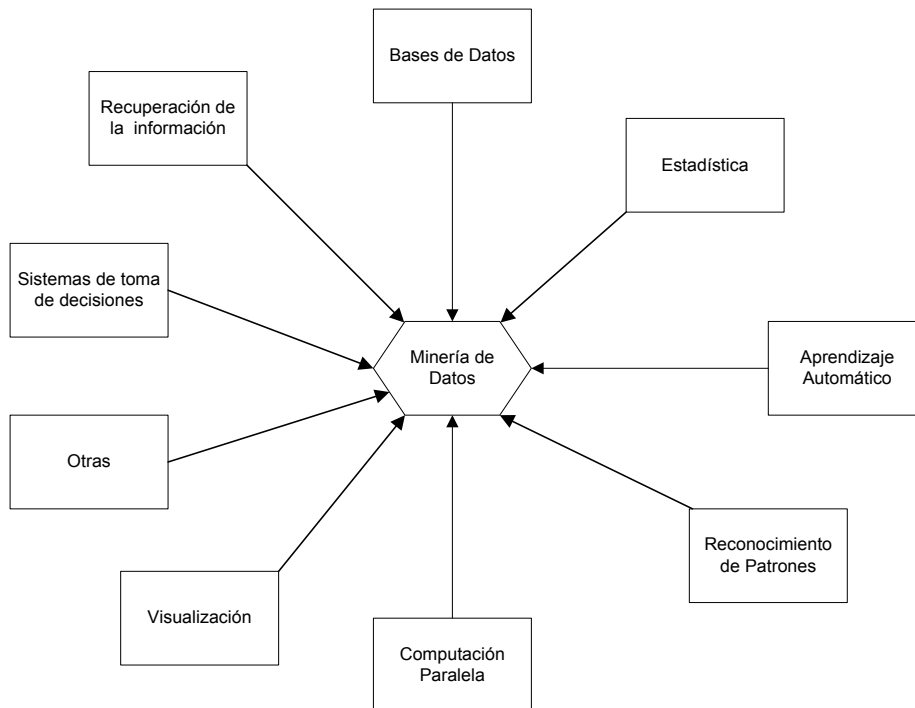


Figura 1 – Aporte de otros dominios a la Minería de Datos

La Minería de Datos también puede ser identificada con términos similares como: minería de conocimiento a partir de datos, extracción del conocimiento, análisis de datos y patrones, arqueología de datos y dragado de datos (Han et al., 2011).

Según Kantardzic (2020) la Minería de Datos es un proceso iterativo que utiliza métodos automáticos o manuales, para la búsqueda de nueva información, valiosa y no trivial, a partir de grandes volúmenes de datos.

Con las características descritas en los párrafos que anteceden, es posible sintetizar la definición de Minería de Datos como sigue:

La Minería de Datos es un proceso para descubrir patrones de forma automatizada, hallar tendencias significativas, filtrando grandes cantidades de datos almacenados en diferentes repositorios, para ser utilizados en la toma de decisiones (Bhatia, 2019; Gartner Group, 2019; Tan et al., 2014), mediante el uso de tecnologías de reconocimiento de patrones, técnicas estadísticas, matemáticas, entre otras.

La característica interdisciplinaria de la Minería de Datos permite que las aplicaciones alcancen un éxito en su implementación, en combinación con otros dominios, así como el uso de las técnicas apropiadas, de acuerdo con la definición del problema. A continuación, se describen las principales disciplinas que influyen fuertemente en el desarrollo de métodos de Minería de Datos y están relacionadas con el objetivo del presente trabajo:

- Estadística: esta disciplina estudia la recopilación, el análisis, la interpretación o explicación y la presentación de datos. Utiliza conceptos, algoritmos y técnicas que usa la Minería de Datos como: media, varianza, distribuciones, regresiones, análisis, muestreo, validaciones cruzadas, técnicas bayesianas, entre otros (Hernández Orallo et al., 2004).

Los modelos estadísticos se utilizan para modelar datos y clases de datos, el ruido y los valores de datos faltantes. La estadística es útil para extraer varios patrones de los datos. Los métodos estadísticos son utilizados para verificar los resultados de la Minería de Datos, ya que el modelo debe verificarse mediante pruebas de hipótesis estadística; en este caso, si el modelo de clasificación o predicción es cierto, la estadística descriptiva del modelo incrementa la validez (Han et al., 2011).

- Bases de datos: estos sistemas son conocidos por la escalabilidad en el procesamiento de conjuntos de datos muy grandes y relativamente estructurados. Se orientan en la creación, el mantenimiento y el uso de bases de datos para organizaciones y usuarios finales (Han et al., 2011; Hernández Orallo et al., 2004).
- Recuperación de la Información «Information Retrieval» (IR): es la ciencia que busca obtener información a partir de documentos. Estos documentos pueden ser de tipo texto o multimedia provenientes de la Web. El enfoque más común distintivo de la recuperación de información, es adoptar modelos probabilísticos (Han et al., 2011; Hernández Orallo et al., 2004).
- Aprendizaje Automático «Machine Learning» (ML): es la combinación del área de la inteligencia artificial y la estadística (Maimon y Rokach, 2010), que permite el desarrollo de algoritmos con capacidad de aprendizaje, o para mejorar el rendimiento de las computadoras en función de los datos (Mitchell, 1997). Los algoritmos varían en función de los objetivos, de acuerdo con el conjunto de datos de entrenamiento, de las estrategias de aprendizaje y de la representación de datos.

Entre las tareas del Aprendizaje Automático se encuentran las predicciones o inferencias; con el objetivo de encontrar la generalización de patrones a partir de un conjunto de muestras, mediante el uso de diferentes técnicas y modelos.

### 2.1.3 Aplicaciones

Son múltiples y variadas las aplicaciones de la Minería de Datos (Bhatia, 2019; Hernández Orallo et al., 2004). Entre los campos más importantes en los que ha incursionado la Minería de Datos se pueden enumerar los siguientes:

- Finanzas y banca: aprobación de préstamos/tarjetas de crédito, detección de fraudes, correlaciones entre indicadores financieros, análisis de riesgos crediticios.
- Telecomunicaciones: patrones de llamadas, modelos de carga de redes.
- Seguros y salud privada: determinación de potenciales clientes, predicción de nuevas pólizas, predicción de patrones de comportamiento para clientes con riesgo, identificación de comportamiento fraudulento.
- Ventas: segmentación del mercado, análisis de la cesta del mercado, mejorar el marketing, análisis de tendencias, rotación de clientes y diseño y promoción de sitios web.
- Educación: captación de estudiantes, detección de deserción y fracasos, estimación de permanencia de estudios.
- Medicina: identificación de patologías, detección de pacientes con riesgo de sufrir alguna patología, gestión hospitalaria.
- Biología y otras ciencias: análisis de secuencias de genes y proteínas, predecir compuestos químicos cancerígenos, clasificación de cuerpos celestes.
- Otros campos y aplicaciones.

En muchas ocasiones, la Minería de Datos es conocida como KDD, por sus siglas en inglés de «Knowledge Discovery in Databases», cuyo significado en español es Descubrimiento de Conocimiento en Bases de Datos (Hernández Orallo et al., 2004). Sin embargo, la Minería de Datos, es parte del proceso del KDD, que incluye diferentes tareas como: la inferencia de algoritmos, exploración de los datos, desarrollo de modelos descriptivos o predictivos y el descubrimiento de patrones desconocidos (Maimon y Rokach, 2010; Zaki y Meira, 2014).

## 2.2 Procesos del KDD

El KDD es un proceso que permite la realización de diferentes tareas como: el análisis, el modelado automático y exploratorio de grandes repositorios de datos. Este proceso incluye 5 etapas bien definidas, y que pueden ser observadas en la Figura 2.

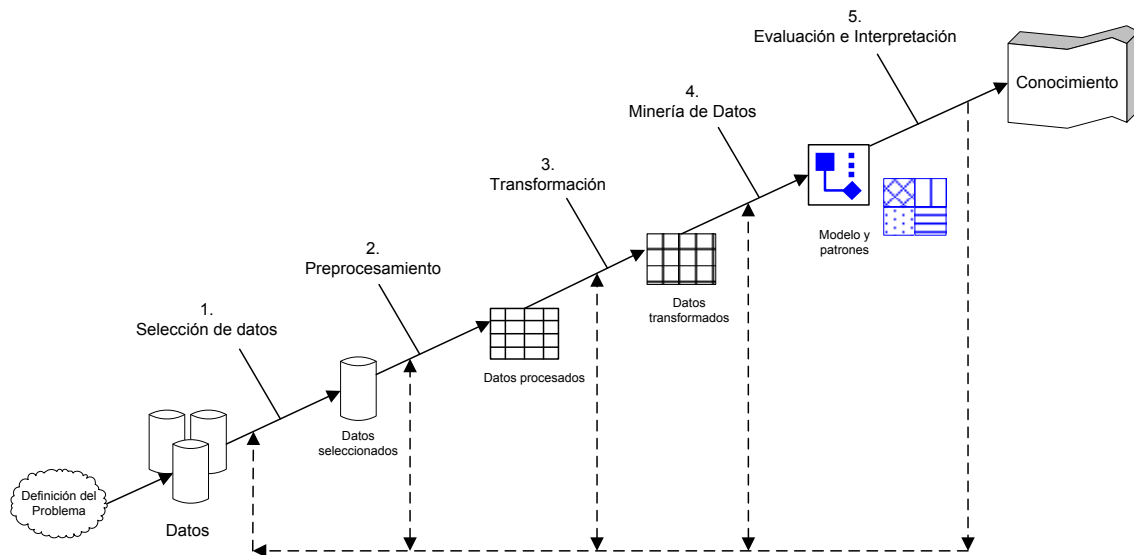


Figura 2 – Proceso del descubrimiento del conocimiento en bases de datos – KDD

Cada una de las etapas del KDD (Bhatia, 2019; Hernández Orallo et al., 2004; Kantardzic, 2020; Maimon y Rokach, 2010) son brevemente descritas a continuación:

1. Selección de datos: esta fase incluye identificar los datos disponibles, obtener datos adicionales necesarios y luego integrarlos en un solo conjunto, que incluya los atributos a ser considerados para el proceso y el posterior descubrimiento del conocimiento.
2. Preprocesamiento: el preprocesamiento incluye la limpieza de los datos, como el manejo de valores faltantes y la eliminación de ruido o valores atípicos. En esta etapa, se mejora la confiabilidad de los datos.
3. Transformación: los métodos empleados en la transformación incluyen la reducción de dimensiones, tanto la selección y extracción de características y el muestreo de registros, así como la transformación de atributos, como la discretización y la transformación funcional. De esta etapa depende el éxito de todo el proyecto KDD, pero suele ser muy específico del proyecto. En esta etapa se prepara y desarrolla la generación de los mejores datos, previa la etapa de la Minería de Datos.
4. Minería de Datos: proceso esencial donde se aplican métodos inteligentes para extraer patrones de datos. La técnica a ser utilizada depende del objetivo del KDD y de las fases previas. Los objetivos del KDD que permiten determinar su aplicabilidad pueden ser descriptivos o predictivos.
5. Evaluación e interpretación: Se utilizan técnicas de visualización y representación, para presentar el conocimiento extraído a los usuarios. Esta etapa permite identificar los patrones útiles que representan el conocimiento basado en medidas de interés.



### 2.3 Técnicas de Minería de Datos

Existen diferentes métodos de Minería de Datos utilizados para distintos propósitos y objetivos; por lo que se requiere una taxonomía para facilitar la comprensión de la diversidad de métodos, su interrelación y agrupación (Maimon y Rokach, 2010). Para una mejor comprensión de los métodos utilizados y su aplicación, se expone una representación del paradigma de la Minería de Datos en la Figura 3.

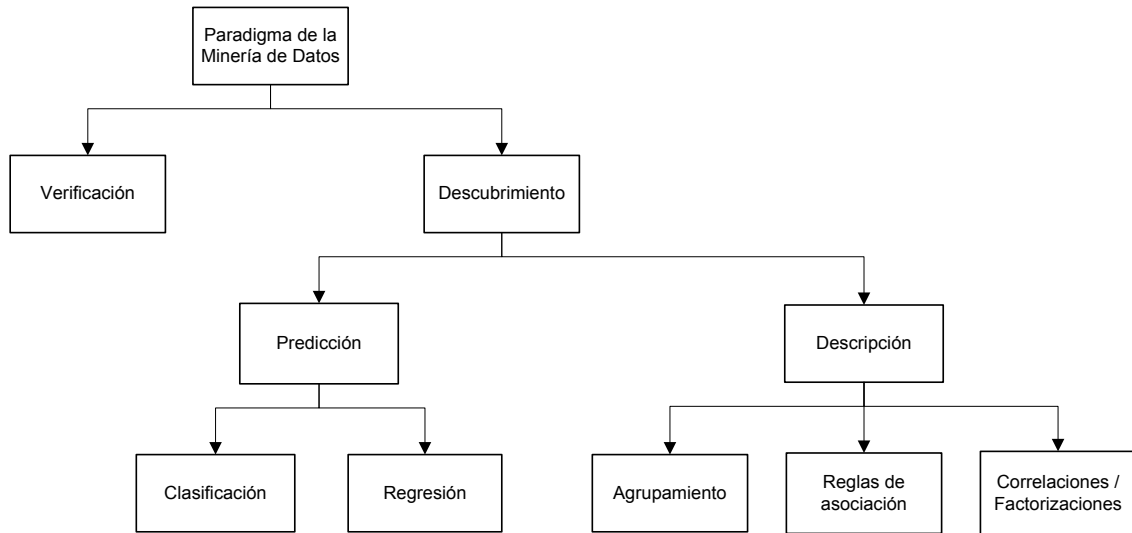


Figura 3 – Paradigma de la Minería de Datos

A partir de la Figura 3, se describen brevemente los conceptos de cada una de las orientaciones del paradigma de la Minería de Datos (Hernández Orallo et al., 2004; Maimon y Rokach, 2010):

1. Minería orientada a la verificación: Los métodos de verificación evalúan una hipótesis propuesta por una fuente externa, por ejemplo, un experto en el área. Estos métodos incluyen la estadística tradicional, como la prueba de bondad de ajuste, las pruebas de hipótesis (prueba t de media) y el análisis de varianza (ANOVA).
2. Minería orientada al descubrimiento: Los métodos de descubrimiento identifican automáticamente nuevas reglas y patrones en los datos. El descubrimiento de patrones incluye métodos predictivos y descriptivos.

La mayoría de las técnicas de Minería de Datos orientadas al descubrimiento, se basan en el aprendizaje inductivo, particularmente técnicas cuantitativas; donde un modelo se construye explícita o implícitamente, generalizando a partir de un número suficiente de ejemplos de entrenamiento. La suposición implícita del enfoque inductivo es que, el modelo entrenado se aplica a ejemplos no analizados.

- Modelos predictivos: los modelos predictivos realizan estimaciones de valores futuros o desconocidos, denominamos variables objetivo o dependientes. Estos modelos usan otras variables o campos de la base de datos, referidas como variables independientes o predictivas. Los métodos orientados a la predicción tienen como objetivo construir automáticamente un modelo de comportamiento, para obtener nuevas muestras e inéditas, con la capacidad de predecir valores de una o más variables relacionadas con la muestra. Los métodos predictivos desarrollan patrones que forman el conocimiento descubierto, de una manera comprensible y fácil de operar. Los modelos predictivos emplean tareas de clasificación, regresión, detección de anomalía o valores atípicos.
- Modelos descriptivos: estos modelos identifican patrones que explican o resumen los datos, es decir, permiten identificar las propiedades de los datos examinados, se identifican categorías o grupos de acuerdo con las características; pero sin realizar predicciones. Los métodos descriptivos están orientados a la interpretación de datos, enfocados en la comprensión de los datos subyacentes interrelacionados con sus partes. Los modelos descriptivos incluyen tareas de agrupamiento, reglas de asociación, análisis correlacional y patrones secuenciales.

Debido a que la Minería de Datos está relacionada con diferentes dominios, es posible asociarla con ideas como: muestreo, estimación, prueba de hipótesis, algoritmos de búsqueda, técnicas de modelado y optimización, computación evolutiva, procesamiento de señales, recuperación de información, Aprendizaje Automático, reconocimiento de patrones, entre otras (Tan et al., 2014). Por lo que, la Minería de Datos emplea diferentes técnicas y algoritmos según el área de estudio y el problema que se pretende resolver.

Por la orientación del presente trabajo, es importante destacar el área del Aprendizaje Automático, y la tarea de clasificación que le corresponde, de acuerdo al tipo de aprendizaje (Bhatia, 2019; Müller y Guido, 2016; Tan et al., 2014). Ver Figura 4.

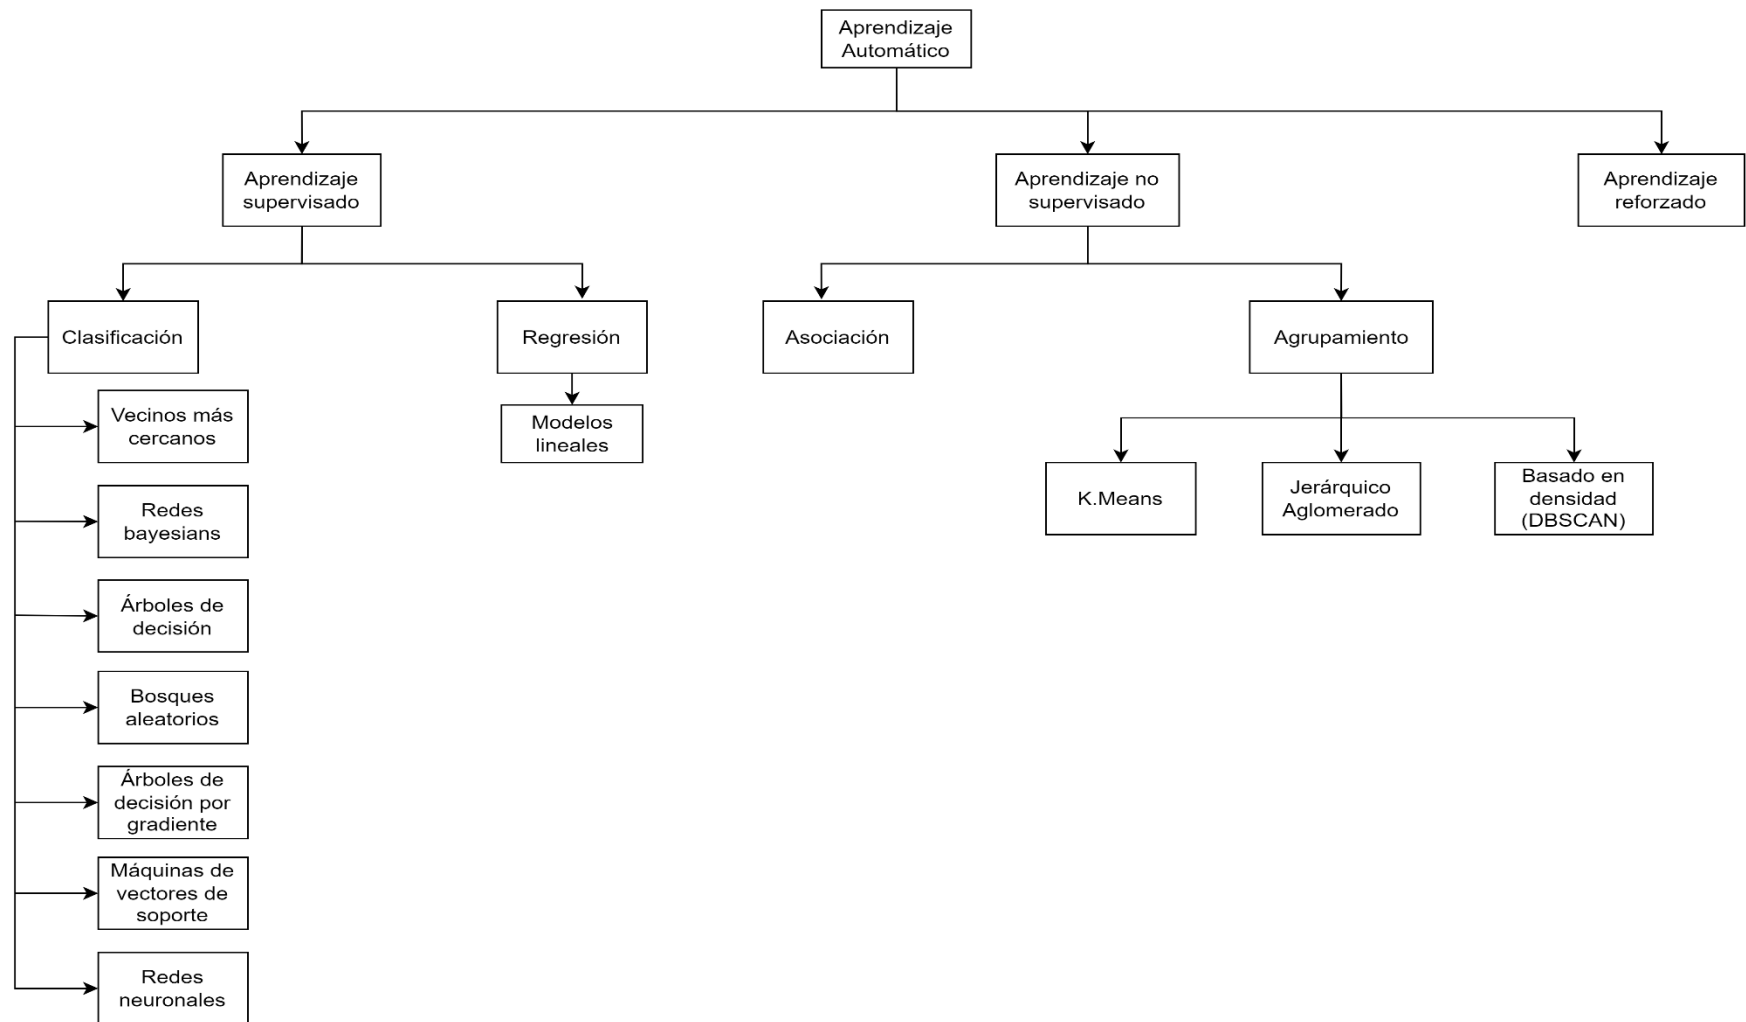


Figura 4 – Clasificación del Aprendizaje Automático

A partir de la Figura 4, se describen brevemente el concepto de los temas que incluye el Aprendizaje Automático (Bhatia, 2019; González, 2018; Janiesch et al., 2021; Nabeel et al., 2021; Tan et al., 2014):

### 2.3.1 Aprendizaje supervisado

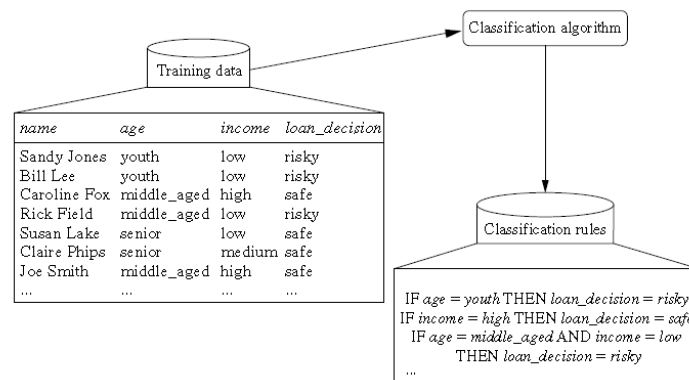
El aprendizaje supervisado, pretende descubrir la relación entre los atributos de entrada, denominados como variables independientes; y un atributo objetivo, conocido como variable dependiente (Bhatia, 2019). El aprendizaje supervisado requiere de un conjunto de datos de entrenamiento que contenga ejemplos para la entrada, así como respuestas etiquetadas o valores objetivo para la salida (Goodfellow et al., 2016; Janiesch et al., 2021). Esta relación descubierta se representa en una estructura denominada modelo (Maimon y Rokach, 2010). Este modelo es entrenado con los datos iniciales y puede ser utilizado para predecir el valor objetivo, a partir de nuevos valores de entrada. En este tipo de aprendizaje se destacan dos tareas, que son descritas a continuación:

#### 2.3.1.1 Clasificación

La tarea de clasificación consiste en el descubrimiento de una función de aprendizaje predictivo, que clasifica elementos de datos en una de las diferentes clases predefinidas (Goodfellow et al., 2016; Kantardzic, 2020), es decir predicen un valor discreto o una clase.

Diferentes investigaciones sobre Minería de Datos han desarrollado técnicas escalables de clasificación y predicción, capaces de manejar grandes cantidades de datos, mediante métodos de clasificación como el reconocimiento de patrones y estadísticas.

Entre las aplicaciones de tareas de clasificación, se encuentran: la detección de fraudes, el marketing dirigido, la predicción del rendimiento, la manufacturación, el diagnóstico médico, entre otras. Un ejemplo de clasificación se puede mostrar en la Figura 5 (Han et al., 2011).



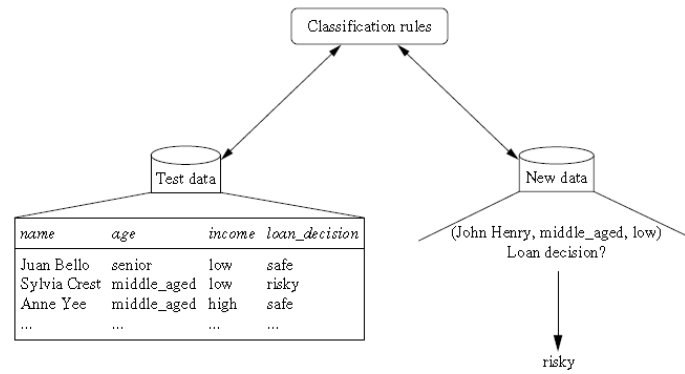


Figura 5 – Ejemplo de una regla de clasificación

Los problemas de clasificación pueden ser de dos tipos: binarios o multiclase. En la clasificación binaria, el atributo objetivo tiene dos valores posibles; mientras que, en la clasificación multiclase, el atributo de destino puede tener más de dos valores (Bhatia, 2019). Existen dos tipos de tareas de clasificación que a continuación son mencionados:

- Clasificación posteriori: las clases objetivo ya se conocen, es decir, los datos de entrenamiento ya están etiquetados con respuestas reales; es una aproximación al aprendizaje de máquina supervisado.
- Clasificación A priori: tiene un enfoque no supervisado, donde no existen clases destino. Aunque los datos no están etiquetados, se pueden realizar predicciones basadas en datos, aplicando primeramente el agrupamiento, seguido de la clasificación.

Las tareas de clasificación utilizan diferentes algoritmos, entre los cuales se describen algunos ejemplos:

- Vecinos más cercanos «K-Nearest Neighbors» (KNN): es el algoritmo más básico del Aprendizaje Automático. Es considerado como un algoritmo paramétrico, basado en instancias. Su principal aplicación es el reconocimiento de patrones, la Minería de Datos y la detección de intrusos (González, 2022a).
- Redes bayesianas «Bayesian Network»: representan el conocimiento cualitativo de un modelo, a través de un grafo dirigido acíclico; además expresan de forma numérica las relaciones entre las variables (Hernández Orallo et al., 2004).
- Árboles de decisión «Decision Tree»: conjunto de condiciones organizadas en forma jerárquica; es decir, aprenden una jerarquía de preguntas si/sino, lo que permite la toma de decisiones (Müller y Guido, 2016). Es aplicado para tareas que combinen datos numéricos y categóricos (Hernández Orallo et al., 2004).

- Bosques aleatorios «Random Forest»: es una clase de conjunto de métodos diseñados específicamente para clasificadores de árboles de decisión (Tan et al., 2014), resolviendo el problema del sobreajuste a los datos de entrenamiento (Müller y Guido, 2016).
- Árboles de decisión por gradiente «Gradient Boosted Regression Trees»: es un conjunto de métodos que combina múltiples árboles de decisión para crear un modelo más robusto. La diferencia con el bosque aleatorio, es la construcción de árboles en serie, donde cada árbol intenta corregir los errores del anterior, sin utilizar árboles muy profundos; lo que genera un modelo más pequeño en términos de memoria y realiza predicciones más rápidas (Müller y Guido, 2016).
- Máquinas de vectores de Soporte «Support Vector Machines» (SVM): un método de clasificación, cuyo objetivo es encontrar el hiperplano óptimo que maximiza el margen entre las clases (Zaki y Meira, 2014).
- Redes Neuronales «Neural Networks» (NN): las NN aparecen como una tecnología diseñada para resolver problemas en diferentes campos como: ciencias neuronales, matemáticas, estadística, física, informática, ingeniería, biología, entre otras. Las NN se aplican en modelado, análisis de series temporales, reconocimiento de patrones, procesamiento de señales, teoría de control, entre otras. Su principal característica es la capacidad para aprender a partir de datos de entrenamiento. A diferencia de otras técnicas como los árboles de decisión, el procesamiento de la información se realiza según el principio de la caja negra (Gorunescu, 2011; Tan et al., 2014).

### 2.3.1.2 Regresión

La tarea de regresión permite realizar el descubrimiento de una función de aprendizaje predictivo, donde, la variable objetivo a estimar es continua (Tan et al., 2014). La regresión permite el ajuste de datos, elimina el ruido y suaviza el conjunto de datos mediante ecuaciones matemáticas. La regresión lineal es uno de los métodos más utilizados, cuyo objetivo es hallar la línea más adecuada para ajustar los valores de dos variables o atributos. El propósito principal es la predicción del valor de otra variable, usando la primera. De forma similar, la regresión múltiple se usa cuando hay más de dos variables involucradas (Bhatia, 2019). En este tipo de tareas, se utilizan diferentes algoritmos, que son enunciados a continuación (González, 2022b):

- Regresión lineal: es una técnica paramétrica, que permite predecir variables continuas y dependientes, en base a un conjunto de variables independientes.

- Regresión no lineal: conocida como regresión polinomial y es similar a la regresión lineal; la diferencia está relacionada con la forma en que se considera el espacio de las características. Se requiere implementar polinomios de grado  $n$  para obtener el modelo.

### 2.3.2 Aprendizaje no supervisado

El aprendizaje no supervisado, supone que el sistema de aprendizaje detecta patrones sin etiquetas preexistentes. Por lo que, los datos de entrenamiento solo consisten en variables, con el objetivo de encontrar información estructural de interés, como grupos de elementos que comparten propiedades comunes. El aprendizaje no supervisado contempla métodos de agrupamiento pero no métodos de visualización (Janiesch et al., 2021; Maimon y Rokach, 2010).

#### 2.3.2.1 Asociación

Las reglas de asociación representan un conjunto de metodologías relativamente nuevas según Kantardzic (2020), que incluyen algoritmos como: el análisis de la cesta de la compra, el algoritmo «A priori» y los patrones transversales de la ruta WWW; aunque es importante señalar que «A priori» es considerado un algoritmo pionero en reglas de asociación, y se ha utilizado desde años atrás (Agrawal et al., 1993; Rocha Hernández et al., 2016).

Las tareas de asociación, son tareas descriptivas, que se puede definir como la identificación de patrones frecuentes, correlaciones, asociaciones o estructuras causales entre conjuntos de objetos o elementos en bases de datos transaccionales, bases de datos relacionales y otros depósitos de información (Bhatia, 2019; Hernández Orallo et al., 2004). Entre las aplicaciones de las tareas de asociación se encuentran: marketing, segmentación de clientes, minería web, medicina, aprendizaje adaptativo, finanzas y bioinformática, entre otras.

Las reglas de asociación son generalmente declaraciones si/entonces que ayudan a descubrir relaciones entre datos aparentemente no relacionados. Por ejemplo, "Si un cliente compra pañales, es probable que también compre leche". Ver Figura 6.

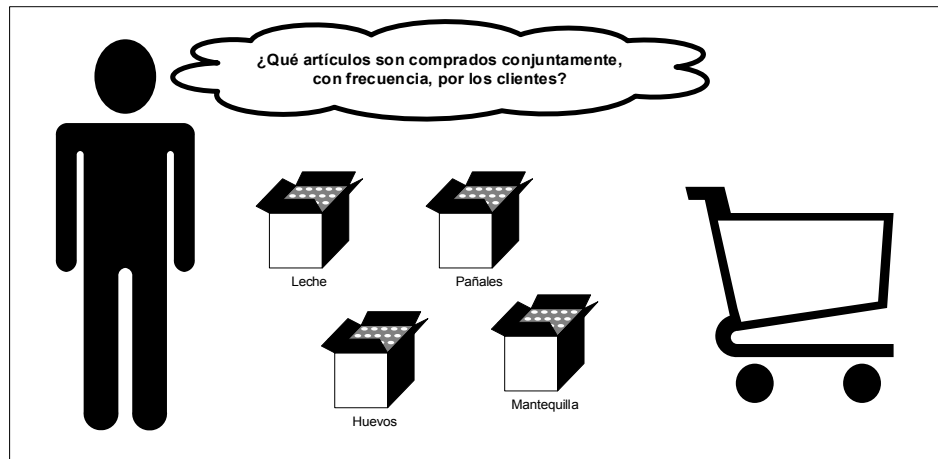


Figura 6 – Ejemplo de reglas de asociación

### 2.3.2.2 Agrupamiento

A diferencia de las tareas de clasificación y regresión, que analizan conjuntos de datos etiquetados, el agrupamiento analiza los datos sin utilizar las etiquetas de clase, ya que es posible que, los datos etiquetados no existan en principio (Han et al., 2011). En el caso de grandes conjuntos de datos, los datos no se etiquetan, porque etiquetar una gran cantidad de registros requiere mucho esfuerzo humano (Bhatia, 2019).

Los objetos se agrupan según el principio de maximizar la similitud intraclassa y minimizar la similitud interclase, de forma que, los objetos dentro de un grupo tengan similitud entre sí, pero son diferentes a los objetos de otros grupos. El agrupamiento facilita la formación de taxonomías de clases que agrupa datos similares (Bhatia, 2019; Han et al., 2011). Entre los algoritmos que permiten realizar agrupamiento se pueden describir los siguientes:

- «K-Means»: es uno de los algoritmos de agrupamiento más antiguos y utilizados. Es una técnica de agrupamiento particional basada en prototipos que intenta encontrar un número de clústeres (K) especificado por el usuario, que están representados por sus centroides (Tan et al., 2014). Un centroide es el punto representativo de cada clúster.
- Jerárquico Aglomerado «Agglomerative Hierarchical Clustering»: se refiere a una colección de técnicas de agrupación fuertemente relacionadas, que producen una agrupación jerárquica, repiten la fusión de los grupos más cercanos hasta que quede un único grupo (Tan et al., 2014).
- «DBSCAN»: es un algoritmo de agrupamiento basado en densidad, que produce un agrupamiento particional, donde el algoritmo determina de forma automática el número de grupos. Los puntos en regiones de baja densidad son considerados como



ruido y se omiten; por tanto, DBSCAN no produce una agrupación completa (Tan et al., 2014).

### 2.3.3 Aprendizaje reforzado

En un sistema de aprendizaje por refuerzo, se describe el estado actual del sistema, se especifica el objetivo, las acciones permitidas y restricciones del entorno. El modelo de Aprendizaje Automático experimenta el proceso hasta alcanzar el objetivo, utilizando el principio de prueba y error para maximizar una recompensa; es decir, la máquina aprende por su cuenta (Janiesch et al., 2021).

### 2.3.4 Aprendizaje Profundo

El aprendizaje profundo o «Deep Learning» (DL), es un concepto que surge en el año 2006 (Vargas et al., 2017) y es considerado un tipo particular de Aprendizaje Automático (González, 2018; Goodfellow et al., 2016; Janiesch et al., 2021; Vargas et al., 2017). El aprendizaje profundo implica un análisis de capas abstractas y métodos jerárquicos, que comprende múltiples capas ocultas de redes neuronales artificiales (Janiesch et al., 2021; Vargas et al., 2017). En otras palabras, el aprendizaje profundo puede entenderse como: un método para mejorar los resultados y optimizar los tiempos de procesamiento en varios procesos informáticos.

## 2.4 Redes Sociales

### 2.4.1 Origen de las redes sociales

Las redes sociales tuvieron sus orígenes en el año 1995, con el sitio web classmates.com, creado por Randy Conrads (García, 2015). Este sitio permitía mantener el contacto con antiguos compañeros de colegio o universidad. Antes de adoptar el nombre de redes sociales, a estas plataformas se les denominaban comunidades virtuales. No obstante, la primera red social reconocida como tal, fue Sixdegrees.com, creada en el año 1997. Entre las funcionalidades de esta red social era la creación de perfiles y la posibilidad de listar amigos; sin tomar en consideración el vínculo preexistente (Bueno Delgado y Pavón Mariño, 2011). Ver Figura 7.



Figura 7 – Logotipo SixDegrees

Pero no fue hasta el año 2003 que el verdadero comienzo de las redes sociales se produjo, con la aparición de Myspace. Con esta red social existió la posibilidad de crear páginas personales de forma gratuita y relacionarse con otros usuarios (García, 2015). Ver Figura 8.



Figura 8 – Logotipo MySpace

Aunque MySpace logró captar la atención de la mayoría de los medios en EE. UU. y en el extranjero, los servicios de redes sociales se proliferaron y alcanzaron gran popularidad en todo el mundo; por ejemplo, Hi5 fue adoptado en países más pequeños de América del Sur y Europa. En este mismo campo, los servicios de blogs con la funcionalidad de mensajería, alcanzaron gran fama (Boyd y Ellison, 2007).

En los años siguientes, aparecieron otras redes sociales como Facebook, que surgió a principios de 2004, como una red social de uso exclusivo de Harvard; pero en el año 2005, se expandió para incluir a estudiantes de secundaria, profesionales dentro de redes corporativas, y de forma eventual a los demás usuarios (Boyd y Ellison, 2007).

Otra red social que surgió en octubre de 2006 fue Twitter, o también conocida también como microblogging (Ha et al., 2014), con el objetivo de permitir a las personas publicar estados llamados tweets o mensajes cortos de máximo 140 caracteres, hoy en día hasta 280 (Cano, 2017).

Según el Reporte Global realizado por HootSuite (2022), para enero de 2022, el ranking de vistas de páginas web y aplicaciones más usadas a nivel mundial, las redes sociales ocupan el segundo puesto con el 95,2% de interés por parte de personas de entre 16 y 64 años de edad; donde, Facebook, YouTube, WhatsApp, Instagram y WeChat, lideran las estadísticas de mayor uso de redes sociales. Ver Figura 9.



Figura 9 – Redes sociales

### 2.4.2 Definición de las redes sociales

En los años 50, los antropólogos británicos se referían a las redes sociales como espacios para establecer vínculos entre conjunto de personas; otros, las consideraban como redes de apoyo, formales e informales (Espinar Ruiz y González Río, 2009).

Desde el punto de vista sociológico, una red social es considerada un sistema abierto y en continua construcción a medida que existe la interacción social. Se dice que, una red social se fundamenta en el intercambio dinámico entre personas, grupos o instituciones con necesidades y preferencias similares (García, 2015).

Según otros autores, las redes sociales son identificadas como: un servicio basado en la web que permiten a las personas: a) construir un perfil público o semipúblico en un entorno delimitado; b) relacionar una lista de contactos con los que comparte información; y c) mirar y explorar su lista de conexiones y de sus contactos dentro del entorno (Ayala, 2017; Bueno Delgado y Pavón Mariño, 2011).

Para definir una red social, Obar y Wildman (2015) sintetizan algunas definiciones previas realizadas en su investigación, y que, de acuerdo con los servicios que ofrece, se describen a continuación:

- El servicio de una red social se basa en la aplicación Web 2.0.
- El corazón de una red social es la generación de contenido.
- Personas y grupos crean perfiles de usuarios específicos para un sitio.
- Personas y grupos diseñan una aplicación, sustentada por el servicio de la red social.
- Las redes sociales facilitan la conexión de perfiles con otras personas o grupos.

Aunque no existe una concepto único, con las definiciones descritas anteriormente, las redes sociales, o también conocidas como medios sociales (Aichner et al., 2021), se las puede definir como: un servicio que permite la conexión y comunicación con otras personas, no basadas únicamente en temas específicos, sino con una visión más amplia.

### 2.4.3 Clasificación de las redes sociales

De la misma forma que no existe una definición única sobre redes sociales, tampoco existe una clasificación exclusiva que permita catalogar los diferentes espacios virtuales; sin embargo, diferentes autores han intentado clasificarlas desde distintas perspectivas.

Area (2008) por ejemplo, clasifica las redes sociales en 3 grandes grupos, aunque manifiesta que su delimitación puede ser difusa:

### 2.4.3.1 Redes de propósito general

Para formar mega comunidades, entre las que se encuentran Facebook, MySpace, Twitter.

- Redes para compartir archivos: usadas para compartir videos, fotografías, presentaciones, entre las que se puede mencionar a YouTube, Flickr, SlideShare.
- Redes temáticas: para comunidades pequeñas o de interés específico, como Ning, Google Groups, Elgg.

Por su parte, INTECO y AEPD (2009), catalogan las redes sociales de acuerdo con el público objetivo o por su contenido. De esta forma, se identifican dos principales grupos: a) redes sociales generales o de ocio; y b) redes profesionales.

### 2.4.3.2 Redes sociales generales o de ocio

Estas redes facilitan o promueven las relaciones personales entre los miembros. En este grupo se puede establecer una subclasificación:

- Redes para intercambio de contenido e información: en este grupo estarían inmersas plataformas como YouTube, Google Video, Flickr, etc.
- Redes basadas en perfiles: Facebook, Tuenti, Wamba, etc.
- Redes de microblogging: Twitter, Yammer, etc.

### 2.4.3.3 Redes profesionales

Estas redes permiten establecer contactos profesionales con otros usuarios, como LinkedIn. Según Caldevilla Domínguez (2010) existe un panorama interactivo, que permite establecer una tipología de las redes sociales con 5 grandes grupos:

- Redes sociales de uso general: entre las que se incluyen Facebook Twitter, Netlog, Ning, Hi5.
- Redes sociales de fans: se incluyen aficionados por temas, como: Xbox Live, Bloogges, NVivo, Myspace, Dejaboo, Mysofa, Kindo, minube, Servifutbol, etc.
- Redes sociales de estados vitales: de acuerdo con la edad del usuario, como: Tuenti, Wamba, Vi.vu, Mapalia, etc.
- Redes sociales de contenidos: Flickr, Fotolog, Menéame, YouTube, etc.
- Redes profesionales y activistas: LinkedIn, Tuplanet, ideas4all, Domestika, NotasWeb, Xing, etc.

Con la información que antecede, es evidente que no existe un consenso que delimite claramente la clasificación de las redes sociales; sin embargo, de acuerdo con la información provista, es posible identificar los principales usos de acuerdo con el objetivo propuesto y que son descritos en el siguiente epígrafe.

#### 2.4.4 Aplicación de las redes sociales

Según Pertegal-Vega et al. (2019), entre las principales aplicaciones y usos de las redes sociales, están consideradas las siguientes necesidades:

- Necesidades sociales: como el mantenimiento del contacto, el establecimiento de nuevas relaciones o la búsqueda de reconocimiento social.
- Necesidades individuales: la hedonista y de regulación del humor. En especial, la búsqueda de sensaciones positivas, entretenimiento o pasatiempo.
- Necesidad de información: acceso a la información, curiosidad de saber sobre lo que ocurre en general o respecto de alguna persona en concreto.
- Necesidad de desarrollo de la identidad personal: aunque es menos frecuente, incluye motivos de validación personal, autoexpresión de sentimientos u opiniones.

Los principales usos de las redes sociales según HootSuite (2022), son descritos en la Figura 10.




Figura 10 – Uso de las redes sociales.

Como se observa en la Figura 10, el enfoque de carácter social es el aspecto que más destaca en la aplicación y uso de las redes sociales.

Basado en trabajos previos, Caldevilla Domínguez (2010) identifica 4 principales usos de las redes sociales, que se describen a continuación:

- Mantenimiento de amistades: seguir en contacto con compañeros de trabajo o amigos de colegio o universidad.
- Creación de nuevas amistades: contactar nuevas personas de ciudades o países diferentes.
- Entretenimiento: permiten visualizar el perfil de otros usuarios, actualizar estados.
- Gestión interna de empresas: cuyo objetivo es agilizar trámites, comunicación, conferencias, informes; o a su vez mantener contacto con profesionales del sector.

La investigación realizada por Matassi y Boczkowski (2020) sobre las tendencias de uso de las redes sociales en Iberoamérica, destacan cuatro principales ámbitos en las que éstas plataformas están inmersas:

- Comunicación política y gobierno electrónico: uso de las redes sociales para campañas electorales; interacción con la comunidad, ciudadanía o electorado; medir tendencias electorales; discursos populistas.
- Periodismo y medios tradicionales: las redes sociales son utilizados como medio de comunicación con el público; como fuente de información; para realizar reportajes; acceso a noticias.
- Grupos sociales y áreas de uso: en este ámbito se identifican 7 grupos sociales (adolescentes y jóvenes, marginados, mujeres, empresarios, «influencers», estudiantes y adultos); además existen 5 áreas investigadas: comercio, turismo, educación, salud y comunicación profesional.
- Participación política y cívica: redes sociales utilizadas con el objetivo de promover protestas, movilizaciones, el activismo; para realizar peticiones económicas, exigir libertad política, y también se incluye circulación de discursos de odio y desinformación.

Como se ha descrito anteriormente, no existe una clasificación única de las redes sociales y su uso dependerá del objetivo que se desee alcanzar, del contexto en que se desarrolle y de los actores que intervienen.

### 2.4.5 Las redes sociales en la educación

Considerando el enfoque realizado por Matassi y Boczkowski (2020), las redes sociales en la educación, estarían inmersas en la temática de grupos sociales y áreas de uso.

La influencia de las redes sociales en el proceso de aprendizaje, no se considera una primicia (Santoveña-Casal y Bernal-Bravo, 2019); pero han sido una fuente de investigación continua en la comunidad científica (Chávez Márquez y Gutiérrez Diez, 2015), y según Salinas Lozano (2021), en el año 2020 se produjo un incremento notable de investigaciones, debido al confinamiento derivado de la COVID-19, y que obligó al cambio del modelo educativo, pasando de lo presencial a lo virtual; por lo que, las publicaciones han estado en continuo crecimiento (Gil-Fernández y Calderón, 2021).

No obstante, en el Reporte Global de HootSuite (2022), las principales razones para el uso del Internet, posiciona a la educación y temas afines en el puesto 10 de 19, con un 42,3% a nivel mundial; además, entre los usos que se da a las redes sociales, el campo de la educación no fue considerado como parte del estudio; por tanto, se puede evidenciar que, las redes sociales no están totalmente inmersas en la educación, a pesar de los beneficios que han demostrado tener en la academia (Gil-Fernández y Calderón, 2021; Matosas-López et al., 2021).

En la revisión sistemática realizada por Gil-Fernández y Calderón (2021), existen cinco categorías en las que se fusionan las redes sociales y la educación:

- Competencia digital y competencia digital docente.
- Creación de entornos virtuales y comunidades educativas.
- Recurso didáctico para los procesos de enseñanza y aprendizaje.
- Movimientos y reivindicaciones sociales en el ámbito educativo.
- Dilemas éticos, adicciones y otros problemas derivados del uso de las redes sociales en el aula.

Se ha evidenciado que, el uso de redes sociales como Facebook, Instagram, Twitter, Google+ en el contexto educativo, fortalece o genera el aprendizaje colaborativo, el cual constituye un requisito básico del modelo constructivista del aprendizaje, y que, dadas las prácticas de enseñanza y aprendizaje actuales, los actores de la educación recomiendan este enfoque, debido a su capacidad para involucrar a los estudiantes y mejorar los resultados del aprendizaje (Saini y Abraham, 2019).

En el área educativa, las redes sociales más utilizadas son Twitter, Facebook, WhatsApp, YouTube e Instagram (Salinas Lozano, 2021); entre las que se destacan las dos primeras en este

campo (Chávez Márquez y Gutiérrez Diez, 2015; Ruiz Bolívar, 2016; Sánchez Rodríguez et al., 2015; Tur et al., 2017).

Dado que el presente trabajo se desarrolla en el ámbito de la educación superior, se procede a la descripción de las redes sociales Facebook y Twitter, como las plataformas de mayor uso en las diferentes investigaciones (Barreto y Jimenez, 2010; Lambert y Smith, 2014).

#### 2.4.5.1 Facebook

Facebook ha revolucionado la forma en que las personas se comunican e interactúan; por ejemplo, en el área de la educación, la comunidad se ha beneficiado en la interrelación docente-estudiante y estudiante-estudiante, promoviendo el aprendizaje colaborativo, permitiendo a los usuarios compartir, colaborar y formar conexiones sociales (Chugh y Ruhi, 2018; Llorens Cerdà y Capdeferro Planas, 2011).

Debido a la popularidad de Facebook entre los estudiantes universitarios, es imperativo que, tanto los actores de la educación, así como la comunidad científica, orienten sus investigaciones en identificar la utilidad de esta red social, como medio de comunicación y aprendizaje. Además, muchos estudios han demostrado su potencial, para motivar a los estudiantes a aprender e influir en los resultados del aprendizaje cognitivo y afectivo (Delgado-García et al., 2018; Saini y Abraham, 2019).

Sancar et. al. (2021) demuestran que, Facebook puede ser utilizado con uno de los mejores sistemas de gestión de aprendizaje «Learning Management Systems» (LMS) para la educación superior. Otros estudios han destacado los múltiples beneficios del uso de Facebook en los diferentes procesos de enseñanza y aprendizaje como: mejorar el rendimiento académico, incrementar o fomentar la participación estudiantil (Chugh y Ruhi, 2018; Keles, 2018). Sin embargo, también existen estudios que se contraponen, y destaca los posibles problemas y limitaciones del uso de Facebook, como la falta de dominio por parte de los docentes, la preocupación por la privacidad, el exceso de uso por parte de los estudiantes, y la distracción que puede generar esta red social debido al contenido que se puede encontrar (Leung et al., 2022).

#### 2.4.5.2 Twitter

“Twitter es lo que está pasando y de lo que las personas están hablando en este momento”, es el slogan en el sitio web de la empresa (TWITTER, 2022e).

Twitter, también conocido como microblogging; tiene como característica principal, publicar mensajes cortos, eventos, situaciones, sentimientos, opiniones, todo esto en tiempo real, a



través de diferentes canales de comunicación como la web, dispositivos móviles o mensajes instantáneos (Cetintas et al., 2011; Parselis, 2014; Yadraniaghdam et al., 2017).

#### 2.4.5.2.1 Usos de Twitter

De acuerdo con la revisión sistemática realizada por Ha et al. (2014) entre en 2012 y 2013, la tendencia de uso de la red social Twitter, se podía resumir en los siguientes puntos:

1. Los estudios están orientados en la aplicación, tendencia de uso y análisis de contenido de Twitter, como la tendencia de noticias en el periodismo (Arrabal-Sánchez y De-Aguilera-Moyano, 2016). Se realiza un análisis del flujo y contenido de los tweets.
2. Twitter se aplica en diferentes campos como: educación, política, economía, salud, prevención de desastres (Lambert y Smith, 2014; Toro Araneda, 2010); con el uso de grandes cantidades de datos.
3. Con base al contenido de los tweets, se posibilita la generación de «ranking», detección de «spam», detección de eventos; temáticas que son motivo de un análisis continuo.
4. Existen estudios que permiten la extracción de las relaciones entre usuarios, proveniente del flujo y contenido de los «influencers», usuarios expertos, seguimiento de relaciones; así como el impacto social de esta red social (Pejić Bach et al., 2020).
5. El principal campo está relacionado con Tecnologías de la Información y toma de decisiones en I+D+i (Díaz-Mendivelso y Suarez-Baron, 2019), donde, la mayor parte de autores pertenecen a instituciones estadounidenses, y los estudios se han incrementado desde el año 2007.

Debido al enfoque académico del presente trabajo y de acuerdo con las investigaciones realizadas por diferentes autores, se han sintetizado los principales usos de Twitter en la educación, tanto para la educación formal como para la informal, según se detalla en la Tabla 2.

Tabla 2 – Principales usos de Twitter

No.	Autor	Aporte
1	(Altrabsheh et al., 2015)	Predecir emociones relacionadas con el aprendizaje, utilizando técnicas de Aprendizaje Automático y n-gramas.
2	(Baviera, 2017)	Analizar los sentimientos de los estudiantes universitarios.
3	(Belanche Gracia et al., 2014)	Implantar Twitter para el aprendizaje colaborativo en red, que permita contribuir a la renovación de los procesos pedagógicos y la calidad del aprendizaje.
4	(Calabuigi Serra y Donaire Benito, 2012)	Presentar actividades educativas para integrar el entorno web 2.0 y las tecnologías móviles en la educación superior.

No.	Autor	Aporte
5	(Cetintas et al., 2011)	Presentar una aplicación para categorizar dos tipos de preguntas formuladas en el aula: preguntas relevantes y preguntas irrelevantes.
6	(Chawinga, 2017)	Incorporar Twitter y blogs en dos cursos de pregrado, para conocer la percepción sobre el uso de blogs y Twitter en el aula.
7	(Checa García, 2013)	Destacar el uso del microblogging y particularmente de Twitter, como herramienta tecno-social, que mejore las habilidades comunicativas y sociales en sistemas de aprendizaje informal.
	(Chen et al., 2014; Patil y Kulkarni, 2018)	Comprender cuestiones y problemas en experiencias educativas de estudiantes de ingeniería.
8	(Fernández-Ferrer y Cano, 2016)	Analizar una práctica de evaluación formativa entre pares a partir de una experiencia de innovación docente universitaria, permitiendo el involucramiento de los estudiantes; evaluación del desempeño en la asignatura; motivación y autopercepción del aprendizaje y del desarrollo competencial de los estudiantes.
9	(Froment et al., 2022)	Analizar las percepciones del alumnado universitario en relación con la credibilidad del profesorado universitario, de acuerdo con los tweets publicados en sus perfiles, y su efecto en la motivación.
10	(Gallardo-López y López-Noguero, 2020)	Analizar los principales resultados de un proyecto de innovación usando Twitter como recurso didáctico, metodológico colaborativo y colectivo en la educación superior; explorando el impacto de su uso y la percepción de los estudiantes como instrumento integrado en una metodología participativa.
11	(García Suárez et al., 2015)	Analizar una experiencia basada en la utilización de Twitter en la evaluación diaria del proceso de enseñanza y su repercusión en el alumnado.
12	(Graves y Ziaeehezjeribi, 2010)	Presentar los resultados cuantitativos y cualitativos de una modificación del Diseño Universal, a un entorno de aprendizaje combinado para difundir rápidamente información en el aula y proporcionar una diversidad de estilos de aprendizaje.
13	(Guzmán Duque et al., 2012)	Analizar el uso de Twitter en 20 universidades iberoamericanas. Destacándose la concepción como herramienta catalizadora del proceso de enseñanza-aprendizaje; y para dinamizar la participación e interacción con la comunidad educativa.
14	(Ha et al., 2013)	Comprender los efectos sobre la participación y las calificaciones de los estudiantes universitarios, mediante el uso de patrones como: construcción de comunidad, relaciones de colaboración e intercambio de información entre estudiantes.
15	(Hasan et al., 2014)	Desarrollar una herramienta para clasificar las emociones de los mensajes de Twitter.
16	(Hauff et al., 2012)	Inferir el estilo de aprendizaje de un alumno a partir de su flujo de Twitter.
17	(Jones, 2011)	Usar Twitter para que los estudiantes compartan sus ideas antes de asistir a las conferencias y debates en clase.

No.	Autor	Aporte
18	(Junco et al., 2011)	Determinar si el uso de Twitter con fines educativos, afecta la participación y las calificaciones de los estudiantes universitarios.
19	(Kassens-Noor, 2012)	Explorar la práctica docente de Twitter como una herramienta de aprendizaje activa, informal y fuera de clase; para determinar si el uso de Twitter ayuda a los estudiantes a aprender una materia en particular.
20	(Kimmons et al., 2017)	Recopilar y analizar las historias disponibles de las principales cuentas de Twitter de instituciones de educación superior en los <b>Los hallazgos sobre prácticas pedagógicas utilizadas</b> , para determinar los temas predominantes.
21	(Kimmons y Veletsianos, 2016)	Comprender el uso académico de Twitter durante, alrededor y entre las conferencias anuales.
23	(Lowe y Laffey, 2011)	Mejorar y facilitar el aprendizaje de conceptos de marketing, y reconocer la importancia del uso de tecnologías innovadoras.
26	(Moguel Marín et al., 2012)	Presentar una metodología para el uso del Twitter como plataforma de la metacognición; para promover su uso pedagógico en el nivel superior y recocer su potencial para el proceso de enseñanza-aprendizaje y que permita adquirir competencias.
27	(Pérez-Suasnavas et al., 2020b)	Proponer una estrategia educativa para mejorar la participación estudiantil en el aula, que permita minimizar los factores que limitan una participación activa, permitiendo un intercambio de ideas y generar un aprendizaje significativo.
28	(Pill et al., 2017)	Usar Twitter como herramienta de investigación en educación física, mediante el empleo de métodos mixtos.
29	(Rinaldo et al., 2011)	Identificar el beneficio de Twitter para los educadores de marketing para involucrar a los estudiantes en el aprendizaje experiencial; utilizando como herramienta de comunicación, de discusión, y generar interés en un curso.
30	(Roig-Vila y Álvarez Herrero, 2019)	Identificar el grado de repercusión y análisis de las relaciones que se establecieron entre los diferentes usuarios de Twitter sobre metodologías activas.
31	(Santoveña-Casal y Bernal-Bravo, 2019)	Analizar la influencia del rol del profesorado sobre la participación social en Twitter y la experiencia académica percibida de los estudiantes.
32	(Tang y Hew, 2017)	Comprender si la implementación de Twitter beneficiaría a los estudiantes, como medio de comunicación y evaluación.
33	(Toro Araneda, 2010)	Identificar los usos de Twitter como plataforma de microblogging, destacándose su aplicación en el aprendizaje formal e informal.
34	(Veletsianos y Kimmons, 2016)	Identificar el uso de Twitter por parte de los docentes y estudiantes, mediante el uso de hashtags y predicción de seguidores.
36	(Wakefield et al., 2011)	Generar el pensamiento reflexivo y comunicación basada en temas del aula; para aumentar el discurso entre los estudiantes y mejorar el aprendizaje.

No.	Autor	Aporte
37	(Welch y Bonnan-White, 2012)	Diseñar un estudio cuasiexperimental para probar el efecto de Twitter en la participación de los estudiantes en cursos de introducción a la sociología y la antropología.
38	(Zaina et al., 2014)	Utilizar Twitter para colaborar, comunicar e intercambiar ideas entre usuarios que comparten intereses comunes.

Aunque se evidencia una gran cantidad de aplicaciones de esta red social, también se citan algunas desventajas de su uso en la educación, como: en aulas con gran cantidad de estudiantes, se derivan muchas preguntas o comentarios que el instructor recibe (Cetintas et al., 2011); restricción del pensamiento crítico y autorreflexión por la limitación de caracteres (Kassens-Noor, 2012); los estudiantes no utilizan la red social con fines académicos (Sánchez Rodríguez et al., 2015); las distracciones que generan las redes sociales; además, requiere de una estrategia previa de implantación en el aula (Checa García, 2013);

## 2.5 Estrategias didácticas

Antes de realizar una descripción de las estrategias didácticas, es conveniente conceptualizar los diferentes términos relacionados, y que, en ocasiones se tiende a confundir con las nociones de metodología, método o técnica.

### 2.5.1 Definiciones

Una metodología educativa se refiere al método de enseñanza, con el que los docentes llevan a cabo su actividad diaria. Una metodología implica el uso de distintos recursos, herramientas, técnicas, métodos didácticos, procedimientos y las estrategias varían en cada caso; con el objetivo de afianzar los contenidos, motivar y dar sentido al conocimiento de diferentes formas (Forma Infancia, 2021; Touriñán López y Sáez Alonso, 2006; Universidad Europea, 2021). Las metodologías educativas suelen girar en torno a las teorías del aprendizaje, como el conductismo, cognitivismo, constructivismo y últimamente el conectivismo (Cengage, 2021).

Etimológicamente el método se le conoce como el camino lógico para conseguir algo, es decir, es la vía que conduce a un fin, donde el fin puede ser la enseñanza o el aprendizaje (Alcoba González, 2012; Salvador Mata y Gallego Ortega, 2009). El método implica pasos a seguir de forma ordenada y en un determinado tiempo, por tanto, el método está relacionado con el procedimiento; por ejemplo, se puede citar al método de lectura (Castelló et al., 1999).

La estrategia, o también llamada táctica en el contexto militar (Castelló et al., 1999; Méndez Hinojosa y González Ramírez, 2011), es una secuencia de actividades que el docente decide

como utilizar en el aula con una rigurosa planificación (Orlich et al., 2010; Salvador Mata y Gallego Ortega, 2009), es decir, una estrategia es una guía de acción, que orienta a la obtención de ciertos resultados (Méndez Hinojosa y González Ramírez, 2011), que son observables y medibles (Javaloyes Sáez, 2016).

De acuerdo con la investigación realizada por Fumero (2009) y Gutiérrez Tapias y García Cué (2016), una estrategia didáctica se encarga del procesamiento de los contenidos de enseñanza, para la constitución de la parte cognitiva y la metacognitiva del individuo.

Según Salvador Mata y Gallego Ortega (2009), el concepto de estrategia didáctica incluye, tanto estrategias de aprendizaje desde la perspectiva del estudiante, como las estrategias de enseñanza, desde la perspectiva del docente.

Una técnica se define como actividad fundamentada en conocimientos científicos, en otras palabras, es un “saber hacer” y se relaciona con el procedimiento, por la secuencia que debe seguir (Salvador Mata y Gallego Ortega, 2009). Una técnica puede ser utilizada sin la necesidad de tener un propósito de aprendizaje; a diferencia de la estrategia que siempre persigue un objetivo (Javaloyes Sáez, 2016); en ocasiones es considerada como sinónimo de procedimiento (Orlich et al., 2010).

Con el objetivo de tener una idea más clara, se citan algunos ejemplos que permiten diferenciar los términos método, estrategia y técnica, de acuerdo con el análisis realizado por Alcoba González (2012) y Monereo (1990). Ver Tabla 3.

Tabla 3 – Ejemplos de método, estrategia y técnica

Método	Estrategia	Técnica
Clase magistral	Representación gráfica	Hablar en público
Trabajo grupal	Comprensión lectora	«Brainstorming»
Prácticas de laboratorio	Análisis de textos	Ensayo
Lectura	Autoaprendizaje	Tareas individuales

Fuente: Adaptación de (Alcoba González, 2012; Monereo, 1990)

Por tanto, una estrategia didáctica se conoce como el conjunto de actividades, métodos y técnicas planificadas por el docente, con el propósito de que el estudiante alcance la construcción del aprendizaje y se consigan los objetivos planteados (Gutiérrez Tapias y García Cué, 2016; Ramírez, 2016).

### 2.5.2 Clasificación de las estrategias didácticas

Debido a la complejidad del proceso didáctico y las diferentes exigencias a las que debe responder la acción didáctica, es necesario optar por una variedad de estrategias metodológicas (Gutiérrez Tapias y García Cué, 2016; Salvador Mata y Gallego Ortega, 2009); por lo que, esta diversidad dificulta establecer una clasificación única. Sin embargo, Salvador Mata y Gallego Ortega (2009), ha conseguido agrupar las estrategias didácticas, en función de los elementos básicos del proceso didáctico, como se describe a continuación:

- a) Profesor: el profesor toma decisiones y adopta determinadas estrategias (estrategia de enseñanza).
- b) Estudiante: la adaptación de las estrategias de enseñanza en función de las características del estudiante. La principal estrategia es la cognitiva (estrategia de aprendizaje).
- c) Contenido: referidas al contenido del aprendizaje, cuyo objetivo es la organización, presentación y estructuración del material.
- d) Contexto: considerar el lugar de enseñanza, la dimensión social, el trabajo colaborativo.

Para Pimienta Prieto (2012), las estrategias de enseñanza-aprendizaje son instrumentos que el docente utiliza como medio para contribuir a la implementación y el desarrollo de las competencias de los estudiantes; y que por lo general, la literatura habla de estrategias de enseñanza y aprendizaje (Díaz-Barriga y Hernández Rojas, 2004), y aunque no se consideran excluyentes, se procede a realizar una descripción de estos componentes por separado:

### 2.5.3 Estrategias de enseñanza

Procedimientos y arreglos que los agentes de enseñanza utilizan de forma flexible para promover la mayor cantidad de aprendizajes significativos en los alumnos (Díaz-Barriga y Hernández Rojas, 2004; Parra Pineda, 2003).

Para Anijovich y Mora (2009), un estrategia de enseñanza se define como:

Conjunto de decisiones que toma el docente para orientar la enseñanza con el fin de promover el aprendizaje de sus alumnos. Se trata de orientaciones generales acerca de cómo enseñar un contenido disciplinar considerando qué queremos que nuestros alumnos comprendan, por qué y para qué. (p. 4)

Para ser considerada una estrategia de enseñanza, ésta debe cumplir con 3 condiciones: 1) un planteamiento riguroso y con sustento científico; 2) una experimentación previa; y 3) una difusión y formalización (Salvador Mata y Gallego Ortega, 2009).

Díaz-Barriga y Hernández Rojas (2004) manifiestan que las estrategias de enseñanza pueden ser clasificadas como: a) pre-instruccionales; b) co-instruccionales; y c) post-instruccionales; mismas que son definidas por Vargas-Murillo (2020) y se describen a continuación:

- a) Estrategias de enseñanza pre-instruccionales: tienen como propósito que el estudiante tenga la habilidad de plantearse objetivos y metas; de forma que, el docente identifique si el estudiante reconoce la finalidad de la asignatura.
- b) Estrategias de enseñanza co-instruccionales: su finalidad es apoyar los contenidos curriculares durante el proceso de enseñanza.
- c) Estrategias de enseñanza post-instruccionales: se presentan luego de presentar el contenido a aprender, fomentando la criticidad del estudiantado.

#### 2.5.4 Estrategias de aprendizaje

Las estrategias de aprendizaje están relacionadas con la calidad de aprendizaje por parte del estudiante, es decir, permite medir y evaluar el rendimiento académico (Beltrán Llerena, 2003). La estrategia de aprendizaje es un conjunto de procedimientos que el alumno utiliza de forma deliberada, flexible y adaptativa para mejorar sus procesos de aprendizaje significativo de la información (Díaz-Barriga y Hernández Rojas, 2004; Parra Pineda, 2003).

Según Salvador Mata y Gallego Ortega (2009), el concepto de estrategia de aprendizaje está relacionado con los modelos cognitivos sobre el aprendizaje. Las estrategias de aprendizaje incluyen recursos cognitivos que utiliza el estudiante al momento de aprender, pero también consideran factores como la motivación y disposición hacia las diferentes actividades como la planificación, dirección y control en el proceso de aprendizaje, según lo señalan Herrera Capita (2009) y Méndez Hinojosa y González Ramírez (2011).

Existen diferentes posturas respecto de la clasificación de las estrategias de aprendizaje (Díaz-Barriga y Hernández Rojas, 2004; Monereo, 1990; Vargas-Murillo, 2020); de forma que, se consideró una clasificación general que integre los diferentes criterios, la cual se describe a continuación:

- a) Estrategias de ensayo o repetición: se refieren a las actividades de repetición activa de los contenidos, ya sea de forma oral o escrita.
- b) Estrategias de elaboración: incluyen técnicas o métodos que fomentan la relación entre los conocimientos previos y los nuevos contenidos.

- c) Estrategias de organización: mediante estas estrategias, es posible agrupar, ordenar, clasificar la información, para tener una mejor representación de los contenidos, para que sea más fácil recordarla.
- d) Estrategias de regulación o control de comprensión: estas estrategias tienen conexión con la metacognición. El grado de control cognitivo exigido es muy elevado.
- e) Estrategias de apoyo o afectivas/motivacional: las estrategias no están enfocadas en el aprendizaje de los contenidos, sino mejorar las condiciones del aprendizaje como: la motivación, la atención y la concentración. Con estas estrategias es posible identificar las fallas en los tipos de estrategias pedagógicas que se estén aplicando (Euroinnova, 2023).



## Capítulo 3 – Revisión sistemática de la Literatura

En este capítulo se aborda toda la literatura relacionada con el tema central del presente trabajo, esto es, la explicación del desarrollo de las revisiones sistemáticas ejecutadas en (Pérez-Suasnavas et al., 2020a) y en (Pérez-Suasnavas, Salgado Proaño, et al., 2023) y que integran los siguientes temas: técnicas para la extracción de datos de la red social Twitter, técnicas de Minería de Datos para la extracción del conocimiento, y prácticas pedagógicas aplicadas a la educación superior.

En este capítulo se da cumplimiento al primer y segundo objetivo de la tesis doctoral.

### 3.1 Importancia de la revisión

Una revisión sistemática permite al investigador y a cualquier lector, obtener información clara sobre un tema específico. La revisión sistemática da respuesta a una pregunta concreta, contiene un resumen crítico, y debe tener la posibilidad de ser reproducida por la comunidad científica (Pardal-Refoyo y Pardal-Peláez, 2020). La necesidad de realizar una revisión sistemática se justifica en diferentes aspectos considerados por Velásquez (2015), y que son descritos brevemente a continuación:

- Los estudios de mapeo son adecuados para nuevos campos de investigación, con rápido desarrollo y cuya literatura es dispersa.
- El área de estudio tiene un volumen considerable de investigaciones de fuentes primarias, pero que no cuentan con revisiones o a su vez, las existentes son obsoletas.
- Las investigaciones de fuentes terciarias son necesarias cuando existe un gran número de revisiones de la literatura; y cuando la evolución del campo ha sido significativa.
- Permite a los investigadores resumir toda la información existente, sobre algún fenómeno de manera exhaustiva e imparcial.
- Disponibilidad de una guía específica para identificar el volumen de la literatura, cuyo análisis total es imposible ejecutar.
- Resumen de los principales hallazgos, cuando la investigación es antigua y las contribuciones tempranas podrían haberse olvidado.
- Análisis del impacto de un trabajo en particular, referido en la literatura.
- Necesidad de identificar vacíos de investigación, que propongan nuevas áreas de desarrollo o proyectos de investigación innovadores.

Para el presente trabajo, fueron tomados en cuenta dos aspectos para realizar la revisión de la literatura: a) existen investigaciones de fuentes primarias, pero las revisiones estaban obsoletas; y b) proponer nuevas áreas de desarrollo; que permitan responder a la pregunta general de la investigación: ¿Qué tipo de experiencias educativas se están desarrollando con la red social Twitter, para el mejoramiento de los procesos de enseñanza y aprendizaje en el ámbito universitario, mediante la aplicación de técnicas de Minería de Datos?

### 3.2 Método utilizado

Para determinar el estado del arte, respecto de las técnicas de Minería de Datos, la red social Twitter y estrategias didácticas aplicadas a la educación superior, se realizó una revisión sistemática en dos períodos, el primero: de enero/2007 a marzo/2019, y el segundo: de abril/2019 a noviembre/2022; para lo cual, fueron adoptados los lineamientos propuestos por Kitchenham (2007), cuyas actividades se describen a continuación:

1. Identificar la necesidad de realizar la revisión.
2. Especificar las preguntas de investigación.
3. Identificar y determinar los términos de búsqueda.
4. Establecer las estrategias de búsqueda.
5. Delimitar los criterios de inclusión.
6. Realizar el proceso de extracción de los datos.

#### 3.2.1 Identificar la necesidad de realiza la revisión

Como una parte de las actividades que conformaron el protocolo, se realizaron búsquedas de revisiones sistemáticas previas, que incluyeron los temas centrales de la presente tesis doctoral, que derivaron en la extracción de la siguiente información:

- Gao et al. (2012), realizaron una revisión sistemática entre 2008 – 2011 sobre Microblogging en la Educación «Microblogging in Education» (MIE), concluyeron que el microblogging fomenta la participación, compromiso, pensamiento reflexivo y el aprendizaje colaborativo en diferentes entornos de aprendizaje, sugieren realizar una indagación más rigurosa sobre MIE.
- Kleftodimos y Evangelidis (2013), realizaron una revisión para obtener y clasificar la información de las actividades de los estudiantes, en un Sistema de Gestión de Aprendizaje «Learning Management System» (LMS).
- Shabgahi et al. (2013), realizaron una comparación temática entre el uso del microblogging en las empresas y en la educación superior, para mejorar el sistema

pedagógico, identificando las principales actividades que realizan los estudiantes, así como los riesgos que genera su uso.

- Alias et al. (2013), realizaron una revisión entre 2007 – 2012, para evidenciar tendencias y problemas en el uso del Twitter, a través de un análisis de contenido.
- Lambert y Smith (2014), realizaron una revisión entre 2010 – 2013 en el ámbito de la salud, para determinar las actividades y percepciones que tienen los profesores y estudiantes respecto al uso de Facebook y Twitter, con el objetivo de mejorar la comunicación y aumentar la accesibilidad de los estudiantes a las prácticas y la experiencia del mundo real.
- Al-Samarraie y Saeed (2018), realizaron un estudio enfocado en los académicos, profesionales e investigadores, para comprender el potencial de uso de los entornos de computación en la nube, fomentando el aprendizaje colaborativo en un aula mixta.

De las seis revisiones sistemáticas encontradas en el primer período de análisis, estos es: enero/2007 a marzo/2019, únicamente dos estudios aportan información significativa: Gao et al. (2012) y Alias et al. (2013); sin embargo, los períodos de observación fueron realizados en los años 2011 y 2012 respectivamente. Por tanto, fue necesario desarrollar una nueva revisión, que incluye las investigaciones no consideradas hasta el año 2019.

Para el segundo período de análisis, se realizó una actualización de la revisión sistemática, para identificar la evolución de las investigaciones entre abril/2019 a noviembre/2022; período en el cual no se identificaron revisiones sistemáticas adicionales, además de la realizada por el autor hasta el año 2019.

### 3.2.2 Especificar las preguntas de investigación

Como parte de las actividades ejecutadas en el protocolo de revisión, fue necesario el planteamiento de las preguntas de investigación, las cuales son presentadas en la Tabla 4.

Tabla 4 – Preguntas de investigación

Pregunta	Aporte al objetivo
1) ¿Cómo ha evolucionado el estudio de técnicas de Minería de Datos para la extracción y/o análisis de datos provenientes de Twitter aplicado a la educación superior?	Investigar la evolución de las áreas descritas, permite identificar qué se ha realizado y los vacíos existentes en la literatura (objetivo 1).

2) ¿En qué países han sido desarrolladas estas investigaciones?	Reconocer los países en que se han desarrollado las investigaciones, permite identificar los vacíos que existe en otros países (objetivo 1).
3) ¿Cuál es el tamaño de la muestra utilizada en las investigaciones?	Identificar el tamaño de la muestra utilizada en las investigaciones forma parte de la revisión sistemática de la literatura (objetivo 1); además, permite establecer las condiciones necesarias para diseñar la estrategia didáctica (objetivo 3).
4) ¿Qué técnicas de Minería de Datos han sido utilizadas para extraer patrones de los datos de Twitter?	Describir las técnicas utilizadas para la extracción de los datos provenientes de Twitter, es parte de la revisión sistemática (objetivo 1), que permite identificar los vacíos existentes en la literatura sobre el uso de técnicas de Minería de Datos.
5) ¿Qué herramientas o aplicaciones se han utilizado para la extracción y/o análisis de datos utilizando Minería de Datos?	Constatar las herramientas utilizadas para la extracción de los datos provenientes de Twitter, forma parte de la revisión sistemática (objetivo 1), que permite identificar los vacíos existentes en la literatura respecto de las herramientas de análisis de los datos (objetivo 5).
6) ¿Cuáles son los usos de Twitter en la educación?	Identificar los principales usos educativos de Twitter, permite indagar la existencia de estrategias educativas en la educación superior (objetivo 2).
7) ¿Existe alguna práctica pedagógica utilizada en las investigaciones que incluya a Twitter?	Indagar las prácticas pedagógicas que incluyan a la red social Twitter, permite realizar la propuesta de la estrategia educativa innovadora (objetivo 2 y objetivo 3).

### 3.2.3 Identificar y determinar los términos de búsqueda

Luego de un sondeo preliminar de literatura, se identificaron los términos principales de búsqueda relacionados al tema central de la investigación; también se identificaron los posibles sinónimos y abreviaturas que estén contenidos en el título, palabras claves y resumen de los artículos.

Mediante la combinación de los términos principales y alternativos descritos en la Tabla 5, y con el uso de los operadores lógicos «AND» y «OR», la cadena de búsqueda se estructuró de la siguiente forma, para el idioma inglés:

("data mining" OR "knowledge discovery" OR KDD) AND (Twitter OR Tweet OR Microblog) AND ("higher education" OR university OR college)

Mientras que, para el idioma español, la cadena de búsqueda se estructuró de la siguiente forma:

("Minería de datos" OR "Descubrimiento del conocimiento") AND (Twitter OR Tweet OR Microblogueo) AND ("Educación Superior" OR Universidad)

Tabla 5 – Términos de búsqueda

Términos principales en inglés	Términos alternativos en inglés	Términos principales en español	Términos alternativos en español
Data Mining	Knowledge Discovery KDD	Minería de Datos	Descubrimiento del conocimiento
Twitter	Tweet Microblogging	Twitter	Tweet Microblog
Higher Education	University College	Educación Superior	Universidad

### 3.2.4 Establecer las estrategias de búsqueda

Para la búsqueda de la información, debido a su relevancia en el ámbito de estudio, como Minería de Datos, redes sociales y educación, se incluyeron las siguientes bases de datos:

- Association for Computing Machinery (ACM) Digital Library
- Education Resources Information Center (ERIC)
- Scholar Google
- Institute of Electrical and Electronics Engineers (IEEE) Xplore Digital Library
- JStor (abreviatura de **J**ournal **S**torage)
- ScienceDirect
- Servicio de Difusión de la Creación Intelectual (Sedici)
- SpringerLink
- Taylor

### 3.2.5 Delimitar los criterios de inclusión

Los criterios de elegibilidad de los diferentes artículos se fundamentaron en las siguientes características:

- Que los artículos hayan sido escritos en idioma español e inglés.
- Que las publicaciones se encuentren entre los siguientes períodos:

- enero/2007 a marzo/2019 y
- abril/2019 a noviembre/2022
- Que los artículos incluyan las cadenas de búsqueda en el título, palabras claves o resumen.
- Que los artículos hayan sido publicados en revistas o conferencias.
- Que las investigaciones incluyan los términos: Minería de Datos, Twitter y Educación Superior.

### 3.2.6 Realizar el proceso de extracción de los datos

A partir de las diferentes combinaciones de los términos de búsqueda, y respetando los criterios de inclusión, se obtuvieron 370 artículos, como se muestra en la Tabla 6.

Tabla 6 – Artículos encontrados, seleccionados e incluidos

Repositorio	#Artículos encontrados por las cadenas de búsquedas	#Artículos seleccionados por lectura de Título, Palabras Claves, Resumen	#Artículos incluidos para la revisión
ACM	5.166	13	4
IEEE	4.418	43	12
ScienceDirect	17.977	98	20
SpringerLink	74.140	118	18
Taylor	2.230	16	8
ERIC	118	8	3
JStor	3.872	2	1
Sedici	217	2	1
Scielo	7	2	-
Scholar Google	33.506	68	29
<b>TOTAL</b>	<b>141.651</b>	<b>370</b>	<b>96</b>

Una vez que fueron analizados los artículos, se detectaron y eliminaron 3 archivos duplicados. A partir de los 96 artículos considerados, se elaboró una matriz de extracción de datos, desarrollada en base a las preguntas de investigación en Pérez-Suasnavas et al. (2020a) y en Pérez-Suasnavas et al. (2023). Esta matriz se conformó por los siguientes campos: Id del artículo, año, título, autores, tipo de artículo, DOI/URL, cuyo detalle se encuentra en el Anexo A.

**1. ¿Cómo ha evolucionado, el estudio de técnicas de Minería de Datos para la extracción y/o análisis de datos provenientes de Twitter aplicado a la educación superior?**

Los hallazgos indican que, en el período de evaluación, esto es enero/2007 a noviembre/2022, los estudios sobre técnicas de Minería de Datos aplicadas a la red social Twitter en la educación superior, han crecido exponencialmente, destacando el año 2019, con el mayor número de publicaciones. Ver Figura 11.





Figura 11 – Número de artículos publicados por año

De la gráfica se puede determinar que, los estudios relacionados con técnicas de Minería de Datos y la red social Twitter en la educación superior, tiene un crecimiento exponencial en los cuatro primeros años, pero se evidencia un pequeño decremento en los dos años siguientes. También se observa que, entre el año 2015 y 2017 la curva de investigación se incrementa nuevamente; lo que permite determinar que existe interés en estos campos por parte de la comunidad científica; no obstante, es importante destacar que, para finales del año 2022 las investigaciones tienden a la baja nuevamente.

**2. ¿En qué países han sido desarrolladas estas investigaciones?**

Para identificar los países en los que se han desarrollado las investigaciones, primeramente, se realizó un análisis por continente, obteniéndose los siguientes resultados:



\*NE=no específica

Figura 12 – Número de artículos publicados por continente

De la Figura 12, se observa que, los continentes con más contribuciones son América, Europa y Asia; a partir de estos resultados, se procedió a identificar los países en los que han sido desarrollados los estudios. Ver Figura 13.






Figura 13 – Número de artículos publicados por continente y por país

Como se observa en la Figura 13, USA, España e India, son los países que cuentan con mayor aporte investigativo, siendo USA el que tiene más contribuciones. También se evidencia que, en Latinoamérica los estudios son escasos.

### 3. ¿Cuál es el tamaño de la muestra utilizada en las investigaciones?

Para determinar el tamaño de la muestra, se consideraron dos perspectivas:

- a) Número de usuarios: este aspecto se refiere al número de estudiantes, profesores o instituciones educativas.
- b) Número de tweets: cantidad de tweets recolectados y/o analizados en el experimento.

Debido a la dispersión de los datos respecto al número de usuarios incluidos en cada estudio, se realizó una agrupación de artículos por intervalos, como se muestra en la Tabla 7.

Tabla 7 – Artículos por intervalo de usuarios

Intervalo	#Artículos por intervalo
1 - 19	10
20 - 49	8
50 - 69	9
70 - 99	6
100 - 119	6
120 - 169	6
200 - 499	4
1000 - 1600	4
2000 - 5000	5
12000 - 25000	2
90000 - 110000	2
No se especifica	34
<b>TOTAL</b>	<b>96</b>

De la Tabla 7 se puede evidenciar que, la mayor cantidad de artículos utilizó una muestra entre 1 y 19 usuarios, seguido 9 estudios que utilizaron una muestra entre 50 y 69 usuarios. No obstante, existe un número considerable de estudios (34), que no especifican el número de usuarios que formaron parte del experimento.

De la misma forma en que fue realizado el análisis de la primera perspectiva, el número de tweets utilizados en las diferentes investigaciones, se agruparon por intervalos como se muestra en la Tabla 8.

Tabla 8 – Artículos por intervalo de tweets

Intervalo	#Artículos por intervalo
100 - 999	5
1.000 – 9.999	17
10.000 – 99.999	12
100.000 – 999.999	5
1.000.000 – 9.999.999	2
No se especifica	55
<b>TOTAL</b>	<b>96</b>

A partir de los datos presentados en la Tabla 8, se puede destacar que, 17 estudios utilizan entre 1.000 y 9.999 tweets para los trabajos experimentales, 12 estudios utilizan entre 10.000 y 99.999 tweets, mientras que existen 55 trabajos en los que no se ha especificado el número de tweets utilizados.

#### 4. ¿Qué técnicas de Minería de Datos han sido utilizadas para extraer patrones de los datos de Twitter?

De acuerdo con los datos obtenidos en cada uno de los 96 artículos de la revisión sistemática, se puede constatar la siguiente información:

- Algunos estudios utilizan más de una técnica.
- Algunos estudios emplean más de una tarea.
- Algunos estudios no describen claramente la técnica utilizada.
- Algunos estudios emplean técnicas adicionales, que son complementarias a la Minería de Datos.

Por las razones antes descritas, se consideró oportuno realizar una clasificación de acuerdo con los siguientes criterios, y que son presentados en la Tabla 9:

- Clasificar en un primer momento, por tipo de tarea (predictiva o descriptiva); y luego
- Clasificar por tipo de técnica empleada.

Tabla 9 – Artículos por técnicas de Minería de Datos

Técnica	# Artículos por técnica
<b>PREDICTIVA</b>	<b>87</b>
<b>CLASIFICACIÓN</b>	
Clasificadores Bayesianos	
Naïve Baye	20

Técnica	# Artículos por técnica
Redes bayesianas	4
Complement Naïve Bayes (CNB)	2
Bernoulli Naïve Bayes	1
Clasificador de vectores de soporte	
Máquinas de vectores de soporte (SVM)	11
LibSVM	1
Máquinas de vectores lineales	1
Optimización mínima secuencial (SMO)	1
Linear SCV	1
Clasificador de árboles de decisión	
Random Forest	8
Árboles de decisión	6
Algoritmos de redes neuronales	
Redes neuronales (sin especificar), Algoritmo Evolutivo EvoMSA, Redes neuronales CNN y LSTM, Algorithms Google's neural network algorithms, BERT, Algoritmo MR, Multi-Layer Perceptron.	7
Otras técnicas de clasificación	
Aprendizaje Automático (sin especificar)	8
Clasificador de sentimientos phpInsight	2
Vecinos más cercanos (KNN)	5
Clasificador Max-Margin Multi-etiqueta (M3L), Algoritmo de clasificación (sin especificar), Clasificación colectiva, Algoritmo de clasificación genético Memetic, Clasificador Multi Clase (MCC), Clasificación jerárquica difusa, Clasificador de la vida real (Real-Life-Rating), Baseline for Multilingual Sentiment Analysis (B4MSA), Clasificador AdaBoost.	9
<b>DESCRIPTIVA</b>	<b>11</b>
<b>AGRUPAMIENTO</b>	
Análisis de conglomerados	2
Clustering K-means	1
Método generalizado basado en instancias NNGE	1
Entropía máxima	3
<b>PATRONES FRECUENTES</b>	
Reglas de asociación (sin especificar)	2
Algoritmo A priori	2
<b>ESTADÍSTICA</b>	<b>26</b>
<b>Regresión</b>	
Regresión logística	8
Regresión lineal	5
Regresión OLS	1
<b>Varianza</b>	

Técnica	# Artículos por técnica
Análisis de varianza ANOVA	2
ANOVA unidireccional	1
Análisis multivariado de varianza. (MANOVA)	1
Otras	
Asignación Latente de Dirichlet (LDA)	2
Distribución de probabilidad estocástica	2
Análisis de frecuencias	2
Inferencial: análisis de supervivencia	1
Descriptiva e inferencial	1
<b>OTRAS TÉCNICAS</b>	<b>36</b>
Minería de textos y Análisis de contenido	
Minería de textos	10
Análisis de contenido	9
Análisis temático	6
Entrenamiento cerca del error (TONE)	1
Otras	
Map-Reduce	2
Hadoop Distributed File System (HDFS), Medición de coseno con Tf-Idf y Okap, Validación de datos convergentes, Selección de características (ReliefF), Análisis espacial y relacional, Análisis de patrones semánticos, temporales y espaciales, Eliminación cruzada de datos, Minería Web	8
<b>NO SE ESPECIFICA</b>	<b>20</b>
<b>TOTAL</b>	<b>180</b>

De la Tabla 9 se derivan los siguientes resultados:

- Existen mayor cantidad de estudios con tareas predictivas, con relación a los estudios con tareas descriptivas.
- La técnica predictiva más utilizada es el Clasificador Naïve Bayes.
- La técnica descriptiva más utilizada está relacionada con el Agrupamiento.
- Entre otras técnicas se encuentran: técnicas estadísticas (regresiones), análisis de patrones, Map-Reduce, Minería de Textos, Minería Web, etc.
- Existen 20 estudios en los que no ha sido especificado el tipo de técnica utilizada.

##### 5. ¿Qué herramientas o aplicaciones se han utilizado para la extracción y/o análisis de datos utilizando Minería de Datos?

Algunos artículos analizados, utilizan más de una herramienta, de manera que, estas fueron agrupadas en categorías, de acuerdo con la frecuencia de uso. Ver Tabla 10.

Tabla 10 – Artículos por herramientas

Herramienta	#Artículos por herramienta
<b>Herramientas más utilizadas</b>	<b>138</b>
Twitter API	33
Python	12
NVivo	11
SPSS	10
R	7
Microsoft SQL Server Data mining	6
NLTK	6
Phyton data analysis	6
MATLAB	5
Microsoft Excel Data mining	4
Topsy	4
Lemur Toolkit	4
Weka	3
Java	3
Web Trends	3
Radian	3
Gephi	2
Identica.ca	2
Ning	2
Leximancer	2
Twitter Streaming API	2
Storify	2
MySQL database	2
Streaming API	2
RapidMiner	2
<b>Otras herramientas menos utilizadas</b>	<b>45</b>

Searchtastic.com, Maltego, Tweet Reach, ArcMap, NetBeans, BirdIQ, TextBlob, Blackboard, WAP technologies, Crawler Ad-Hoc, Microsoft Excel, Data Science Toolkit26, Phytion NetworkX, Edmodo Cirip, Seomz, Elasticsearch, TidyText, Emolex, Twitterwall, eMUSE, My Twitter Scraper, Analizador Stanford, ESRI, Mentionmapp.com, Flume, Microsoft Power BI, Followthehashtag, NodeKL, Google geocoder, REST, Google traffic estimator, SenticNet, Google's Cloud Vision API, Solr, ILE-Java, ThingLing, InaNLP, TweetStats, Kibana, TweetTokenizer, Knowcat, VADER, Librería LIWC, Wordle, LibSVM library, Linq2Twitter

Frecuencia de uso 1 por artículo

No se especifica	26
<b>TOTAL</b>	<b>209</b>

De la Tabla 10 se observa que, las herramientas utilizadas con mayor frecuencia son: Twitter API, Python, NVivo y SPSS, cuyas características principales se describen a continuación:

- Twitter API<sup>®</sup>: permite extraer los datos de Twitter y buscar palabras clave de cuentas específicas (TWITTER, 2019, 2022c), no requiere pago y depende del tipo de suscripción para acceder a los datos.
- Python: es un lenguaje de programación que permite trabajar de forma más rápida e integra los sistemas de manera más efectiva (Python, 2022). Python ha migrado de ser un lenguaje informático a un lenguaje importante para la ciencia de datos y el Aprendizaje Automático (McKinney, 2018).
- NVivo<sup>®</sup>: es un software que permite organizar, analizar y hallar perspectivas en datos no estructurados o cualitativos como el contenido de las redes sociales y la web (NVIVO, 2019). Es un software que requiere pago.
- SPSS<sup>®</sup>: es un software que, además de realizar análisis estadístico, análisis de texto, integración con Big data (IBM, 2019), es utilizado para análisis cuantitativo y cualitativo de los datos de Twitter. Es un software que requiere pago.

## 6. ¿Cuáles son los usos de Twitter en la educación?

Para determinar los principales usos de Twitter en la educación, se realizaron dos tipos de análisis:

- a) Por su utilidad en el contexto educativo.
- b) Por los actores de la educación que intervienen en el estudio.

De acuerdo con la utilidad de Twitter en la educación, los estudios fueron agrupados por el objetivo que persiguen las diferentes investigaciones; la información puede ser visualizada en la Tabla 11.

Tabla 11 – Artículos por utilidad de Twitter

Utilidad	ID Artículo
<p><b>Analizar:</b> Tweets, favoritismo, evolución del conocimiento, sentimientos, efectos de participación y las calificaciones, relación entre posición del asiento y seguimiento en red social, educación en Twitter e información en LinkedIn, relación entre preguntas y material de clase, sentimientos asociados a la pandemia por COVID-19, problemas de la vida diaria de los estudiantes árabes, sentimientos y dificultades de los estudiantes por COVID-19, opinión del aprendizaje en línea debido al COVID-19, comunicación de los libaneses en las protestas, sentimientos para comparar y evaluar universidades, sentimientos de los filipinos en tiempo de COVID-19, pensamientos de los estudiantes sobre el curso de preferencia, evolución de los estudiantes, sentimientos y desafíos de los estudiantes por COVID-19, percepciones sobre el impacto de las TIC en la educación, emociones sobre un determinado curso, sentimientos de estudiantes, contenido digital relacionado con calidad y acreditación generado por universidades de Perú y Chile, contenido digital de las universidades de Perú y Chile, experiencias de aprendizaje, prevalencia de tweets considerados irrespetuosos, insensibles o perjudiciales y potencialmente dañinos para los pacientes y/o las organizaciones, patrones y diferencias en los tipos de tuits incívicos, polaridad de los sentimientos.</p>	<p>E10, E17, E34, E36, E42, E43, E66, E70, E71, E72, E73, E74, E75, E76, E77, E78, E79, E83, E84, E85, E89, E93</p>
<p><b>Determinar:</b> usos de Twitter, etiquetas influyentes, sentimientos en una conferencia, usos de Twitter en una conferencia, experiencias, expectativas de Twitter, comportamiento, estilos de aprendizaje, percepción, necesidades de los egresados, características de los tweets incívicos por estudiantes de enfermería.</p>	<p>E9, E15, E19, E20, E24, E26, E30, E39, E41, E44, E45, E51, E52, E57, E58, E59, E60, E63, E89, E94</p>
<p><b>Generar:</b> comunicación informal, participación, comunicación, comunicación reflexiva, participación en línea, participación en una conferencia, comunicación durante una conferencia, comunicación virtual entre estudiantes y comunidad educativa, recopilar automáticamente tweets, nuevo corpus, construir comunidades en tiempos de pandemia, extraer información relevante para formar comunidades educativas.</p>	<p>E5, E12, E14, E16, E21, E23, E26, E28, E35, E40, E46, E53, E54, E57, E61, E64, E67, E83</p>
<p><b>Compartir:</b> material educativo, recursos, conocimiento, sentimientos, información, experiencias, actividades, reflexiones.</p>	<p>E9, E11, E16, E21, E32, E36, E37, E45, E46, E48, E50, E53, E63</p>
<p><b>Mejorar:</b> vocabulario en inglés, rendimiento académico y psicosocial, filtrado de palabras, toma de decisiones, conciencia social, alcance social de las instituciones, competencias, estructura y organización del curso, aprendizaje de conceptos, lenguaje académico cognitivo, toma de decisiones políticas para ajustar planes institucionales, tomar medidas correctivas para la retención, éxito de los estudiantes.</p>	<p>E3, E13, E19, E28, E31, E34, E35, E37, E38, E50, E54, E59, E60, E64, E67, E85</p>



Utilidad	ID Artículo
<b>Fomentar:</b> pensamiento creativo, trabajo en equipo, habilidades sociales, de comunicación, de aprendizaje autorregulado, comunidades, competencia cultural, educación STEM, discurso, nuevas competencias, conciencia metacognitiva.	E11, E36, E38, E42, E53, E54, E56, E60, E62
<b>Identificar:</b> estilos de aprendizaje, temas importantes, rasgos de personalidad, comentarios, automáticamente preguntas relevantes en una conferencia, datos demográficos en pandemia, estrategias de comunicación, fuentes de medios de comunicación, tendencias del sector educativo, estudiantes y motivo del bajo rendimiento, opinión pública en tiempos de pandemia, contextos del comentario, conflictos estudiantiles, estado de ánimo.	E4, E17, E19, E20, E43, E66, E69, E82, E83, E85, E90, E91
<b>Evaluar:</b> portafolios, por pares, efectividad en el aprendizaje, proceso de enseñanza, formativamente, actividades y preferencias universitarias, titulares de noticias educativas, las quejas de los estudiantes, técnicas de análisis de sentimientos.	E11, E13, E32, E44, E55, E64, E68, E82, E87, E88

Nota: \*El ID del artículo puede ser visualizado en la tabla del Anexo A.

Con relación a los actores que intervienen en los diferentes estudios, estos fueron clasificados de acuerdo con las funciones y/o entornos en que se desenvuelven, entre los que se puede mencionar a: estudiantes, profesores, institución, comunidad, profesionales, entre otros. De acuerdo con las categorías identificadas, fue posible totalizar el número de artículos que se enfocan en un determinado actor o escenario. Ver Figura 14.




Figura 14 – Usos de Twitter por actor

De la Figura 14 se evidencia que, Twitter es utilizado en su mayoría para actividades con los estudiantes (68,2%), seguido de las actividades en donde intervienen las instituciones (9,3%), y otro valor a considerar son los asuntos profesores-estudiantes (5,6%).

En síntesis, Twitter ha sido utilizado para distintos propósitos, focalizando su aplicación en los estudiantes, y que se describen a continuación:

- Determinar las experiencias y percepciones, estilos de aprendizajes, sentimientos, experiencias.
- Analizar los sentimientos, favoritismo, participación, evolución del conocimiento.
- Fomentar diferentes habilidades como: pensamiento creativo, comunicación, aprendizaje autorregulado, sociales.
- Compartir información y recursos.
- Generar participación, comunicación.
- Mejorar rendimiento académico y psicosocial, competencias, vocabulario.
- Identificar estudiantes en riesgo, estado de ánimo, estilos de aprendizaje, rasgos de personalidad.

## 7. ¿Existe alguna práctica pedagógica utilizada en las investigaciones que incluya a Twitter?

Para identificar las prácticas pedagógicas utilizadas en las investigaciones, se realizó una clasificación de acuerdo con el objetivo que persiguen. Ver Tabla 12.

Tabla 12 – Artículos por prácticas pedagógicas

Prácticas pedagógicas	#Artículos por práctica
<b>Modelo</b>	<b>7</b>
Modelo de Felder-Silverman	3
Modelo de Psicología de los Cinco Grandes	2
Modelo Constructivista	1
Modelo de aprendizaje de Kolb	1
<b>Técnica</b>	<b>2</b>
Léxico afectivo de Finn Årup Nielsen conocido como AFINN	2
<b>Método</b>	<b>2</b>
Método feedback	1
Método de evaluación feedforward	1
<b>Estrategia</b>	<b>2</b>
Estrategia pedagógica Justo a tiempo para enseñar	1
Estrategia de aula extendida	1
<b>Metodología</b>	<b>1</b>

Metodología asalto de fuerza bruta	1
<b>Instrumento</b>	<b>1</b>
Instrumento pedagógico de inventario de conciencia metacognitiva MAI	1
<b>Teoría</b>	<b>1</b>
Teoría del aprendizaje y la enseñanza como acciones comunicativas	1
<b>Tipo de aprendizaje</b>	<b>1</b>
Tipo de aprendizaje semipresencial	1
<b>No se especifica</b>	<b>79</b>
<b>TOTAL</b>	<b>96</b>

De la Tabla 12 se derivan los siguientes resultados:

- Diecisiete artículos utilizan una práctica pedagógica.
- Siete artículos mencionan el uso de un modelo.
- Dos artículos hablan de un método.
- Dos artículos utilizan una estrategia.
- 79 artículos no mencionan el uso de alguna práctica pedagógica.

Los hallazgos sobre prácticas pedagógicas utilizadas en los estudios son muy variados, de estos, únicamente el 17,7% mencionan una práctica, ya sea identificada como metodología, modelo, técnica, estrategia o instrumento (Ortiz Ocaña, 2013; Santos, 2016); por lo que no es posible establecer la práctica pedagógica más idónea para la inclusión de la red social Twitter en la educación, y de forma particular en la educación superior.

Debido a la relación con el tema central de la presente tesis doctoral, se citan tres artículos relevantes:

Primeramente se cita el estudio realizado por Hasan et al., (2014), quienes proporcionan un sistema para clasificar emociones de Twitter de estudiantes universitarios, mediante el uso de hashtags específicos. Seguidamente se encuentra el estudio realizado por Patel y Mistry (2015), quienes brindan un sistema clasificador que permite identificar y clasificar los tweets, que reflejan los problemas y los aspectos positivos de los estudiantes, de un número determinado de palabras claves. Por último, Ingole et al. (2018) proporciona un flujo de trabajo para comprender los problemas de aprendizaje e inquietudes de los estudiantes utilizando sus tweets, mediante la combinación de términos relacionados a ingeniería.

Con la información descrita anteriormente, se puede evidenciar la evolución de las investigaciones en el campo de la Minería de Datos, la red social Twitter y su aplicación en la

educación superior; lo que permitió establecer los vacíos existentes en la literatura, y establecer las pautas para la propuesta de la estrategia que permita integrar las áreas en cuestión. Ver Tabla 13.

Tabla 13 – Resumen de hallazgos en la literatura vs. aportes de la estrategia propuesta

No.	Hallazgos en la literatura	Aportes de la estrategia propuesta
1	En Latinoamérica, existen pocos estudios que integren las tres áreas de estudio (Minería de Datos, Redes Sociales y Educación Superior).	La estrategia didáctica integra estrechamente las áreas descritas, mediante el uso de instrumentos, muestras y un entorno que se ajusta a un país latinoamericano.
2	Los datos recopilados de Twitter están escritos en idioma inglés.	La estrategia didáctica utiliza comentarios realizados en idioma español.
3	Los estudios utilizan diferentes Técnicas de Minería de Datos, pocos de ellos refieren el uso de Redes Neuronales.	Una de las fases de estrategia didáctica, automatiza el proceso, con la inclusión de técnicas de Minería de Datos, específicamente con el uso de Redes Neuronales.
4	Algunos estudios realizan el proceso de extracción de datos y desarrollo del algoritmo con herramientas de pago; o a su vez no se han especificado.	Entre los recursos que utiliza la estrategia didáctica, se encuentra Twitter API y Python; herramientas de libre acceso.
5	De los 96 estudios encontrados en la literatura, 79 no mencionan el uso de alguna práctica pedagógica.	En el presente estudio, además de combinar las tres áreas principales descritas anteriormente; Twitter es utilizado como parte de una estrategia claramente definida en 4 fases.
6	Los cinco principales usos de Twitter en la educación superior, se enfoca en: 1) determinar las experiencias, percepciones, estilos de aprendizaje; 2) analizar sentimientos, preferencias; 3) fomentar diferentes habilidades; 4) compartir información y recursos; y 5) generar participación y comunicación.	La estrategia didáctica propuesta identifica las experiencias, percepciones, sentimientos, generar participación y comunicación; además genera habilidades de abstracción, pensamiento crítico; fomenta el trabajo en equipo y principalmente predice las dificultades de los estudiantes.

## Capítulo 4 – Diseño de la estrategia didáctica

En este capítulo, se describen los pasos y actividades realizadas para el diseño de la estrategia didáctica, que permite incluir la red social Twitter en los procesos de enseñanza y aprendizaje en la educación superior. Con estas actividades se da cumplimiento al tercer objetivo de la tesis doctoral.

### 4.1 Antecedentes

Uno de los problemas identificados en los estudiantes universitarios, y que motiva el desarrollo del presente trabajo, es la reducida participación estudiantil durante las sesiones de clases presenciales, el uso excesivo de dispositivos tecnológicos dentro del aula, especialmente en el manejo de redes sociales. Este problema fue identificado desde los períodos que anteceden al proyecto doctoral (Pérez-Suasnavas et al., 2019), esto es, entre abril/2015 y marzo/2018.

Una participación activa por parte de los estudiantes, se ve influenciada por diferentes agentes como: disposición, motivación, estilos de aprendizaje, relación profesor-estudiante, seguridad, confianza del estudiante, entre otros (Pérez-Suasnavas et al., 2020b; Zepke y Leach, 2010). Por lo que, la participación puede ser evaluada en diferentes entornos y momentos (Bond et al., 2020; Jenaro-Río et al., 2018; Kahu, 2013; Tejera Concepción y Cardoso Sarduy, 2015); de forma que, se requiere aplicar estrategias innovadoras para evaluar la participación estudiantil.

Para Rogers (1983) una innovación incluye los siguientes pasos: a) Reconocer un problema o necesidad; b) Investigación básica y aplicada; c) Desarrollo; d) Comercialización y e) Difusión y adopción.

En el campo de la educación, para que la innovación docente sea considerada eficaz, existen ciertas condiciones necesarias que se deben cumplir, entre las que se puede mencionar: viabilidad, realismo y adaptabilidad para cada disciplina y para cada tipo de universidad; además, se debe contar con la participación de todos los actores de la educación, como son: directivos, docentes y estudiantes (Michavila, 2009).

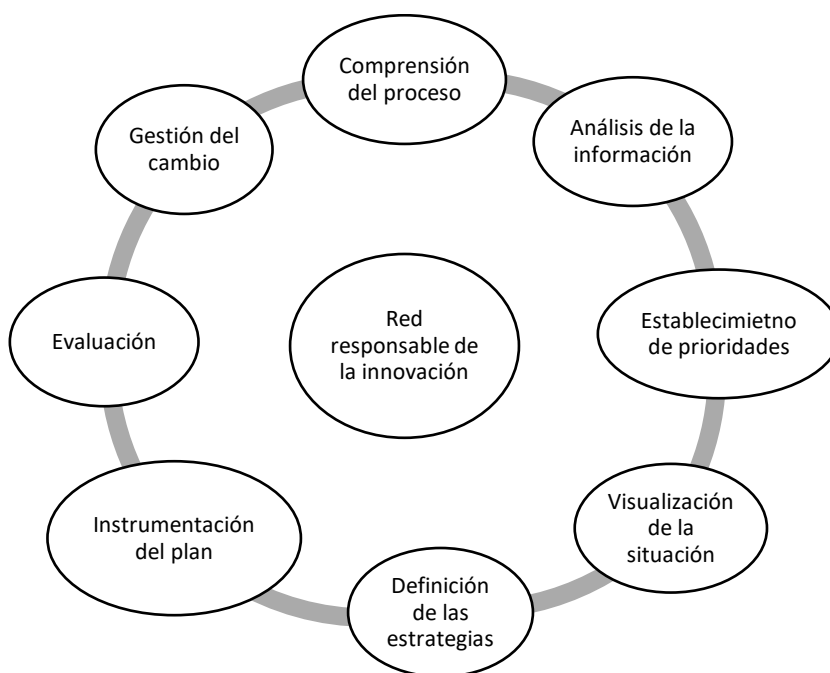
Para delimitar el campo de la innovación educativa, Ortega et al. (2007) proponen un conjunto de criterios que garanticen el carácter de innovación y exista la probabilidad de éxito; no obstante, los criterios son “objeto de revisión constante y se aplican con flexibilidad” (p. 155). Según el Modelo de Innovación Educativa desarrollado por el Instituto Politécnico Nacional (IPN) de México, existen doce criterios que caracterizan una innovación educativa, fundamentados en los de la Red Innovemos de la UNESCO (2005) y los propuestos por Blanco Guijarro y Messina Raimondi (2000). Ver Figura 15.



Fuente (Ortega Cuenca et al., 2007)

Figura 15 – Criterios de innovación educativa

El Modelo de Innovación Educativa (MIE) descrito por Ortega Cuenca et al. (2007) comprende ocho fases, y que no necesariamente siguen un orden, puesto que, en cada fase puede existir ciclos subsecuentes y reiniciar en otro punto para continuar con el siguiente. Ver Figura 16.



Fuente (Ortega Cuenca et al., 2007)

Figura 16 – Fases de MIE

Una práctica educativa innovadora, se convierte en el medio por el cual los estudiantes adquieren conocimientos, habilidades y actitudes; por lo que, no existe un único método, sino que el mejor será una combinación de diferentes situaciones diseñadas de manera intencional y sistemática (Fernández March, 2006), mediante el empleo de diferentes métodos, técnicas y estrategias de intervención (Presutti, 2002).

## 4.2 Desarrollo

Para el diseño de la estrategia didáctica, uno de los principales instrumentos fueron los registros del docente, los cuales estaban conformados por diferentes campos con información relacionada a: calificaciones, asistencia, número de participaciones por clase, trabajos grupales, entre otros datos; además se contó con la información generada por el sistema SIIU.

De acuerdo con lo expresado por Handelsman et al. (2005) y Payne (2017), para el presente trabajo, la participación estudiantil fue medida de acuerdo con los siguientes criterios:

- Reconocer el entorno y condiciones de trabajo.
- Considerar como participación estudiantil a uno o más de los siguientes escenarios:
  - El estudiante responde a las preguntas planteadas por el docente de forma voluntaria.
  - El estudiante responde a una pregunta direccionada, planteada por el docente.
  - El estudiante pregunta o realiza algún comentario relacionado al tema de clase, de forma voluntaria.
- Las participaciones se registraron por cada sesión de clase y por cada Hemisemestre. Un Hemisemestre, más identificado como Hemi dentro de la Institución, corresponde a la mitad de un período académico, cuya duración es de 16 semanas; es decir, un período académico tiene 2 Hemis, cada uno de aproximadamente 2 meses.
- Cada nueva participación realizada por el estudiante fue acumulada por cada Hemi.
- Cada período académico, estuvo conformado por tres (3) cursos de la asignatura de Programación 1.
- Para obtener el porcentaje de participación, se totalizaron todas las participaciones de todos los estudiantes por cada período académico y por Hemi.

Con los criterios descritos anteriormente, se obtuvo el porcentaje de participación por cada período académico y por cada Hemi, como se muestra en la Figura 17.

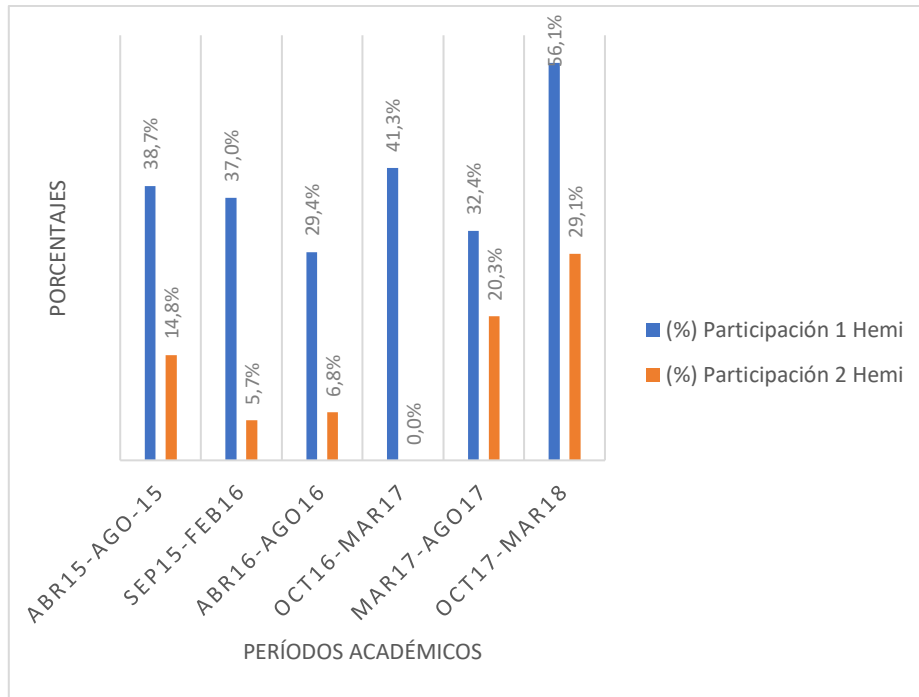


Figura 17 – Porcentaje de participación por período y por Hemi

De la Figura 17 se puede evidenciar que, el porcentaje de participación está por debajo del 50% en todos los períodos; exceptuándose el 1° Hemi en el período octubre/2017 – marzo/2018, que bordea el 66%. Además, el porcentaje del 2° Hemi es inferior al 1° Hemi en todos los períodos académicos; lo que permite inferir que, para los últimos meses de clases, la participación estudiantil tiende a reducirse sustancialmente, como se puede observar en el período octubre/2015 – marzo/2017, no se registra ninguna participación en ninguno de los cursos en que se imparte la asignatura de Programación 1.

#### 4.2.1 Encuesta – Parte 1

Previo al desarrollo de la herramienta que permita incrementar la participación de los estudiantes universitarios, se desarrolló una encuesta Ad-hoc vía web, que permitió determinar las redes sociales que pueden ser utilizadas como parte del proyecto de investigación. Con este antecedente, surge la pregunta de investigación: ¿Qué herramientas tecnológicas utilizan con mayor frecuencia los estudiantes como apoyo académico?

La encuesta se aplicó en julio de 2018 a 146 estudiantes de la carrera de Ingeniería Civil de la Universidad Central del Ecuador, en el período académico abril/2018 a agosto/2018, matriculados en la asignatura de Programación 1, de estos, el 70,55% correspondían al género masculino y el 29,45% al género femenino.



De los 146 estudiantes encuestados, se receptaron 78 encuestas (53,4%); sin embargo, de los 146 estudiantes, para la fecha en que se aplicó la encuesta, 22 estudiantes habían dejado de asistir a clases, considerándose como “Retirados” de la asignatura y no formaron parte del análisis. Así, la población efectiva fue de (n=124), a partir de este valor, se calculó la tasa de retorno efectiva según fórmula propuesta por (Johnson y Christensen, 2014):

$$RR = \frac{\text{Número de personas en la muestra que participan en la investigación}}{\text{Número total de personas en la muestra}} \times 100$$

$$RR = \frac{78}{124} \times 100$$

$$RR = 62,9\%$$

La tasa de respuesta del 62,9% se considera favorable, tomando en cuenta que las tasas de respuestas receptadas por Internet/Correo son comúnmente bajas; sin embargo, una tasa de respuesta del 70% es considerada aceptable suponiendo que los encuestados y no encuestados tienen similares características (Mertens, 2014), por ese motivo fue necesario determinar si la muestra fue representativa en relación a la población, es decir se validó el tamaño de la muestra. Al ser un tamaño de población pequeño y finito (n=124), se aplicó la fórmula de correlación propuesta por Dilman et al. (2014), considerando el nivel de confianza estadístico del 95%, cuyo valor crítico es z=1,645, con una proporción de respuesta del 80/20 (p=0.8, q=1-p) y margen de error de ± 5 (MoE=0.05) puntos porcentuales del valor real de la población, se determinó el tamaño de muestra necesario (n), conforme a la siguiente fórmula:

$$n = \frac{N * p * q}{(N - 1) * \left(\frac{MoE}{z}\right)^2 + (p * q)}$$

$$n = \frac{124 * 0.8 * 0.2}{(124 - 1) * \left(\frac{0.05}{1.645}\right)^2 + (0.8 * 0.2)}$$

$$n = 72,51$$

Aunque AAPOR (2016) manifiesta que no existe un consenso sobre los factores asociados a la tasa de respuesta y la calidad de la encuesta; según la tabla de tamaños de muestra necesarios

( $n=73$ ) es la muestra mínima requerida (Dilman et al., 2014), de modo que, con ( $n=78$ ) respuestas obtenidas, se tienen valores suficientes para el análisis.

La encuesta, denominada «Social Network & Education», estuvo conformada por 10 preguntas de tipo mixtas (Ver Anexo B), de acuerdo con la siguiente estructura:

- 5 preguntas de opción múltiple.
- 2 preguntas en escala de Likert de 4 niveles, con el objetivo de evitar las respuestas neutras por parte de los estudiantes.
- 2 preguntas abiertas.
- 1 pregunta de opción única.

La encuesta fue validada por 5 expertos académicos con más de 10 años de experiencia en el área. Para determinar el nivel de acuerdo entre los expertos se aplicó el coeficiente de validez de contenido (CVC) propuesto por Hernández Nieto (2011). El CVC permitió evaluar 4 categorías: claridad, coherencia, relevancia y suficiencia de los ítems, según se describe en Anexo C. El valor obtenido por el CVC fue superior a 0.80 en cada categoría, por lo que se considera un instrumento con viabilidad y confiabilidad.

Para dar contestación a la pregunta de investigación, se consideraron las 4 primeras preguntas de la encuesta «Social Network & Education», cuyas respuestas se describen a continuación:

#### 4.2.1.1 Pregunta 1: ¿Qué red social utilizas con más frecuencia?

Los estudiantes fueron encuestados sobre la frecuencia de uso de ciertas redes sociales, cuyos resultados se muestran en la Figura 18.

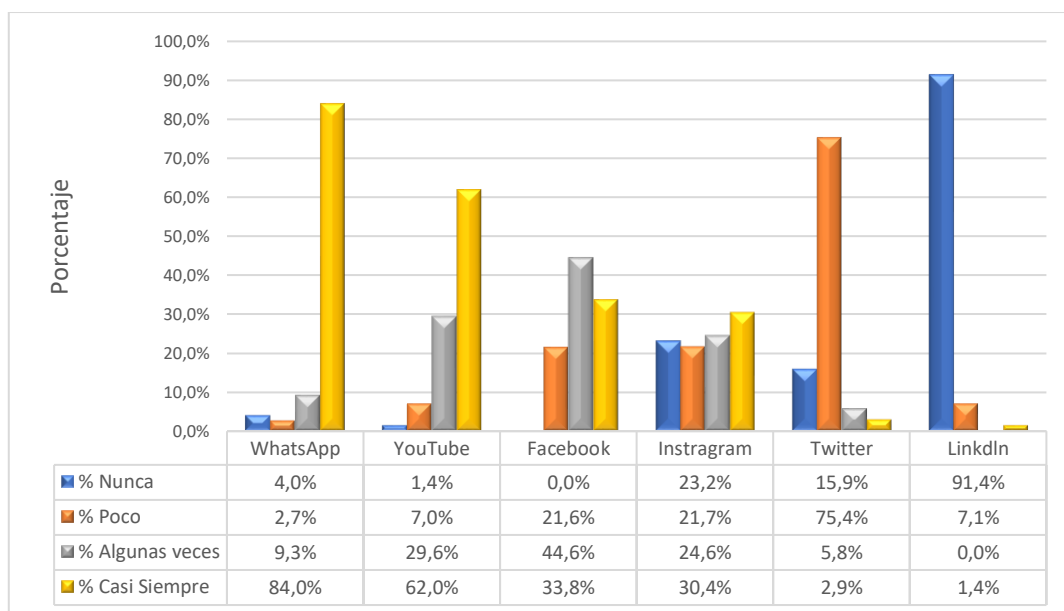


Figura 18 – Frecuencia de uso de las redes sociales

De la Figura 18 es posible realizar un resumen por red social y la frecuencia de uso. Ver Tabla 14.

Tabla 14 – Frecuencia de uso de redes sociales

Red social	Porcentaje	Frecuencia
WhatsApp	84,0%	Casi siempre
YouTube	62,0%	Casi siempre
Twitter	75,4%	Poco
Facebook	44,6%	Algunas veces
Instagram	30,4%	Casi siempre
LinkedIn	91,4%	Nunca

De la Tabla 14 se destacan WhatsApp, YouTube e Instagram como las redes sociales que mayormente utilizan los estudiantes; aunque los porcentajes tienen una diferencia importante; estos resultados podrían ser debido a que los estudiantes podían escoger más de una respuesta. Por otra parte, la red social de Twitter y LinkedIn son las menos utilizadas por los estudiantes.

#### 4.2.1.2 Pregunta 2: ¿Con qué objetivo utilizas la red social?

Sobre las redes sociales, los estudiantes tienen bien diferenciadas sus intenciones de uso, como se observa en la Figura 19.

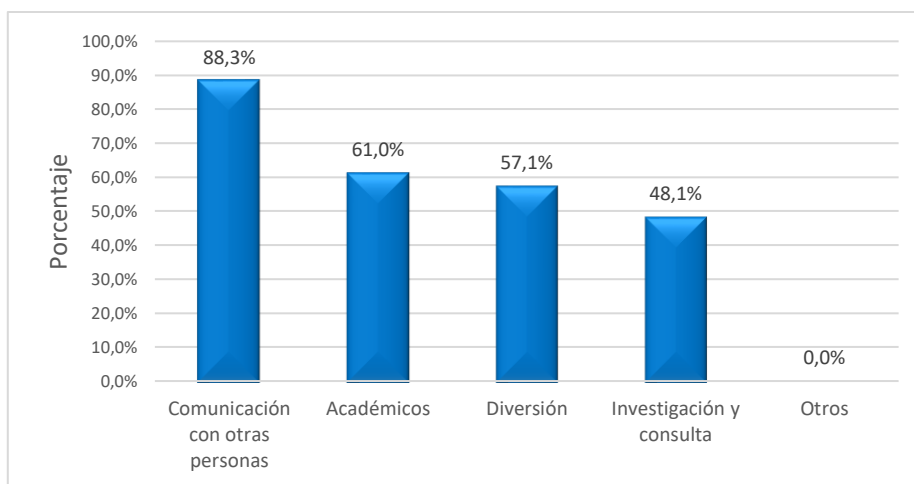


Figura 19 – Objetivo del uso de las redes sociales

De la Figura 19 se destaca que, el principal uso de las redes sociales es la comunicación con otras personas (88,3%); asuntos académicos (61%); por diversión (57,1%) y para realizar investigaciones y consultas (48,1). También se consultó a los estudiantes si utilizan las redes sociales con otros propósitos, en esta pregunta no hubo ninguna respuesta (0%). Estos hallazgos

permiten inferir que, existe un gran porcentaje de estudiantes que utilizan las redes sociales con fines educativos, resultados que son favorables para el presente estudio.

#### 4.2.1.3 Pregunta 3: ¿Qué red social utilizas o utilizarías con fines educativos, investigación o consulta académica?

Los estudiantes fueron consultados sobre la red social que utilizarían con fines académicos y se pudo observar que, los estudiantes demuestran que los aplicativos tecnológicos son parte de su cotidianidad, revelándose diversidad de plataformas como se observa en la Figura 20.




Figura 20 – Redes sociales que utilizan los estudiantes con fines académicos

De la Figura 20, YouTube es la red social que más utilizan los estudiantes con fines educativos (84,4%), luego está WhatsApp con 40,3% y Facebook (32,5%) y en menor proporción Twitter y LinkedIn; resultados que pueden ser cotejados con el 61% de estudiantes que emplean las redes sociales con fines educativos; estos hallazgos permiten ratificar el uso efectivo de las redes sociales en la academia.

#### 4.2.1.4 Pregunta 4: ¿En qué lugar buscas información académica?

Respecto de las fuentes de consulta, los resultados sobre las búsquedas académicas que realizan los estudiantes se muestran en la Tabla 15.

Tabla 15 – Búsqueda de información académica

Lugar de búsqueda	Porcentaje
Google	80,5%
Libros digitales	71,4%
YouTube	64,9%
Google Académico	50,7%
Libros físicos	48,1%
Bibliotecas Digitales	39,0%
Yahoo! respuestas	20,8%
Wikipedia	20,8%
Revistas digitales	15,6%
Otro	2,6%

Sobre las fuentes de consulta, la Tabla 15 denota una preferencia por Google con el 80,5%, seguido de Libros digitales con 71,4% y luego YouTube con 64,9%; en menor proporción revistas digitales, con el 15,6%.

Los resultados de la encuesta permitieron identificar que, las redes sociales utilizadas con mayor frecuencia son: WhatsApp, YouTube e Instagram y menor en porcentaje Twitter, Facebook y LinkedIn. A pesar que, en la Tabla 14, se evidencia “Poco” uso de la red social Twitter por parte de los estudiantes encuestados, diferentes estudios evidencian que mediante Twitter se potencia la motivación y la participación del estudiantado (Junco et al., 2011; Martínez-Rodrigo y Raya-González, 2013); además, se fomenta la comunicación y la creación de comunidades de aprendizaje (Tejedor et al., 2021); además, la limitación a la escritura de los caracteres, permite a los estudiantes desarrollar la habilidad de abstraer y sintetizar la información.

Por lo expuesto en el párrafo que antecede, y de acuerdo con el objetivo propuesto en este capítulo, esto es, incrementar la participación de los estudiantes, se acogió la red social Twitter, cuyo objetivo principal es la conversación pública (Checa García, 2013); permitiendo al estudiante desarrollar diferentes habilidades como: a) generar debate en tiempo real; b) compartir información; c) destacar temas o contenidos con el uso de hashtags; d) promover la capacidad de abstracción y síntesis debido a la limitación de caracteres en la escritura de un tweet (García Suárez et al., 2015; Hasan et al., 2014; Toro Araneda, 2010); entre otras habilidades.

Con la red social Twitter se realizó una pre-experimentación para fomentar la participación de los estudiantes durante una sesión de clase. Este pre-experimento fue ejecutado en el período septiembre/2018 a febrero/2019 a tres cursos de Programación, cuyos códigos asignados

fueron: S2P1, S2P4 Y S2P5; y se aplicó de forma paralela a la metodología tradicional de clase utilizada por el docente.

#### 4.2.2 Uso de Twitter como herramienta de participación estudiantil

El pre-experimento incluyó varias etapas, y que son descritas en la Tabla 16.

Tabla 16 – Etapas del pre-experimento

Etapa	Actividad
1. Creación de la cuenta de Twitter.	Se solicitó a los estudiantes la creación de una cuenta en Twitter.
2. Establecer normas de uso y socializar.	Se socializó a los estudiantes las normativas de uso de la cuenta de Twitter.
3. Informar a los estudiantes el inicio de actividad de prueba.	Los estudiantes realizan intervenciones de presentación personal, para interactuar con los otros compañeros y familiarizarse con la herramienta.
4. Indicar a los estudiantes el inicio de la primera actividad académica.	Se crea un Tweet con la consigna a realizar.
5. Se pide a los estudiantes responder al Tweet mediante sus dispositivos móviles.	Los estudiantes responden al Tweet planteado por el docente.
6. El docente evalúa la actividad	La evaluación de la actividad se realiza de forma manual, a través de la lectura de cada Tweet realizado por el estudiante.
7. Retroalimentación por parte del docente.	Una vez finalizada la etapa de evaluación, el docente retroalimenta a los estudiantes de acuerdo con los comentarios realizados.
8. Reevaluación de la actividad, evidenciando dificultades.	Si existen dificultades manifestadas por los estudiantes, se procede a una nueva retroalimentación.

Con la ejecución del paso 7 y 8 realizado durante las sesiones de clases presenciales, se generó una comunicación bidireccional, es decir, mientras el docente realizaba la retroalimentación de las inquietudes que se habían generado mediante la red social Twitter, los estudiantes participaban activamente con nuevos comentarios o nuevas preguntas; lo que denotaba que, los estudiantes estaban comprometidos con su propio aprendizaje, al ser tomados en cuenta con sus dudas o aportes. Al finalizar el experimento, se procedió con el análisis de la participación en los diferentes cursos. Ver Figura 21.

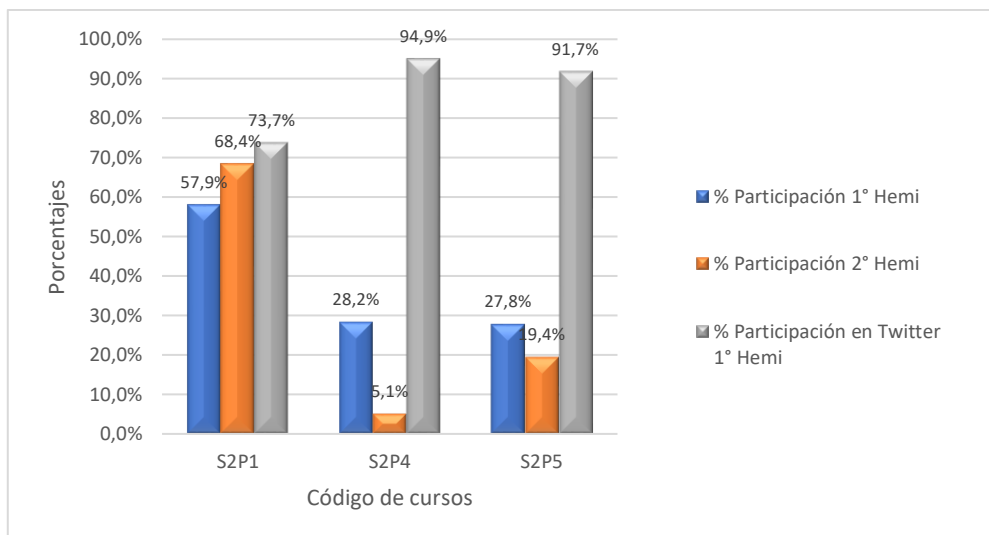


Figura 21 – Análisis de participación estudiantil

Con los resultados obtenidos, es posible determinar que el uso de Twitter durante una sesión de clase presencial incrementó la participación estudiantil; además, se consiguió mantener un ambiente controlado del uso de los dispositivos móviles en el aula, aprovechándolos exclusivamente para la actividad deseada.

En virtud que el experimento derivó resultados favorables, y con base a la revisión sistemática realizada en el primer período de enero/2007 a marzo/2019 en (Pérez-Suasnavas et al., 2020a); donde se pudo constatar la falta de prácticas pedagógicas en la literatura previa, se identificó la necesidad de proponer una estrategia didáctica claramente estructurada, que sea viable en su aplicación y pueda ser validada mediante casos de estudio. El detalle de la estrategia didáctica desarrollada se describe en el siguiente epígrafe.

#### 4.2.3 Propuesta de estrategia didáctica, para fomentar la participación estudiantil universitaria

Como se mencionó en el Capítulo 3, no existe una práctica pedagógica idónea para la inclusión de la red social Twitter en la educación superior, de forma particular que contemple Minería de Datos; por lo que, se realizó una propuesta de estrategia didáctica, que permita minimizar los factores que limitan la participación estudiantil durante las sesiones de clases presenciales. Además se realizó la evaluación de la participación estudiantil y la identificación de los factores asociados a la reducida participación (Pérez-Suasnavas et al., 2020b).

El componente principal de la estrategia es la participación estudiantil, por lo que, es importante describir el origen y forma de recolectar estos datos en esta primera etapa, parte de esta información se abordó en la sección 4.2 Desarrollo; y que son detallados a continuación:

- Para recolectar la participación estudiantil, el docente contaba con el registro personal en una hoja de cálculo, con distintos campos; el cual permitía marcar por cada sesión de clase, la participación de cada estudiante ya sea de forma voluntaria o direccionada. Si el estudiante intervenía en más de una ocasión, las participaciones se acumulaban en cada Hemi. Ver ejemplo Figura 22.

	A	B	C
1	Código Estudiante	Nota 1 Hemi	Participa 1 Hemi
2	E0001	18,8	5
3	E0002	17,5	0
4	E0003	8,8	0
5	E0004	11,7	2
6	E0005	11,2	10
7	.....	.....	.....

Figura 22 – Registro de participaciones por estudiante

- Al finalizar cada Hemi, se totalizó el número de participaciones estudiantiles.
- Una vez totalizada la columna de “Participa 1 Hemi”, se procedió con el cálculo del porcentaje de participación en cada Hemi, de acuerdo con el número de estudiantes matriculados en el período académico.
- Este proceso se realizó por cada período académico analizado.

#### 4.2.4 Evaluación de la participación estudiantil

Fundamentados en el estudio realizado por Pérez-Suasnavas et al. (2019), donde existe evidencia de la reducida participación estudiantil, se estructuró una escala de medición en porcentajes (%) para evaluar la participación estudiantil (Pérez-Suasnavas et al., 2020b). Ver Tabla 17.

Tabla 17 – Escala de medición de participación estudiantil

Escala de medición (%) de participación	Intervalo
0% – 19,99%	Muy bajo
20% – 39,99%	Bajo
40% – 59,99%	Medio
60% – 79,99%	Alto
80% – 99,99%	Muy alto



Con esta escala de medición, se evaluaron cada uno de los períodos de estudio, esto es, entre abril/2015 a marzo/2018, con una muestra de 535 estudiantes. En el epígrafe 4.2. Desarrollo, se describió el procedimiento para calcular el porcentaje de participación por Hemi, datos que se ven reflejados en la Tabla 18.

Tabla 18 – Porcentaje y nivel de participación por período y por Hemi

Períodos académicos	Total estudiantes	% Participa. 1 Hemi	Nivel de participación 1 Hemi	% Participa. 2 Hemi	Nivel de participación 2 Hemi
Abr15-Ago15	84	38,72%	Bajo	14,84%	Muy bajo
Sep15-Feb16	92	37,02%	Bajo	5,67%	Muy bajo
Abr16-Ago16	90	29,37%	Bajo	6,78%	Muy bajo
Oct16-Mar17	97	41,31%	Medio	0,00%	Muy bajo
Mar17-Ago17	72	32,37%	Bajo	20,33%	Bajo
Oct17-Mar18	100	56,08%	Medio	29,13%	Bajo
<b>TOTAL</b>	<b>535</b>	<b>39,15%</b>		<b>12,79%</b>	

De la Tabla 18 se observa que, el nivel de participación estudiantil es Bajo, especialmente en el 2° Hemi; incluso en el período octubre/2016 a marzo/2017 hay total ausencia de participación en el 2° Hemi; por tanto, se induce al análisis estadístico, para medir el comportamiento y tendencia de los datos. Ver Tabla 19.

Tabla 19 – Medidas de tendencia central y dispersión

Medida	1° Hemi	2° Hemi
Media	39,15%	12,79%
Mediana	27,87%	10,81%
Varianza	0,88%	1,16%
Desviación estándar	9,36%	10,76%
Coefficiente de variación	23,90%	84,08%

De la Tabla 19 se pueden obtener los siguientes resultados:

- La media de participación en el 1° Hemi es mayor que en el 2° Hemi.
- La variabilidad de participación del 1° Hemi es menor al 2° Hemi.
- En la prueba *T*, el valor obtenido fue de 6,63, valor que se contrasta con el valor *T* teórico, con un nivel de significancia del 5%, de 2,015 para los 6 períodos académicos.
- Dado que el valor *T* calculado es mayor que el valor *T* teórico, se puede inferir que existe diferencias entre las participaciones del 1° y 2° Hemi.

- El coeficiente de variación del 1° Hemi es menor al 25%, por lo que se consideran grupos homogéneos, mientras que para el 2° Hemi es mayor, evidenciando que las estimaciones son poco precisas por tener datos más dispersos; hallazgos que son justificables por la ausencia de participaciones en el período octubre/2016 a marzo/2017.

El Bajo nivel de participación identificado, y la diferencia del coeficiente de variación obtenido en cada Hemi, genera la necesidad de identificar las causas asociadas a la reducida participación estudiantil; así como desarrollar una estrategia didáctica para minimizar el problema en cuestión.

Para determinar los factores que influyen en la participación estudiantil, fueron considerados los siguientes criterios:

- La muestra de 146 estudiantes de la carrera de Ingeniería Civil de la Universidad Central del Ecuador, matriculados en la asignatura de Programación 1, del período abril/2018-agosto/2018.
- Los resultados de la encuesta denominada «Social Network & Education».
- Se analizaron tanto los datos cuantitativos mediante la herramienta SPSS, así como los datos cualitativos con la herramienta Atlas. Ti.

#### 4.2.5 Encuesta – Parte 2

Para esta sección del diseño de la estrategia didáctica, se consideraron las preguntas 5, 6, 7, 8, 9 y 10 de la encuesta «Social Network & Education», cuyas respuestas se describen en las siguientes subsecciones.

##### 4.2.5.1 Pregunta 5: Si no comprendes algún concepto o explicación del profesor, ¿Qué haces?

Los estudiantes fueron encuestados sobre las opciones de consulta, cuando surgen inquietudes o dificultades durante la sesión de clase. Los estudiantes tenían la posibilidad de elegir más de una respuesta. Ver Figura 23.

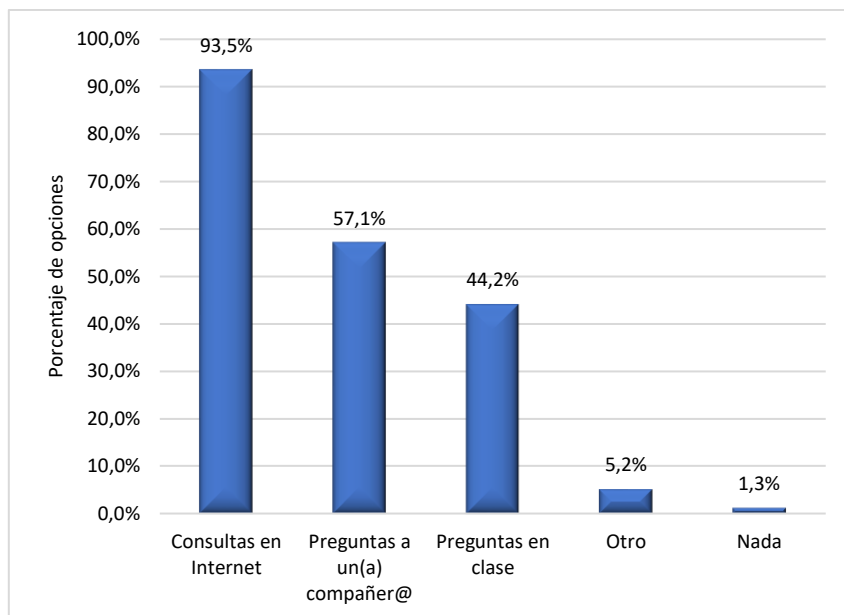


Figura 23 – Opciones de consulta estudiantil

De la Figura 23 se puede observar que, el 93.5% de estudiantes optan como fuente de consulta Internet; seguido del 57,1% que prefieren preguntar a sus compañeros; mientras que el 44.2% manifiestan que si realizan preguntas en clase. En menor porcentaje los estudiantes expresan tener otras causas, pero no fueron incluidas como parte de sus respuestas. Además, existe un reducido 1,3% de estudiantes que no realizan ninguna acción, frente a una duda, resultados que serían importantes analizar las posibles causas y acciones respectivas.

#### 4.2.5.2 Pregunta 6: Si no preguntas al profesor ¿En dónde buscas solventar la duda con mayor frecuencia?

En caso de que el estudiante no realice preguntas durante la sesión de clase; se deseaba ratificar las fuentes de consulta que utiliza el estudiante. De igual forma que la pregunta anterior, los estudiantes tenían la posibilidad de elegir más de una respuesta. Ver Figura 24.

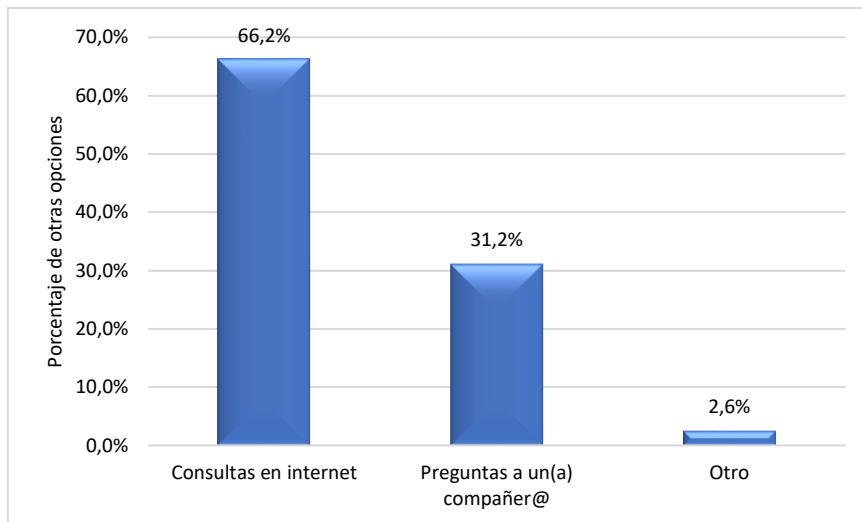


Figura 24 – Otras opciones de consulta

En la Figura 24 se puede evidenciar que, frente a la permanencia de una duda, el 66,2% de los estudiantes realizan consultas en Internet y el 31,2% preguntan a sus compañeros. Un 2,6% manifiesta otras fuentes, pero no las incluyeron en sus respuestas. Estos resultados denotan que los estudiantes prefieren evitar el contacto con el docente.

#### 4.2.5.3 Pregunta 7: ¿Cuál es la razón de no realizar preguntas en clase?

La pregunta fue de tipo abierta, de manera que los estudiantes tenían la libertad de expresar sus sentimientos, sobre los motivos por los que no realizan preguntas durante la sesión de clases presenciales. Ver Figura 25.




Figura 25 – Motivos de falta de participación en clase

En la Figura 25 se puede identificar que los principales factores asociados a la ausencia de realizar preguntas al docente durante la sesión de clase están: miedo (14,0%), vergüenza (12,9%), no interrumpir (11,8%), por burla de compañeros (9,7%) y por incomprensión del profesor (8,6%). Los demás motivos tienen menos del 7% de ocurrencia, pero son considerados importantes dentro del trabajo como factores que inciden en la falta de participación.

#### 4.2.5.4 Pregunta 8: Consideras que lo más importante de asistir a clases es

Con esta pregunta, se pretende identificar el nivel de importancia que los estudiantes otorgan a ciertos factores o condiciones, cuando asisten a clases. Ver Figura 26.




Figura 26 – Porcentaje de importancia de asistencia según factores

Respecto de la importancia de asistir a clases, en la Figura 26 se observa que la opinión de los estudiantes es diversa; sin embargo, es posible identificar los principales factores asociados: el 72,7% de estudiantes consideran muy importante escuchar al profesor; el 67,5% que consideran que es importante la asistencia a clases para realizar los ejercicios con el docente; el 65,8% asisten a clases para escuchar las explicaciones y disposiciones del docente; y el 61,3% para realizar las prácticas propuestas. Aunque el porcentaje de estudiantes que asisten solo por cumplir con la normativa es el más bajo (49,3%) respecto de los otros factores; este resultado se podría analizar con el obtenido en la pregunta 5, donde, el 1,3% de estudiantes no toma ninguna acción cuando tiene dudas durante una sesión de clase, lo que denotaría la existencia de una desmotivación estudiantil.

#### 4.2.5.5 Pregunta 9: ¿Cómo consideras que aprendes más?

Con esta pregunta, se pretende identificar la percepción de los estudiantes, sobre la forma en que ellos consideran, que alcanzan un mejor aprendizaje. Ver Figura 27.

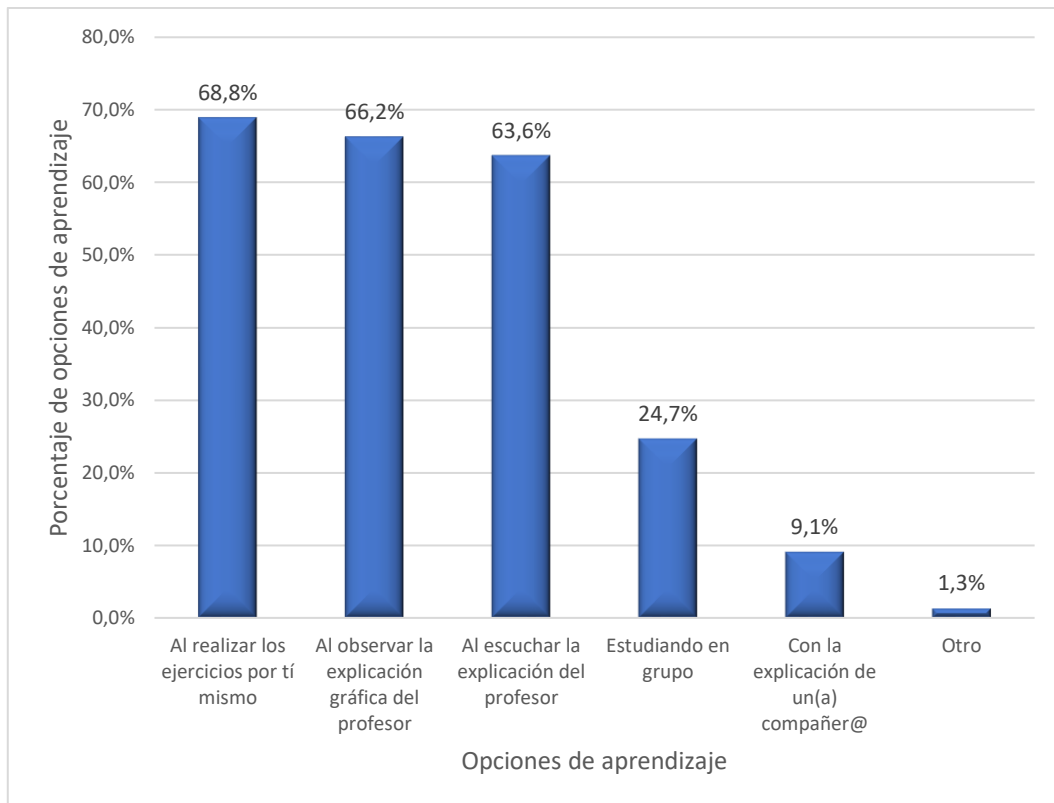


Figura 27 – Preferencias de aprendizaje

A partir de los resultados de la Figura 27, es posible identificar que más del 60% de estudiantes consideran que, aprenden de mejora forma al realizar los ejercicios por si solos, observando la explicación gráfica y al escuchar la explicación del docente. Por otra parte, el 24,7% de los estudiantes aprenden mejor con el estudio en grupo; y el 9,1% con la explicación de un compañero. Por lo que, el estilo que podría estar predominando el estilo de aprendizaje de los estudiantes es el auditivo/visual y el kinestésico (Alonso et al., 1994).

#### 4.2.5.6 Pregunta 10: Si fueras profesor ¿cómo solventarías las dudas de los estudiantes?

Otra pregunta importante de la encuesta es posicionar al estudiante en el rol de docente, y consultar sobre la forma en que ellos podrían solventar las dudas de los estudiantes. Frente a esta interrogante, las respuestas de los estudiantes se muestran en la Figura 28.




Figura 28 – Resolver dudas en el rol como docente



A partir de los datos presentados en la Figura 28, los estudiantes en el rol como docente solventarían las dudas de sus estudiantes principalmente de las siguientes formas:

- El 17,1% menciona que a través de resolver ejercicios base.
- El 13,5% manifiesta que mediante las tutorías y fomentando la actuación.
- El 9,9% a través de una explicación más detallada.
- El 5,4% con una explicación personalizada.
- Otras formas de solventar las dudas están por debajo del 5%, pero cuyas opciones pueden complementar el análisis del estilo de aprendizaje de los estudiantes.

Con los resultados obtenidos en cada una de las preguntas de la Encuesta – Parte 2, es posible realizar las siguientes inferencias:

- Más del 90% de estudiantes prefieren resolver sus inquietudes con búsquedas en Internet, y más del 50% optan por consultar a sus compañeros; por lo que, es posible determinar que los estudiantes evitan la comunicación con el docente durante las sesiones de clases presenciales.
- Aunque el 44,2% de estudiantes manifiestan que, si realiza preguntas en clase, más del 66,2% ratifica que su primera fuente de consulta es el Internet, seguido del 31,2% que pregunta a los compañeros.
- Los principales motivos que derivan una falta de participación en el aula son: miedo, vergüenza, no interrumpir la clase, posible burla de compañeros, incomprensión del profesor; razones que podrían estar relacionados con las preferencias de utilizar otros medios de consulta como es el Internet, puesto que evitan la comunicación con el docente.
- El 67,5% de los estudiantes consideran importante asistir a clases, por realizar los ejercicios en conjunto con el docente; no obstante, el 68,8% de los estudiantes mencionan que, la mejor forma de aprender es a través de la resolución de ejercicios por sí mismos; lo que daría una contradicción en la forma de aprender y las actividades durante la sesión de clase.
- El 66,2% de estudiantes consideran que aprenden más al observar la explicación gráfica y el 63,6% escuchar la explicación del docente, valores que son cotejados con el 72,7% de estudiantes que consideran importante la asistencia a clases por escuchar la explicación y el 65,8% por escuchar las explicaciones y disposiciones del docente.

- Existe un 31,2% de estudiantes que tienen como opción de consulta sus compañeros, valor que puede ser contrastado con el 24,7% de estudiantes que consideran que aprenden mejor estudiando en grupo.
- En el rol como docente, los estudiantes optarían por resolver las dudas académicas, principalmente a través de la resolución de ejercicios base, resultado que se confirma con la importancia que otorgan al asistir a clases, para realizar ejercicios juntamente con el profesor.
- Debido a que más del 60% de estudiantes prefieren reforzar sus conocimientos al realizar ejercicios por sí mismos, y en el rol de docente optarían por enseñar mediante la aplicación de ejercicios; se puede deducir que los estudiantes son más pragmáticos y prefieren el autoaprendizaje; motivo que también puede estar asociado a la reducida participación estudiantil.

De los resultados presentados en el presente capítulo, se destacan principalmente los relacionados a la participación estudiantil y los factores que inciden; ya que este tema es el eje central para el desarrollo de la estrategia didáctica, los cuales son descritos a continuación:

- En los 6 diferentes períodos académicos comprendidos entre abril/2015 y marzo/2018, la participación estudiantil decrementó entre el 1° y el 2° Hemi, con valores comprendidos entre el 12.1% y el 41.3%; por lo que, para el desarrollo de la estrategia didáctica se consideró de gran importancia realizar un análisis antes y después de la aplicación de la estrategia, que permita comparar los resultados de su incidencia en la participación estudiantil en cada Hemi.
- El 88,3% de los estudiantes que utilizan las redes sociales tienen como objetivo principal la comunicación con otras personas, y el 57,1% como medio de diversión; por lo que, el uso de los dispositivos móviles en el aula pueden ser un motivo de distracción para los estudiantes, factor que estaría ligado a la falta de participación académica en el aula.
- Con el pre-experimento descrito en la sección 4.2.2 Uso de Twitter como herramienta de participación estudiantil, se fomentó la participación activa y la comunicación con el docente mediante la red social Twitter; además se logró mantener el uso controlado de los dispositivos móviles en el aula. Estos resultados favorables son la base para la construcción de la estrategia didáctica, denotando que Twitter puede ser utilizado en la educación superior.
- Los resultados obtenidos en la Parte 2 de la Encuesta «Social Network & Education», revelan que los estudiantes evaden la comunicación con el docente para solventar las

inquietudes, situación que se pretende mejorar mediante la estrategia didáctica, al involucrar al estudiante en expresar sus dificultades, en primera instancia mediante la red social Twitter y luego, con la retroalimentación durante las sesiones de clases presenciales, el estudiante se identifique con su comentario y sea partícipe de la misma.

- El uso de Internet para solventar las inquietudes por parte de los estudiantes, no se pretende erradicar; el objetivo de la estrategia es hacer uso efectivo de estas herramientas para mejorar los procesos de enseñanza y aprendizaje.
- Respecto de los factores que inciden en la ausencia de preguntas durante las sesiones de clases presenciales, están asociados con los sentimientos, emociones propias del estudiante y su preferencia de aprendizaje. Con la aplicación de la estrategia didáctica, se pretende minimizar el problema de hablar en público por miedo a la burla, vergüenza o no querer interrumpir en clase; puesto que, con las redes sociales existe mayor posibilidad de socialización y participación ciudadana (Ayala, 2017).
- El 72,7% de estudiantes que consideran importante la asistencia a clases por escuchar la explicación del docente, constituye un resultado favorable para el desarrollo de la estrategia didáctica, en tanto que, el docente recopila la información proveniente de los comentarios realizados por los estudiante en la red social Twitter, y la usa para retroalimentar los temas de la asignatura que han generado mayor dificultad; de esta forma, el estudiante que publicó un comentario, estará identificado con su problema y tendrá la posibilidad de apropiarse de mejor manera el conocimiento impartido por el docente.
- El porcentaje de estudiantes que prefieren observar y escuchar al docente, puede estar relacionado con la reducida participación estudiantil, ya que prefieren ser espectadores de la clase.
- El porcentaje de estudiantes que prefieren resolver sus inquietudes con un compañero de clase, y que aprenden mejor trabajando en equipo, es un resultado que permitirá que las actividades realizadas en grupos, logren el objetivo deseado dentro de la estrategia didáctica a ser desarrollada.

Luego de realizar el análisis cuantitativo del nivel de participación estudiantil y el análisis cualitativo de los factores que inciden en la participación durante las sesiones de clases presenciales; se realizó la propuesta de la estrategia didáctica que permita minimizar los problemas identificados, para lo cual se desarrolló una secuencia descrita en 3 pasos: 1)

recolección y análisis de los datos provenientes de la encuesta; 2) fundamentación para el diseño de la metodología educativa; y 3) diseño de la estrategia (Pérez-Suasnavas et al., 2020b).

## 4.2.6 Fundamentación para el diseño de la estrategia didáctica

### 4.2.6.1 Razón de innovación

De acuerdo con los criterios de innovación educativa descritos por Ortega Cuenca et al. (2007), se procedió a cotejarlos con las actividades que forman parte de la propuesta de la estrategia educativa, con el propósito de denotar el carácter de innovación. Ver Tabla 20.

Tabla 20 – Criterios de innovación y actividades previas

Criterios	Actividades previas
<b>NOVEDAD</b>	Usar como precedente la dificultad académica identificada en el pre-experimento.
<b>INTENCIONALIDAD</b>	Mejorar la participación estudiantil.
<b>INTERIORIZACIÓN</b>	Aceptar la propuesta de mejora, tanto docentes como estudiantes.
<b>CREATIVIDAD</b>	Identificar la posibilidad de mejoras, establecer metas y diseño de estrategias, para aprovechar los recursos disponibles, esto es, las redes sociales, el uso de dispositivos móviles en el aula, registros del docente.
<b>SISTEMATIZACIÓN</b>	Planificar cada una de las fases de la estrategia, involucrando etapas de evaluación y de reflexión crítica.
<b>PROFUNDIDAD</b>	Mejorar el pensamiento crítico, la actitud y la participación estudiantil mediante la estrategia didáctica.
<b>PERTINENCIA</b>	Contextualizar el problema.
<b>ORIENTACIÓN A LOS RESULTADOS</b>	Reconocer que la estrategia es el medio para la mejora de los procesos de enseñanza y aprendizaje.
<b>PERMANENCIA</b>	Permanencia: (*)
<b>ANTICIPACIÓN</b>	El advenimiento de la pandemia obligó a un cambio de la recolección de comentarios reportados por los estudiantes.
<b>CULTURA</b>	Fomentar el trabajo en equipo.
<b>DIVERSIDAD DE AGENTES</b>	Identificar los principales actores de la educación: docente y estudiantes de la asignatura.

(\*) *“...Se ha mantenido durante el tiempo necesario para convertirse en la nueva normalidad” (Ortega Cuenca et al., 2007, p. 157); por lo que, no fue posible medir este criterio a causa del advenimiento de la pandemia.*

El docente por su parte tiene el propósito de integrar el área pedagógica con la tecnológica, de forma que se satisfagan los requerimientos de los actores de la educación, de acuerdo con el entorno en que se desarrollen. Por lo que, la estrategia didáctica que se propone en el presente

trabajo requirió de un esfuerzo importante en la etapa inicial por parte del docente para el desarrollo de algunas tareas manuales, y que forman parte de las fases de una innovación educativa, las cuales son descritas en la Tabla 21.

Tabla 21 – Fases de una innovación educativa y actividades realizadas por el docente

Fases de la innovación	Actividades
1. La comprensión del proceso de innovación	<ul style="list-style-type: none"> <li>• Identificar las principales dificultades del entorno que requieran ser analizadas.</li> <li>• Identificar los actores o situaciones que son parte del problema.</li> <li>• Identificar los datos e información disponible, tanto de docentes, como de estudiantes.</li> </ul>
2. El análisis de la información	<ul style="list-style-type: none"> <li>• Mantener un registro de datos relevantes que ayuden al seguimiento del problema.</li> </ul>
3. El establecimiento de prioridades	<ul style="list-style-type: none"> <li>• Planificar las posibles acciones a ser tomadas de acuerdo con las principales dificultades encontradas.</li> </ul>
4. La visualización de la situación y la definición de las estrategias	<ul style="list-style-type: none"> <li>• Determinar los instrumentos necesarios para el diseño de la estrategia, tanto tecnológicos como pedagógicos.</li> </ul>
5. La identificación de las estrategias	<ul style="list-style-type: none"> <li>• Analizar y comparar los instrumentos pedagógicos y tecnológicos que pueden ser utilizados en el entorno para la solución del problema.</li> </ul>
6. La instrumentación del plan	<ul style="list-style-type: none"> <li>• Diseño del flujo de trabajo de la estrategia para atender los imprevistos en las distintas fases.</li> </ul>
7. La evaluación	<ul style="list-style-type: none"> <li>• Desarrollo de los casos de estudio para la validación de la estrategia.</li> </ul>
8. La gestión del cambio	(*)

(\*) "...Para disponer de evidencias auténticas de los resultados de los procesos formativos, de la generación y gestión del conocimiento, deben transcurrir tiempos prolongados" (Ortega Cuenca et al., 2007, p. 152); por lo que, no fue posible medir este criterio a causa del advenimiento de la pandemia.

#### 4.2.6.2 Razón pedagógica y tecnológica

El docente, como eje fundamental para el diseño de una estrategia didáctica, debe incluir actividades innovadoras acorde a las necesidades del entorno y de los estudiantes (Ferrer, 2015); no obstante, requiere del apoyo tecnológico, pedagógico e institucional para su óptima aplicación (Bonwell y Eison, 1991). La estrategia didáctica propuesta incluye tanto orientaciones pedagógicas como tecnológicas, cuyas actividades se detallan a continuación:

- 1) Identificar las características del entorno de trabajo y condiciones en que se dicta la asignatura, para el diseño de una estrategia adaptativa. Ver Anexo D.
- 2) Considerar la clasificación de las estrategias por su perspectiva teórica (Cobos Peña, 2015; Díaz-Barriga y Hernández Rojas, 2004; Mayer, 1984, 1988; Vera y Vera, 2011), la cual permite al docente diseñar contenidos accesibles e innovadores en todo el proceso educativo, así como incidir en el nivel micro-curricular de la asignatura para medir los resultados en un futuro cercano (Handelsman et al., 2005). Esta clasificación contempla cuatro fases: a) generar conocimientos previos; b) orientar la atención del estudiante; c) organizar la información; y d) enlazar conocimientos. Ver Tabla 22.
- 3) Adaptar la estrategia pedagógica Justo a Tiempo para Enseñar «Just-in-Time to Teach» (JiTT) de acuerdo al entorno y estilo de enseñanza (Davis, 2009; Novak et al., 1999), utilizando las respuestas de los estudiantes en cada sesión de clase (Simkins y Maier, 2004, 2010); en combinación con otras innovaciones pedagógicas, como el trabajo grupal y la evaluación entre pares (Carter, 2012; Simkins y Maier, 2010), que permite generar una retroalimentación entre los estudiantes.
- 4) Incluir la red social Twitter, utilizada como prueba piloto en el período septiembre/2018 – febrero/2019 (Pérez-Suasnavas et al., 2019); cuyos resultados denotaron un incremento en la participación estudiantil durante las sesiones de clases presenciales.
- 5) Integrar el pensamiento computacional en las diferentes fases de la estrategia didáctica; desarrollando habilidades de pensamiento crítico, abstracción, descomposición, reconocimiento de patrones y diseño algorítmico (Vilanova, 2018).

#### 4.2.7 Diseño de la estrategia didáctica

La propuesta del diseño de la estrategia didáctica denominada Justo a Tiempo para Enseñar con Twitter, «Just in Time to Teach with Twitter» (JiTTwT), está conformada por 4 fases que integra diferentes métodos, técnicas y procedimientos, que son ampliamente descritas en la Tabla 22.

Tabla 22 – Fases de la estrategia didáctica

Perspectiva Teórica	Objetivos / Recursos	Actividad	Descripción de la actividad y tiempo de desarrollo
<p><b>1. Generar conocimientos previos</b></p>	<ul style="list-style-type: none"> <li>• Desarrollar material con significancia lógica.</li> <li>• Enviar tweet.</li> <li>• Contestar tweet.</li> <li>• Retroalimentar tweet.</li> </ul> <p><b>Recursos</b></p> <ul style="list-style-type: none"> <li>• Twitter.</li> <li>• Teléfono móvil.</li> <li>• Enlace a repositorio de material didáctico.</li> <li>• Docente.</li> </ul>	<p>Envío de tweet antes de la siguiente sesión de clase, para activar conocimientos de los estudiantes.</p> <p>Se coloca dos hashtags: 1) #Temaclase y la 2) Idea principal del #Ejercicio realizado la clase anterior. También se incluye el enlace al repositorio del material didáctico.</p> <p>Solicitar a los estudiantes que responda al tweet con el hashtag #Dudas, #Aprendizajes, #AlternativaSolucion, de forma que el docente identifique el aprendizaje o dificultades del estudiante, así como nuevas propuestas de solución.</p> <p>Cualquier estudiante puede responder a las #Dudas, #Alternativa, de sus compañeros, de forma que se promueva nuevos aprendizajes.</p> <p>El docente resuelve las #Dudas no solventadas en la siguiente sesión de clase presencial. Se comenta sobre las #Alternativa.</p>	<p>El docente revisa el material didáctico y los ejercicios realizados durante la sesión de clase presencial; para enviar el tweet a los estudiantes con los hashtags respectivos y el enlace al material didáctico de la asignatura (30 minutos). El envío del tweet se realiza dentro de las 24 y 48 posteriores a la sesión de clase.</p> <p>Los estudiantes responden al tweet del docente (tiempo estimado que le toma al estudiante: 10 minutos). Esta actividad se realiza en virtud de que los estudiantes usan el Internet como medio para solventar sus dudas, según los resultados de la encuesta; debido a las principales razones para no participar como son el miedo o vergüenza. Los estudiantes pueden comentar más de una ocasión, hasta 48 horas posteriores a su publicación.</p> <p>En la primera etapa de la estrategia, los tweets son leídos por el docente uno a uno, por lo que, el tiempo empleado por el docente fue entre 2 horas aproximadamente.</p>

Perspectiva Teórica	Objetivos / Recursos	Actividad	Descripción de la actividad y tiempo de desarrollo
			<p>A continuación, se utilizó la API Issues, aplicación que cumple diferentes funcionalidades: extraer y preprocesar los datos; para posteriormente predecir y visualizar la información a través de una nube de palabras que describe las dificultades reportadas por los estudiantes y que tienen mayor incidencia; y, por tanto, requieren mayor atención del docente. (30 minutos). Más detalles sobre la aplicación API Issues en el Capítulo 6.</p> <p>De entro los comentarios reportados, fueron considerados aquellos que expresan alguna dificultad.</p> <p><b>TIEMPO TOTAL (Sin API Issues): 2h40 horas.</b></p> <p><b>TIEMPO TOTAL (Con API Issues): 1h10 horas.</b></p>



Perspectiva Teórica	Objetivos / Recursos	Actividad	Descripción de la actividad y tiempo de desarrollo
<p><b>2. Orientar la atención del estudiante</b></p>	<ul style="list-style-type: none"> <li>• Destacar y premiar las respuestas efectivas realizadas entre compañeros.</li> <li>• Motivar la participación oral.</li> </ul>	<p>Iniciar la clase con los comentarios recibidos vía tweet, destacando los resultados de #Aprendizaje y #Dudas, tanto las resueltas entre compañeros, como las no contestadas.</p>	<p>Los resultados del cuestionario indican que, los estudiantes prefieren preguntar a los compañeros sobre sus dudas, por lo que, los comentarios y respuestas efectivas realizadas entre compañeros, son premiados con puntos extras al próximo trabajo grupal (0,5 puntos por participación). La premiación consta en el registro personal del docente (10 minutos).</p> <p>Sobre los tweets recopilados de los estudiantes en la red social, el docente toma como base los comentarios que expresan alguna dificultad, y en especial sobre los temas que no han sido resueltos entre compañeros; para la formulación de preguntas a los estudiantes de forma aleatoria e identificar la permanencia de dudas o generar nuevos aprendizajes (15 minutos). De esta manera, se fomenta la actuación; opción de respuesta que los estudiantes realizarían en calidad de docente, según lo expresaron en el cuestionario aplicado previamente.</p>
	<p><b>Recursos</b></p> <ul style="list-style-type: none"> <li>• Twitter.</li> <li>• Registros del docente en hoja electrónica.</li> <li>• Docente.</li> <li>• Estudiantes.</li> </ul>	<p>Preguntar a los estudiantes de forma aleatoria (para mantener la atención) si las #Dudas fueron resueltas.</p> <p>Retroalimentar a los estudiantes que mantengan inquietudes o aporten con nuevos aprendizajes, relacionando el conocimiento previo con el actual.</p>	<p>Las nuevas participaciones dentro del aula también son registradas y premiadas en las mismas condiciones que las participaciones virtuales (10 minutos).</p> <p>En el caso de que no se fomente la participación, el docente, presenta el material didáctico propio, el cual incluye los comentarios de los estudiantes de forma resumida.</p> <p><b>TIEMPO TOTAL: 35 minutos.</b></p>

Perspectiva Teórica	Objetivos / Recursos	Actividad	Descripción de la actividad y tiempo de desarrollo
<p><b>3. Organizar la información</b></p>	<ul style="list-style-type: none"> <li>• Presentar material de nueva sesión de clase.</li> <li>• Motivar y premiar la participación oral.</li> <li>• Conformar grupos de trabajo.</li> <li>• Aplicar evaluación entre pares.</li> </ul> <p><b>Recursos</b></p> <ul style="list-style-type: none"> <li>• Diapositivas.</li> <li>• Programa informático para la enseñanza de Programación 1.</li> <li>• Proyector.</li> <li>• Correo electrónico institucional.</li> <li>• Registros del docente en hoja electrónica.</li> <li>• Docente.</li> <li>• Estudiantes.</li> </ul>	<p>Presentar el material didáctico con el tema, objetivo, estrategia y recursos, complementando con información de Twitter.</p> <p>Explicación teórica del tema.</p> <p>Mostrar y explicar ejercicio base sobre el tema.</p> <p>Incrementar nivel de dificultad de los ejercicios.</p> <p>Solicitar a los estudiantes que aporten con alternativas de resolución o compartir enlaces con nuevo material #Aporte.</p> <p>Conformar grupos de trabajo para resolver la práctica de laboratorio.</p> <p>La calificación se realiza entre grupos, vía correo electrónico y bajo la rúbrica establecida.</p>	<p>Luego de solventar las inquietudes y retroalimentar a los estudiantes sobre las dificultades expresadas en la red social Twitter, se presenta y explica el material didáctico preparado por el docente, el cual incluye los comentarios realizados por los estudiantes de forma resumida en forma de nube de palabras, destacándose en mayúscula los temas más demandados (30 minutos). Actividad que es apreciada por los estudiantes, quienes dan la importancia al asistir a clases por escuchar la explicación del docente, y realizar ejercicios base, según los resultados del cuestionario aplicado previamente.</p> <p>Al tiempo que se realiza la explicación teórica y resolución de ejercicios, se solicita a los estudiantes generar nuevos comentarios sobre el nuevo tema presentado (10 minutos), si no existen inquietudes se continua con la siguiente actividad.</p> <p>Los grupos de trabajo se encuentran previamente conformados desde el inicio del periodo académico por afinidad, de manera que los estudiantes se agrupan para la realización de la práctica de laboratorio (5 minutos), para fomentar y/o fortalecer el trabajo en equipo.</p> <p>La realización de la práctica de laboratorio tiene la duración de 40 minutos y 5 minutos para el envío (tiempo total 45 minutos).</p> <p>La calificación de la práctica se realiza entre pares de acuerdo con la</p>

Perspectiva Teórica	Objetivos / Recursos	Actividad	Descripción de la actividad y tiempo de desarrollo
			siguiente rúbrica definida previamente: Cumplimiento del objetivo: 3 puntos Creatividad en la presentación: 3 puntos Lógica de programación: 7 puntos Uso de sintaxis correcta: 4 puntos Entrega a tiempo: 3 puntos  Tiempo aproximado de revisión y calificación (15 minutos).  <b>TIEMPO TOTAL: 1h45 minutos.</b>

Perspectiva Teórica	Objetivos / Recursos	Actividad	Descripción de la actividad y tiempo de desarrollo
4. Enlazar conocimientos	Registrar observaciones de los grupos evaluadores.	Solicitar a los estudiantes realizar comentarios sobre la práctica de laboratorio realizada; en virtud del número de estudiantes no es posible preguntar uno a uno; se solicita responder al tweet que el docente plantea evidenciando los #Aprendizajes alcanzados y #Dudas generadas.	Durante la sesión de clase presencial, el docente genera un nuevo tweet para recopilar las dudas generadas a partir la realización de la práctica de laboratorio (5 minutos). Los estudiantes disponen de (5 minutos) para contestar al tweet del docente.
		El grupo evaluador, emite la calificación al grupo evaluado a través de correo electrónico.	Con las respuestas de los estudiantes al nuevo tweet, el docente realiza la retroalimentación a los estudiantes (10 minutos).
	El docente destaca oralmente, las observaciones realizadas por los grupos evaluadores.	La clase finaliza con las conclusiones a los objetivos planteados (10 minutos).	
	El docente recapitula la clase, citando el objetivo, contrastando con los tweets de los estudiantes.		
			<b>TIEMPO TOTAL: 30 minutos.</b>

*Nota: La primera fase se realiza fuera del aula de clase, mientras que, la fase 2, 3 y 4 son desarrolladas durante la sesión de clase presencial, cuya duración es de tres (3) horas efectivas.*

Para una mejor comprensión de las fases de la Estrategia Didáctica JiTTwT descritas en la Tabla 22, se desarrolló un flujo que incluye los recursos y las actividades que forman parte de cada etapa. Ver Figura 29.

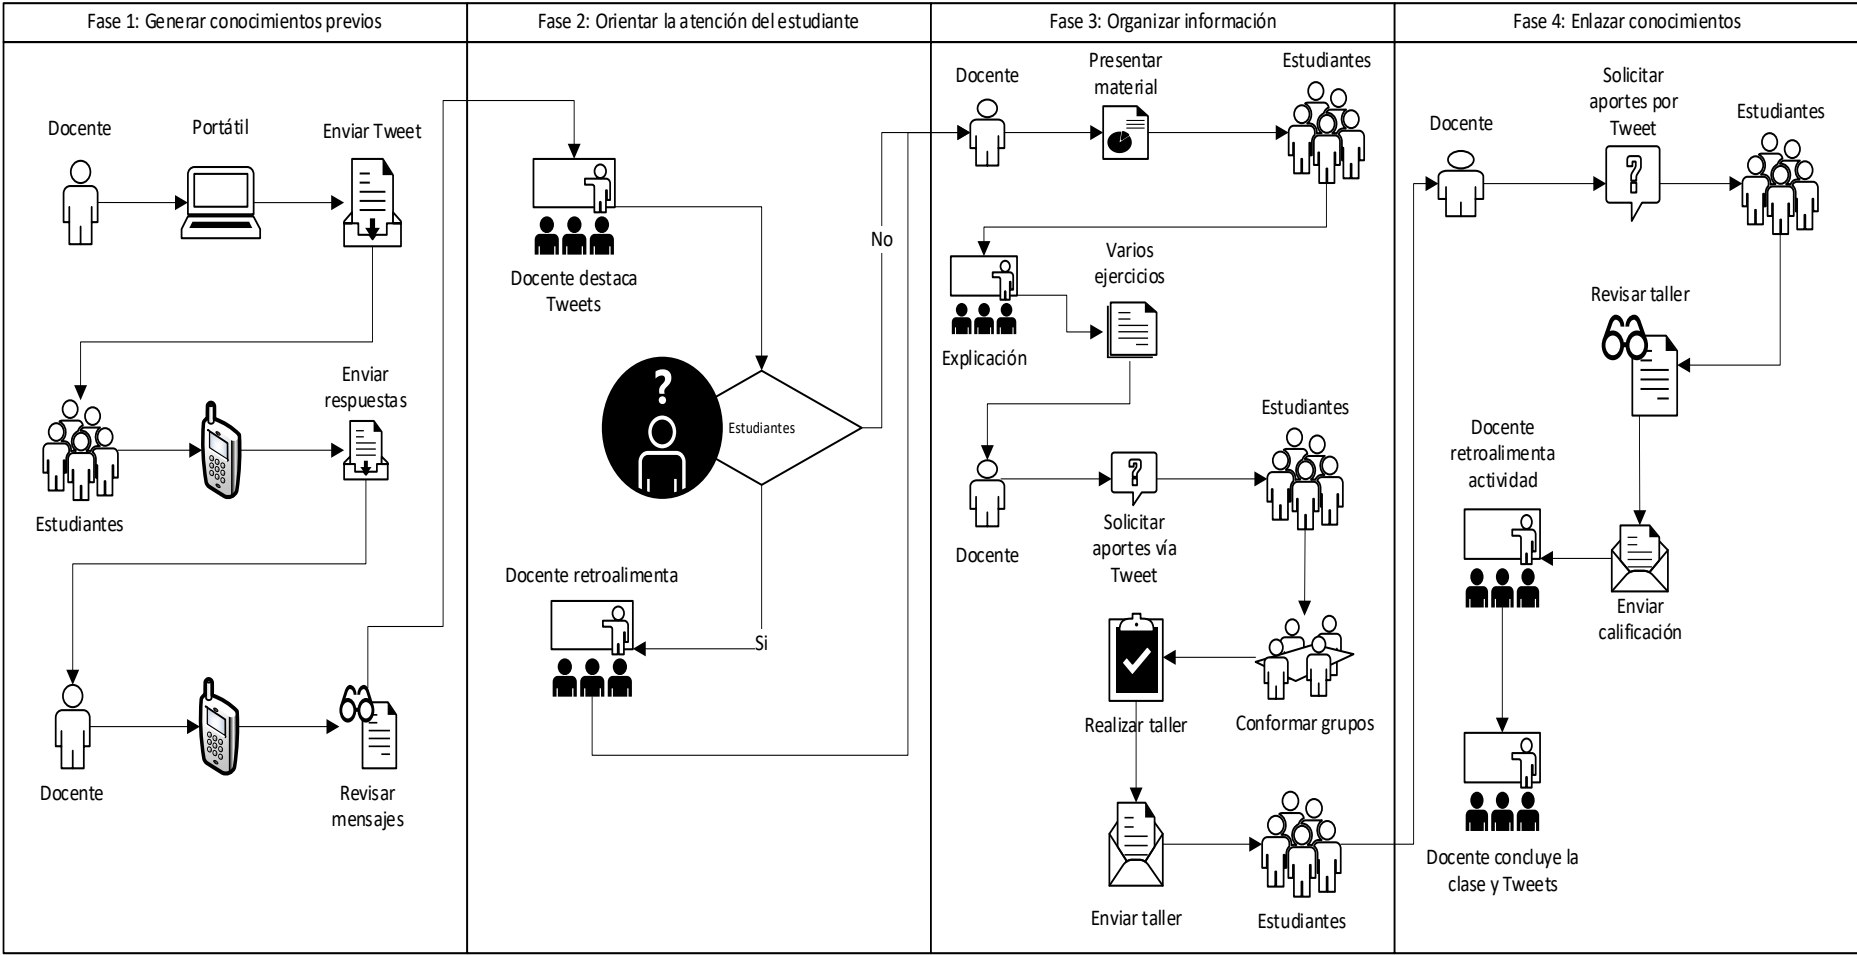


Figura 29 – Diagrama de Flujo de la Estrategia Didáctica JiTTwT

## Capítulo 5 – Validación de la Estrategia Didáctica JiTTwT

El capítulo quinto permite validar la Estrategia Didáctica JiTTwT, que fue descrita en el capítulo anterior; de forma que, se compruebe la viabilidad de ser implementada en instituciones educativas con similares características, para lo cual, se desarrollaron dos casos de estudio que validen esta estrategia; con lo cual se da cumplimiento al cuarto objetivo de la presente tesis doctoral.

### 5.1 Caso de estudio 1 – mejorar participación estudiantil

El caso de estudio 1, permite determinar si la Estrategia Didáctica JiTTwT mejora la participación estudiantil.

#### 5.1.1 Método

La Estrategia Didáctica JiTTwT tiene como objetivo mejorar la participación estudiantil durante las sesiones de clases presenciales; por lo que, se requiere determinar su incidencia en los procesos de enseñanza y aprendizaje en las aulas universitarias, por este motivo, se diseñó un caso de estudio que valide esta estrategia (Pérez-Suasnavas y Cela, 2020), con el planteamiento de los siguientes objetivos:

1. Determinar en qué medida la estrategia didáctica propuesta incrementa la participación de los estudiantes durante las sesiones de clases presenciales.
2. Precisar si la estrategia didáctica propuesta genera un cambio de actitud favorable en los estudiantes hacia el aprendizaje.
3. Describir la incidencia de la aplicación de la estrategia didáctica propuesta, en la autopercepción del pensamiento crítico de los estudiantes.

Las variables de estudio fueron las siguientes:

- Variable independiente: Estrategia JiTTwT.
- Variables dependientes: participación estudiantil, pensamiento crítico, actitud hacia el aprendizaje.

Para establecer la relación entre estas variables, se realizó un estudio cuasiexperimental con la participación de un grupo de control y un grupo experimental, por ser un método más orientado al ámbito educativo (Mousalli-Kayat, 2015; Murillo, 2011; Villasís-Keever y Miranda-Navales, 2016). Los estudios cuasiexperimentales se validan internamente, mediante la demostración de

la equivalencia de los grupos participantes y la equivalencia del proceso de experimentación (Hernández Sampieri et al., 2010), y que, para efectos del estudio se plantearon las siguientes hipótesis en el primer caso de estudio:

- h0: los estudiantes que reciben clases de Programación 1 utilizando la Estrategia Didáctica Metodología JiTTwT, reflejan un mayor nivel de participación durante las sesiones de clases presenciales.
- h1: los estudiantes que reciben clases de Programación 1 utilizando la Estrategia Didáctica JiTTwT, mejoran su actitud hacia el aprendizaje de la asignatura.
- h2: los estudiantes que reciben clases de Programación 1 utilizando la Estrategia Didáctica JiTTwT, demuestran un cambio en la autopercepción del pensamiento crítico hacia la asignatura.

### 5.1.2 Muestra

Para la validación de la estrategia didáctica y la comprobación de los objetivos, se establecieron las características principales de la muestra, las cuales son descritas a continuación:

- La muestra estuvo integrada por 144 estudiantes de 2° y 3° nivel de la carrera de Ingeniería Civil de la Universidad Central del Ecuador, cuyas edades bordeaban los 19 y 22 años; de estos, el 71,53% corresponden al género masculino y el 28,47% al femenino.
- Los estudiantes estaban matriculados en la asignatura de Programación 1.
- Se dispuso de un grupo de control y un experimental, previamente conformados con 64 y 80 estudiantes respectivamente.
- La Estrategia Didáctica JiTTwT fue aplicada en el período académico septiembre/2019 – marzo/2020, llevado a cabo de forma presencial.

### 5.1.3 Análisis previo del entorno – Caso 1

El advenimiento de la pandemia posterior al período septiembre/2019 – marzo/2020, irrumpió la planificación del presente estudio, de forma que no se pudo llevar a cabo la ejecución en otros períodos académicos presenciales; no obstante, los pasos para la aplicación de la estrategia descrita en la segunda columna del Anexo D, explica detalladamente cómo se puede replicar la Estrategia Didáctica JiTTwT para otras asignaturas.

De acuerdo con la información descrita en el Anexo D, existen algunos aspectos positivos y negativos que son considerados antes de aplicar la Estrategia Didáctica JiTTwT, los cuales son analizados a continuación:

- Contar con estudiantes “Repetidores” se considera un aspecto positivo, porque se asume que tienen un conocimiento previo, aportan al grupo y tendrían una participación más activa.
- La actitud que los estudiantes de 2° nivel demuestran durante las sesiones de clases presenciales, normalmente está caracterizada por la falta de puntualidad, responsabilidad, falta de participación en el aula y sin habilidad para el trabajo autónomo.
- El número de estudiantes de la muestra se considera significativo para la aplicación de la estrategia didáctica, según consta en los intervalos descritos en Tabla 7.
- El registro del docente es personal y cuenta con todos los campos necesarios para realizar la experimentación; no obstante, es un registro manual y forma parte de la labor docente.
- Se evidencia falta de equidad de género de los estudiantes de la muestra.
- La conformación de los grupos de estudio tiene su aspecto positivo y negativo; por una parte, el problema identificado está le pertenece al grupo experimental, del cual se aspira mejorar la participación estudiantil, mediante la Estrategia Didáctica JiTTwT; sin embargo, este criterio de asignación de grupos podría excluir alguna otra característica importante de los estudiantes.
- Las horas efectivas de clase con los estudiantes puede significar una dificultad para mantener la motivación y atención de los estudiantes.
- Programación 1 es una asignatura de formación básica de la carrera de Ingeniería Civil. Se pretende que los estudiantes la reconozcan como una materia transversal y que su aprendizaje les permita desarrollar diferentes habilidades; además será de ayuda en cursos superiores.
- La atención y motivación de los estudiantes, así como el seguimiento académico continuo, constituye un reto para el docente, debido al elevado número de estudiantes por curso.
- La falta de continuidad de las clases de Programación 1 es un aspecto negativo para el aprendizaje de los estudiantes, ya que el docente debe retroalimentar continuamente durante la sesión de clase lo aprendido.
- La asignatura de Programación 1 tiene un alto porcentaje de reprobación, por lo que, existe la necesidad de realizar estudios más profundos para analizar las causas, así como, encontrar o desarrollar estrategias que minimicen este problema.



- La disponibilidad de los equipos de cómputo efectivos puede inferir en el trabajo grupal; actividad que forma parte de la tercera fase de la Estrategia Didáctica JiTTwT.
- El uso excesivo de los dispositivos móviles en el aula pueden ser una distracción para el estudiante.
- El estilo de enseñanza del docente es de Autoridad Formal debido al gran número de estudiantes por curso.
- No se ha identificado el estilo de aprendizaje de los estudiantes, por lo que, al aplicar la Estrategia Didáctica JiTTwT es posible que omitan características y factores importantes que inciden en sus resultados.

#### 5.1.4 Instrumento

Para el presente Caso de Estudio, fueron utilizados los datos contenidos en el registro del docente, correspondiente al período septiembre/2019 a febrero/2020, que contenía información relacionada a: código del estudiante, género, matrícula, calificaciones por Hemi, asistencia, registro de participaciones estudiantiles por clase, trabajos grupales, estado final, entre otros datos.

#### 5.1.5 Desarrollo

Los resultados que se describen a continuación se presentan en función de los objetivos planteados, mediante el análisis entre el 1° y 2° Hemi para el primer objetivo; mientras que para el segundo y tercer objetivo mediante un análisis pre-test y pos-test de los datos.

##### 5.1.5.1 Determinar en qué medida la estrategia didáctica incrementa la participación de los estudiantes durante las sesiones de clases presenciales.

Para el análisis de la participación estudiantil, se utilizó el registro del docente correspondiente al período descrito en el epígrafe 5.1.2. Muestra, con información relacionada a: calificaciones, asistencia, número de participaciones estudiantiles por clase, trabajos grupales, entre otros datos. El cálculo del porcentaje de participaciones fue realizado de la siguiente forma:

- Si el estudiante participó al menos una vez en cada Hemi, en los registros del docente se marcó el campo respectivo mediante una variable dicotómica (1=si, 0=no) en los registros del docente; es decir, se registró con uno (1) si el estudiante participó, y con cero (0) si no lo hizo.

- Se totalizaron las participaciones de todos los estudiantes por cada Hemi, para calcular el promedio en función del número de estudiantes.

Además, se calculó la media y desviación estándar para analizar el comportamiento de los datos, tanto para el porcentaje de participación, como las medidas de tendencia central, que posteriormente serán comparados entre el 1° y 2° Hemi. Ver Tabla 23.

Tabla 23 – Participación estudiantil, 1° Hemi

Grupos	Media	Desv. Est.	(%) de participación
Control	0,47	0,50	46,9%
Experimental	0,33	0,47	32,5%

De la Tabla 23 se evidencia que, el porcentaje de participación es mayor en el grupo de control en relación al grupo experimental, durante el 1° Hemi; es decir, antes de aplicar la Estrategia Didáctica JiTTwT, el grupo de control denotaba que tenía un porcentaje de participación estudiantil mayor al grupo experimental, valor que se puede contrastar con el cálculo de la media (0,47) que también es mayor al grupo experimental (0,33); no obstante, la desviación estándar es mayor para el grupo de control, esto significa que tiene mayor dispersión de los datos respecto del registro de participaciones.

### 5.1.5.2 Aplicación de la Estrategia Didáctica JiTTwT

A principios del mes de enero de 2020, se aplicaron las 4 fases de la Estrategia Didáctica JiTTwT en cada una de las sesiones de clases, al grupo experimental, por el lapso de 6 semanas, y que, de forma sintetizada, se presentan las siguientes actividades realizadas en cada fase:

1. **Generar conocimientos previos:** en esta fase se identificaron los conocimientos del estudiante y se promovió nuevos saberes, mediante la recopilación de tweets sobre los aprendizajes y/o dudas de los estudiantes sobre una temática existente.
2. **Orientar la atención del estudiante:** se destacaron los tweets más relevantes y se enviaron tweets de retroalimentación.
3. **Organizar información:** en esta fase se presentó el material didáctico, que incluyó un resumen de los tweets de los estudiantes. Se motivó a los estudiantes a expresar sus

conclusiones o dudas que persistan. Se conformaron grupos de trabajo para resolver problemas de razonamiento lógico y abstracto.

4. **Enlazar conocimientos:** los talleres desarrollados fueron evaluados entre pares. Se solicitó nuevos tweets para destacar los resultados de aprendizaje y/o dudas generadas del taller, así como el envío de comentarios finales. El docente finalizó la sesión, contrastando el contenido de los tweets con el objetivo de la clase.

Luego de la aplicación de la Estrategia Didáctica JiTTwT al grupo experimental, y luego de finalizar el 2° Hemi, se contrastó el porcentaje de participación estudiantil, para los dos grupos de estudio. Ver Tabla 24.

Tabla 24 – Participación estudiantil, 1° y 2° Hemi

Hemis	Grupos	Media	Desv. Est.	(%) de participación
<b>I Hemi</b>				
	Control	0,47	0,50	46,9%
	Experimental	0,33	0,47	32,5%
<b>II Hemi</b>				
	Control	0,44	0,50	43,80%
	Experimental	0,43 (*)	0,49	42,50 (*)

En la Tabla 24 se puede evidenciar que:

- El porcentaje de participación y la media de los datos incrementó para el grupo experimental (\*), mientras que, el grupo de control disminuyó.
- El incremento del 10% en el porcentaje de participación estudiantil del grupo experimental permite aceptar la hipótesis h0 para este caso de estudio; la que afirma que, la Estrategia Didáctica JiTTwT mejora el nivel de participación estudiantil durante las sesiones de clases presenciales.
- Aunque el porcentaje de participación estudiantil incrementó, al igual que el valor de la media para el grupo experimental, se puede evidenciar que la desviación estándar también incrementó, esto permite inferir que existe mayor dispersión de los datos respecto del registro de particiones para este grupo.

Para el segundo y tercer objetivo de este caso de estudio, fue necesario validar un cuestionario aplicado a los dos grupos conformados, antes y después de la experimentación; de forma que,

se compruebe, por una parte, que los grupos de estudio se encontraban en igualdad de condiciones, y por otra, que el instrumento utilizado tenía características de fiabilidad y validez. Detalle del cuestionario Ver Anexo E.

### 5.1.6 Validación del cuestionario

La validación del cuestionario permitió evaluar la actitud hacia el aprendizaje de una asignatura, y la autopercepción del pensamiento crítico por parte de los estudiantes universitarios; de manera que, se valide el estudio cuasiexperimental, demostrando que los grupos de estudio estaban en igualdad de condiciones. Además, se identificó la existencia de una correlación entre estas dos variables.

Para el diseño y validación del instrumento, se utilizó la metodología aplicada por Fisher et al. (2001) descrita en las siguientes fases: 1) diseño del instrumento basado en un modelo; 2) determinación de los ítems del instrumento, de acuerdo al modelo propuesto; 3) validación del instrumento basado en el criterio de expertos; y 4) aplicación de la prueba piloto y análisis estadístico (Pérez-Suasnavas y Cela Rosero, 2022). El cuestionario se denominó: “Encuesta para medir la actitud hacia el aprendizaje de Programación y la autopercepción del pensamiento crítico”.

#### 5.1.6.1 Fase 1: Diseño del instrumento basado en un modelo

Conforme a las dimensiones para evaluar la actitud de los estudiantes, y la autopercepción del pensamiento crítico, se establecieron dos secciones:

##### **a) Sección: Actitud hacia el aprendizaje**

Para la primera sección que evalúa la actitud hacia el aprendizaje, se adaptó el cuestionario de Araque Ortiz et al. (2013), que mide el grado de aceptación (acuerdo o desacuerdo) hacia una asignatura, con preguntas orientadas al área de Ciencias de la Computación, de forma específica para el presente estudio, para la asignatura de Programación 1. Esta sección estuvo compuesta por trece (13) ítems, con el objetivo de identificar aspectos como: preferencias, predisposición, percepción, confianza, socialización, importancia de la asignatura en su vida académica, entre otras.

Se considera importante evaluar la actitud hacia el aprendizaje de Programación 1, ya que, como lo señala Payne (2017), la actitud está relacionada con la motivación y con la participación. En el presente estudio se pretende fomentar una participación activa, mediante la aplicación de la

Estrategia Didáctica JiTTwT durante las sesiones de clases presenciales, por lo que, es necesario medir la postura del estudiante en esta dimensión.

**b) Sección: Autopercepción del Pensamiento Crítico**

Para la segunda sección que mide la autopercepción del pensamiento crítico, los ítems fueron elaborados con base al cuestionario de competencias genéricas propuestas por Olivares-Olivares y Wong Tamez (2013); y estuvo conformado por diez (10) preguntas adaptadas a la asignatura de Programación 1 en sus tres dimensiones: habilidades de pensamiento crítico (Interpretación y análisis de información), actitudes hacia la complejidad (Juicio de una situación específica con datos objetivos y subjetivos), y la reflexión hacia las creencias propias (Inferencias de las consecuencias, basándose en el juicio autorregulado).

El pensamiento crítico es una de las habilidades deseadas de los programadores, por lo que, es necesario medir esta competencia (Vilanova, 2018; Zuleta Medina y Chaves Torres, 2011), no centrada en la perspectiva del docente, sino como se auto percibe el estudiante en el aprendizaje de programación; de forma que se puede constatar que la Estrategia Didáctica JiTTwT permite mejorar el rendimiento académico; y una mejora en este parámetro, significa que los estudiantes desarrollaron alguna habilidad básica al momento de aprender programación (Oviedo Galdeano y Ortiz Uribe, 2002).

**5.1.6.2 Fase 2: Determinación de los ítems del instrumento de acuerdo con el modelo propuesto**

En las dos secciones se utilizó la escala de Likert de cuatro niveles de menor a mayor, donde 1 significa Totalmente en desacuerdo y 4 Totalmente de acuerdo. La elección por cuatro posiciones se realizó con la intención de evitar un sesgo de neutralidad de las escalas.

Algunas preguntas tenían sentido positivo y otras negativo, por lo que, para la evaluación de reactivos, se consideró como inverso el peso en preguntas como “¿Estudiar Programación o realizar ejercicios no me asusta?”. Los ítems de las dos secciones se describen en la Tabla 25 y Tabla 26.

Tabla 25 – Ítems de la sección actitud

No.	Factor	Pregunta	Objetivo de la pregunta
1	Importancia	¿Considero a la Programación como una materia necesaria para mi profesión?	Reconocer los beneficios del aprendizaje de la asignatura en la formación integral en la carrera de ingeniería.

2	Desempeño	¿Pienso que no soy buen@ para Programación?	Determinar la autopercepción de los conocimientos, para identificar el nivel de motivación que tiene el estudiante.
3	Actitud	¿Estudiar Programación o realizar ejercicios no me asusta?	Identificar el nivel de tensión que puede generar el aprendizaje de una asignatura con alto grado de reprobación.
4	Diversión	¿Realizar ejercicios en Programación es una diversión para mí?	Contrarrestar la pregunta 2, que fue evaluada en “negativo”, para analizar la motivación.
5	Contenidos teóricos	¿Programación es una asignatura demasiada teórica para que pueda servirme de algo?	Reconocer los beneficios del aprendizaje de la asignatura, en el contexto de su practicidad en la formación integral durante la carrera de ingeniería.
6	Profundidad	¿Deseo alcanzar un conocimiento más productivo en Programación?	Identificar si el estudiante está motivado a desarrollar otras habilidades.
7	Predisposición	¿Programación es una de las asignaturas que más temo?	Identificar el nivel de tensión que puede generar el aprendizaje de una asignatura con alto grado de reprobación.
8	Confianza	¿Tengo confianza en mí cuando me enfrento a un problema a resolver con Programación?	Comprobar que los estudiantes tienen la capacidad resolver problemas de la vida real.
9	Socialización	¿Me divierte hablar con otros sobre Programación?	Determinar el nivel de motivación de los estudiantes.
10	Preferencia académica	¿Qué asignatura te gusta más?	Identificar el nivel de aceptación de una asignatura con alto grado de reprobación; además de reconocer otras habilidades que tienen los estudiantes.
		Algebra Lineal	
		Análisis Matemático	
		Estática	
		Física	
		Estadística	
		Teoría de la Programación	
		Ecuaciones Diferenciales	
Ensayo de Materiales			
11	Confianza	Dinámica	Identificar las habilidades que posee el estudiante, para fortalecer o desarrollar nuevas destrezas.
		Resistencia de Materiales	
		Mecánica de Fluidos	
		Soy buen@ para:	
12	Futura utilidad	¿Crees que saber Programación te ayudará cuando estés en un nivel superior?	Reconocer los beneficios del aprendizaje de la asignatura en la formación integral en la carrera de ingeniería.

13	Percepción	¿Consideras que a tu profesor le gusta enseñar Programación?	Comprobar si la motivación de los estudiantes está relacionada con la actitud del docente de la asignatura.
----	------------	--	---

Fuente: adaptación de Araque Ortiz et al. (2013)

Tabla 26 – Ítems de la sección autopercepción del pensamiento crítico

No.	Dimensión	Pregunta	Objetivo de la pregunta	
1	Interpretación y análisis de información	¿Entro en pánico cuando tengo que lidiar con algo muy complicado?	Reconocer si el estudiante tiene la capacidad de resolver problemas.	
2		¿Puedo explicar con mis propias palabras lo que de acabo de leer?	Evaluar la capacidad de análisis y síntesis, esta última, una destreza requerida para realizar comentarios en Twitter.	
3		¿Puedo establecer comparaciones entre diferentes métodos de resolución de problemas informáticos?	Medir la habilidad de razonamiento lógico.	
4		¿Utilizo mi sentido común para juzgar la relevancia de la información?	Identificar la capacidad de análisis.	
5		¿Prefiero la resolución de problemas informáticos basados en evidencias a mi percepción personal?	Identificar la capacidad de abstracción y análisis.	
6		Juicio de una situación específica con	¿Puedo resolver un problema informático, aunque no disponga de toda la información?	Medir la capacidad de abstracción y análisis.
7		datos objetivos y subjetivos	¿A pesar de las evidencias en mi contra, mantengo firmes mis creencias?	Identificar si un estudiante posee principios sólidos.
8			¿Prefiero aplicar un método conocido, antes de arriesgarme a probar uno nuevo?	Evaluar la habilidad de razonamiento lógico.
9		Inferencias de las consecuencias, basándose en	¿Expreso alternativas innovadoras, a pesar de las reacciones que pueda generar?	Medir el nivel de creatividad en la resolución de problemas.
10		el juicio autorregulado	¿Sé distinguir entre hechos reales y prejuicios?	Evaluar la capacidad de abstracción y análisis.

Fuente: adaptación de Olivares-Olivares y Wong Tamez (2013)

### 5.1.6.3 Fase 3: Validación de los instrumentos basado en el criterio de expertos

Para determinar la confiabilidad y validez del instrumento, según los pasos descritos por Hernández Sampieri et al. (2010), se realizó la medición en dos etapas:

En la primera etapa se consideró la participación de 10 expertos, con más de 10 años de experiencia en el área de programación y capacitación, quienes utilizaron una rúbrica con escala de Likert de cuatro niveles, para evaluar cuatro categorías: claridad, coherencia, relevancia y suficiencia de los ítems (Galicia Alarcón et al., 2017), según se describe en Anexo F. Para determinar el grado de correlación entre las respuestas de los expertos, se utilizó el coeficiente de validez de contenido (CVC) propuesto por Hernández Nieto (2011), para medir la validez de contenido de cada ítem y de todo el instrumento, a partir del nivel de concordancia entre los jueces.

En la segunda etapa se midió la fiabilidad del instrumento mediante Alpha de Cronbach, con el uso de la herramienta SPSS. En esta etapa se consideraron únicamente las preguntas en escala de Likert, 11 preguntas de la primera sección y 10 de la segunda, en total 21 preguntas.

Para determinar la relación entre las preguntas correspondientes a la sección de actitud estudiantil y de la sección de autopercepción del pensamiento crítico, se utilizó la Correlación de Spearman (Santabárbara, 2019).

#### 5.1.6.4 Fase 4: Aplicación de la prueba piloto y análisis estadístico

Para la prueba piloto, se consideró una muestra conformada por 122 estudiantes de 2° nivel de carrera de Ingeniería Civil de una universidad pública ecuatoriana, matriculados en la asignatura de Programación 2, en el período académico septiembre/2019 – febrero/2020, de estos, el 69,67% pertenecían al género masculino y el 30,33% al género femenino.

El cuestionario de las dos secciones fue desarrollado mediante la herramienta virtual LimeSurvey; difundido y aplicado a todos los estudiantes de la muestra, sin distinción de género, edad, ideología, etnia o condición académica. Una vez que fue aplicada la encuesta, se extrajeron los resultados en un archivo, para posteriormente codificar los datos con valores de 1, 2, 3 y 4 en preguntas con escala de Likert.

#### 5.1.6.5 Fiabilidad del instrumento

En la prueba piloto aplicada con los 21 ítems y mediante la herramienta SPSS, se obtuvo la estadística de fiabilidad, donde el Alfa de Cronbach inicial fue de 0,731. Según Frías Navarro (2014), índices de Cronbach mayores a 0,7 garantizan la validez interna en investigaciones exploratorias; sin embargo, acogiendo las recomendaciones de los expertos, se eliminaron 7 ítems, y con los 14 restantes se procedió a calcular nuevamente el Alfa de Cronbach, incrementándose éste a 0,828.



### 5.1.6.6 Validez del instrumento

La validez del instrumento evaluada por los 10 expertos, derivó los siguientes resultados de CVC: Claridad (0,897); Coherencia (0,886); Relevancia (0,831) y Suficiencia (0,896). Esto quiere decir que las respuestas entre los expertos coinciden.

### 5.1.6.7 Análisis descriptivo

Para el análisis descriptivo de los datos, se utilizó la herramienta SPSS que calcula la media de cada ítem del instrumento. Ver Tabla 27.

Tabla 27 – Análisis descriptivo

No.	Sección	Ítem	Media
1	<b>Actitud</b>	¿Realizar ejercicios en Programación es una diversión para mí?	2,8361
2		¿Programación es una asignatura demasiada teórica para que pueda servirme de algo?	3,0410
3		¿Deseo alcanzar un conocimiento más productivo en Programación?	<b>3,1230</b>
4		¿Tengo confianza en mí cuando me enfrento a un problema a resolver con Programación?	2,4836 (*)
5		¿Me divierte hablar con otros sobre Programación?	2,5574 (*)
6		¿Crees que saber Programación te ayudará cuando estés en un nivel superior?	<b>3,0738</b>
7	<b>Autopercepción del pensamiento crítico</b>	¿Puedo establecer comparaciones entre diferentes métodos de resolución de problemas informáticos?	2,8525
8		¿Utilizo mi sentido común para juzgar la relevancia de la información?	2,9426
9		¿Prefiero la resolución de problemas informáticos basados en evidencias a mi percepción personal?	2,6721 (*)
10		¿Puedo resolver un problema informático, aunque no disponga de toda la información?	2,2295 (*)
11		¿A pesar de las evidencias en mi contra, mantengo firmes mis creencias?	2,7541
12		¿Prefiero aplicar un método conocido, antes de arriesgarme a probar uno nuevo?	2,7131
13		¿Expreso alternativas innovadoras, a pesar de las reacciones que pueda generar?	<b>3,0082</b>
14		¿Sé distinguir entre hechos reales y prejuicios?	<b>3,0492</b>

Nota: La puntuación de cada pregunta está entre 1-4 en escala ordinal. Ver Anexo E.

De la Tabla 27 se deriva la siguiente información:

- De los 21 ítems en escala de Likert, fueron eliminados 7 por recomendación de los expertos, en especial los correspondientes a la sección de actitud.
- Respecto de la sección de actitud hacia el aprendizaje programación, los ítems eliminados estaban relacionados con importancia, desempeño, actitud, predisposición y percepción de la asignatura.
- En la sección de autopercepción del pensamiento crítico, se eliminaron ítems correspondientes a la dimensión de interpretación y análisis de información.
- Para determinar los ítems más favorables y los menos favorables, se consideró la media de las respuestas obtenidas por parte de los estudiantes.
- En la sección de actitud hacia el aprendizaje, los resultados más favorables fueron los ítems 3 y 6 (valores resaltados en negrita); mientras que, los menos favorables fueron los ítems 4 y 5 (\*).
- En la sección de autopercepción del pensamiento crítico, los ítems más favorables fueron el 13 y el 14 (valores resaltados en negrita); mientras que, los menos favorables fueron los ítems 9 y 10 (\*).

#### 5.1.6.8 Correlación entre secciones

Al ser un diseño cuasiexperimental, fue necesario establecer la correlación de las variables de estudio entre los ítems de las dos secciones (Hernández Sampieri et al., 2010), y mediante la herramienta SPSS, se agruparon las 6 preguntas de la sección actitud como primera variable, y las 8 preguntas de la sección de la autopercepción del pensamiento crítico como segunda variable, para obtener la correlación de Spearman, con los siguientes resultados:

- El nivel de significancia es menor que 0,01.
- El valor de correlación de Spearman es 0,513.

Con estos hallazgos se puede describir las siguientes conclusiones:

- Con el CVC obtenido, se determinó que existe concordancia entre los ítems del cuestionario; además, con el Alfa de Cronbach mejorado, los ítems poseen un nivel de confiabilidad aceptable, por lo que el instrumento es fiable y válido.
- Los resultados de la estadística descriptiva sobre la actitud determinan que, los estudiantes desean alcanzar un conocimiento más productivo en Programación, y consideran que la asignatura sería de utilidad en un nivel superior en su carrera. Y en lo que respecta a la autopercepción del pensamiento crítico, los estudiantes expresan

alternativas innovadoras, y consideran que pueden distinguir hechos reales y prejuicios, habilidades necesarias en los estudiantes de las carreras de ingeniería.

- Con el coeficiente de Spearman obtenido, se determinó que la actitud y la autopercepción del pensamiento crítico, tienen una correlación positiva moderada; es decir, a medida que la actitud de los estudiantes mejora, la autopercepción del pensamiento crítico también incrementa.

### 5.1.7 Aplicación del instrumento

Una vez que se dispuso de un instrumento fiable y válido, fue posible realizar un análisis pre-test y pos-test sobre la actitud hacia el aprendizaje en la asignatura de Programación 1, y la autopercepción del pensamiento crítico, entre el grupo de control y el grupo experimental.

El cuestionario fue aplicado a los 144 estudiantes descritos en el epígrafe 5.1.2 Muestra, a los dos grupos de estudio, a inicios del mes de enero de 2020; esto es, antes de aplicar la Estrategia Didáctica JiTTwT al grupo experimental; sin embargo, dieron respuesta únicamente 122 estudiantes, valor que representa el 84,72% de respuestas efectivas y que según Dilman et al. (2014), son suficientes para el estudio.

La encuesta fue aplicada vía Web, con la herramienta LimeSurvey, donde los estudiantes respondieron en escala de Likert los 14 ítems, además de las preguntas de introducción como: género, edad y código del curso.

### 5.1.8 Precisar si la estrategia didáctica genera un cambio de actitud favorable en los estudiantes hacia el aprendizaje.

Una vez que fueron recopilados los datos de la encuesta, se calculó la media y desviación estándar de cada pregunta, para observar el comportamiento de los datos en la sección de la actitud hacia el aprendizaje. Ver Tabla 28.

Tabla 28 – Estadística descriptiva pre-test, sección Actitud

		PRE-TEST			
		GRUPOS		Grupo experimental	
SECCIÓN		Grupo de control		Grupo experimental	
	ACTITUD HACIA EL APRENDIZAJE	Media	Desv. Est.	Media	Desv. Est.
1.	¿Realizar ejercicios en Programación es una diversión para mí?	2,72	0,774	2,83	0,762

2.	¿Programación es una asignatura demasiada teórica para que pueda servirme de algo?	2,35	0,916	2,25	0,685
3.	¿Deseo alcanzar un conocimiento más productivo en Programación?	3,35	0,694	3,38	0,654
4.	¿Tengo confianza en mí cuando me enfrento a un problema a resolver con Programación?	2,67	0,690	2,80	0,754
5.	¿Me divierte hablar con otros sobre Programación?	2,51	0,826	2,62	0,784
6.	¿Crees que saber Programación te ayudará cuando estés en un nivel superior?	3,35	0,668	3,43	0,661
PROMEDIO		2,82	0,76	2,88	0,72

Nota: La puntuación de cada pregunta está entre 1-4 en escala ordinal. Ver Anexo E.

De la Tabla 28 se destacan las 3 puntuaciones más altas en la media (valores resaltados en color verde), en cada grupo de estudio, a partir de esta consideración, se derivan los siguientes resultados:

- Los dos grupos de estudio mencionan que realizar ejercicios de Programación es una diversión.
- Tanto el grupo de control como el grupo experimental desean alcanzar un conocimiento más productivo de la asignatura.
- El grupo de control y el grupo experimental, consideran que la asignatura de Programación 1 será de ayuda en un nivel superior.
- De las 6 preguntas de la sección Actitud, 5 de ellas tienen una desviación estándar menor en el grupo experimental respecto al grupo de control; esto permite inferir que, en el análisis pre-test las respuestas de los estudiantes del grupo experimental están más cercanas a la media de los datos.
- Aunque se destacan los 3 valores más altos de la media, tanto en el grupo experimental como de control, el menor valor de la media obtenido corresponde a la pregunta 2: *¿Programación es una asignatura demasiada teórica para que pueda servirme de algo?*, con una media de 2,25 y 2,35 (resaltadas en color rojo) respectivamente; lo que deriva un análisis futuro sobre los motivos de estos hallazgos y la apreciación que tienen los estudiantes sobre la asignatura de Programación 1.
- El promedio de la media del grupo experimental (2,88) es superior al grupo de control (2,82). Este resultado induce a pensar que los estudiantes del grupo experimental, tienen una mejor actitud.

De forma similar a las actividades realizadas en la sección que evalúa la participación estudiantil, la Estrategia Didáctica JiTTwT fue aplicada en sus 4 fases al grupo experimental por el lapso de 6 semanas y se aplicó nuevamente la encuesta, una semana antes de finalizar el 2° Hemi, con el propósito de analizar el cambio generado en la actitud de los estudiantes, hacia el aprendizaje de la asignatura de Programación 1. Con los datos recopilados y tabulados, se procedió a calcular la media y desviación estándar, para observar el comportamiento de los datos. Ver Tabla 29.

Tabla 29 – Estadística descriptiva pos-test, sección Actitud

SECCIÓN	POS-TEST			
	GRUPOS	Grupo de control		Grupo experimental
ACTITUD HACIA EL APRENDIZAJE	Media	Desv. Est.	Media	Desv. Est.
1. ¿Realizar ejercicios en Programación es una diversión para mí?	2,85	0,731	2,82	0,757
2. ¿Programación es una asignatura demasiada teórica para que pueda servirme de algo?	3,11	0,809	2,99	0,728
3. ¿Deseo alcanzar un conocimiento más productivo en Programación?	3,22	0,762	3,04	0,824
4. ¿Tengo confianza en mí cuando me enfrento a un problema a resolver con Programación?	2,38	0,623	2,57	0,722
5. ¿Me divierte hablar con otros sobre Programación?	2,53	0,663	2,58	0,762
6. ¿Crees que saber Programación te ayudará cuando estés en un nivel superior?	3,09	0,727	3,06	0,694
PROMEDIO	2,86	0,72	2,84	0,75

Nota: La puntuación de cada pregunta está entre 1-4 en escala ordinal. Ver Anexo E.

En la Tabla 29 se destacaron las puntuaciones más altas de la media de los datos en los dos grupos de estudio (valores resaltados en color verde), a partir de estos resultados se pueden obtener las siguientes conclusiones:

- Los dos grupos de estudio consideran a Programación una asignatura muy teórica.
- Tanto en el grupo de control como el experimental, los valores más altos de la media son 3,22 y 3,04 respectivamente, por lo que, se mantienen en su criterio al considerar que, desean alcanzar un conocimiento óptimo en la asignatura. Además, la media de la pregunta 6 también es alta para los dos grupos; por tanto, los estudiantes piensan que Programación será de utilidad en un nivel superior de sus estudios; condición que es

muy favorable para el trabajo con los estudiantes, ya que reconocen que la asignatura es de utilidad.

- De las 6 preguntas de la sección Actitud, 2 de ellas tienen una desviación estándar menor en el grupo experimental respecto al grupo de control; esto permite inferir que, en el análisis pos-test las respuestas de los estudiantes del grupo experimental están más dispersas a la media de los datos.
- Aunque se destacan los 3 valores más altos de la media, tanto en el grupo experimental como de control, el menor valor de la media obtenido corresponde a la pregunta 4: *¿Tengo confianza en mí cuando me enfrento a un problema a resolver con Programación?*, con una media de 2,57 y 2,38 (resaltadas en color rojo) respectivamente; lo que permite inferir que, los estudiantes tienen confianza al enfrentarse a la resolución de un problema en la asignatura de Programación 1.
- El promedio de la media del grupo experimental (2,84) es menor al grupo de control (2,86), resultados que no son favorables para la aceptación de la hipótesis h1, respecto de la mejora en la actitud que tienen los estudiantes hacia el aprendizaje de programación.

Para contrastar los datos pre-test y pos-test en los dos grupos de estudio, se analizaron únicamente el promedio de la media y la desviación estándar de los datos. Ver Tabla 30.

Tabla 30 – Análisis pre-test y pos-test, sección Actitud

GRUPOS	PRE-TEST		POS-TEST	
	Media	Desv. Est.	Media	Desv. Est.
Grupo de Control	2,82	0,76	2,86	0,72
Grupo Experimental	2,88	0,72	2,84	0,75

De la Tabla 30, se puede deducir los siguientes resultados:

- El grupo experimental tiene una desviación estándar pos-test mayor al pre-test, valor que es comparable con la disminución del valor de la media.
- En el pos-test, la desviación estándar del grupo experimental es mayor al grupo de control; mientras que la media es menor.
- Una desviación estándar alta y una media baja al evaluar la actitud, indica que las respuestas de los estudiantes del grupo experimental tienden a estar más dispersos,

estos hallazgos que requieren de un análisis posterior sobre las posibles causas de estos resultados.

A pesar de que, las puntuaciones de la media de las preguntas 3 y 6, se mantienen como los más altos, de acuerdo con los datos presentados en la Tabla 30 se observa que, el promedio de la media del grupo experimental disminuyó en el 2° Hemi (pos-test), en comparación con el 1° Hemi (pre-test). Por lo tanto, la actitud de los estudiantes que reciben clases de programación utilizando la Estrategia Didáctica JiTTwT, no generaron un cambio de actitud favorable hacia el aprendizaje de la asignatura, y, por tanto, se rechaza la hipótesis h1 para este caso de estudio. El rechazo de la hipótesis h1, condujo a un análisis de las posibles causas que derivaron estos resultados inesperados; entre ellos, la presencia de estudiantes en condición de “Retirados”, particularmente para el grupo experimental. El detalle de este análisis se presenta en la subsección 5.1.10 Análisis estudiantes “Retirados”.

Por otra parte, es oportuno destacar que, la actitud como constructo, está compuesta de tres elementos básicos: cognitivos, afectivos y conductuales; y se ve influenciada por experiencias personales previas, actitudes significativas de otras personas, y el contexto sociocultural (Delfín de Manzanilla, 2007; Gargallo López et al., 2011). Aunque dentro del objetivo de la presente tesis doctoral no forma parte el análisis de la actitud de los estudiantes, es oportuno destacar que, la actitud es un factor que incide en la participación de los estudiantes como lo señalan los estudios realizados por Bond et al. (2020) y Mandefro (2019).

### 5.1.9 Describir la incidencia de la aplicación de la metodología en la autopercepción del pensamiento crítico de los estudiantes.

Con los datos recopilados los datos de la encuesta, se calculó la media y desviación estándar de cada pregunta, para observar el comportamiento de los datos en la sección de la autopercepción del pensamiento crítico. Ver Tabla 31.

Tabla 31 – Estadística descriptiva pre-test, sección Autopercepción del Pensamiento Crítico

SECCIÓN	PRE-TEST				
	GRUPOS	Grupo de control		Grupo experimental	
AUTOPERCEPCIÓN DEL PENSAMIENTO CRÍTICO		Media	Desv. Est.	Media	Desv. Est.
1. ¿Puedo establecer comparaciones entre diferentes métodos de resolución de problemas informáticos?		2,82	0,571	2,97	0,558

2. ¿Utilizo mi sentido común para juzgar la relevancia de la información?	2,79	0,590	<b>3,03</b>	0,558
3. ¿Prefiero la resolución de problemas informáticos basados en evidencias a mi percepción personal?	<b>2,84</b>	0,621	2,91	0,522
4. ¿Puedo resolver un problema informático, aunque no disponga de toda la información?	<b>2,33</b>	0,690	<b>2,28</b>	0,650
5. ¿A pesar de las evidencias en mi contra, mantengo firmes mis creencias?	2,81	0,693	2,85	0,618
6. ¿Prefiero aplicar un método conocido, antes de arriesgarme a probar uno nuevo?	2,82	0,735	2,74	0,644
7. ¿Expreso alternativas innovadoras, a pesar de las reacciones que pueda generar?	<b>2,84</b>	0,676	2,77	0,656
8. ¿Sé distinguir entre hechos reales y prejuicios?	<b>2,98</b>	0,641	<b>3,06</b>	0,609
<b>PROMEDIO</b>	<b>2,78</b>	<b>0,65</b>	<b>2,83</b>	<b>0,60</b>

Nota: La puntuación de cada pregunta está entre 1-4 en escala ordinal. Ver Anexo E.

De la Tabla 31, se destacan las 3 puntuaciones más altas en la media (valores resaltados en color verde), en cada grupo de estudio, a partir de esta consideración, se derivan los siguientes resultados:

- Los dos grupos de estudio, se perciben como estudiantes que pueden distinguir hechos reales y prejuicios.
- El grupo experimental manifiesta que puede establecer comparaciones entre diferentes métodos de resolución de problemas informáticos; además, utilizan el sentido común para juzgar la relevancia de la información.
- Los estudiantes del grupo de control prefieren resolver problemas informáticos basados en evidencias antes que la percepción personal; además pueden expresar alternativas innovadoras a pesar de las reacciones que se puedan generar.
- El promedio de la media del grupo experimental (2,83) es superior al grupo de control (2,78); estos resultados significan que los estudiantes del primer grupo auto perciben su pensamiento crítico de mejora forma que el segundo grupo.
- De las 8 preguntas de la sección Autopercepción del Pensamiento Crítico, todas las interrogantes tienen una desviación estándar menor en el grupo experimental respecto al grupo de control; esto permite inferir que, en el análisis pre-test las respuestas de los estudiantes del grupo experimental están más cercanas a la media de los datos.
- Aunque se destacan los 3 valores más altos de la media, tanto en el grupo experimental como de control, el menor valor de la media obtenido corresponde a la pregunta 4:



¿Puedo resolver un problema informático, aunque no disponga de toda la información?, con una media de 2,28 y 2,33 (resaltados en color rojo) respectivamente; lo que permite resaltar que los estudiantes tienen la habilidad de resolución de problemas informáticos independientemente de las circunstancias.

De forma simultánea y bajo las mismas condiciones adoptadas en la sección actitud hacia el aprendizaje, se aplicó la Estrategia Didáctica JiTTwT; de manera que, los resultados sean contrastados entre el 1° y 2° Hemi. Los cálculos de la estadística descriptiva se detallan en la Tabla 32.

Tabla 32 – Estadística descriptiva pos-test, sección Autopercepción del Pensamiento Crítico

POS-TEST				
SECCIÓN	GRUPOS			
	Grupo de control		Grupo experimental	
AUTOPERCEPCIÓN DEL PENSAMIENTO CRÍTICO	Media	Desv. Est.	Media	Desv. Est.
1. ¿Puedo establecer comparaciones entre diferentes métodos de resolución de problemas informáticos?	2,87	0,695	2,84	0,709
2. ¿Utilizo mi sentido común para juzgar la relevancia de la información?	2,93	0,539	2,96	0,614
3. ¿Prefiero la resolución de problemas informáticos basados en evidencias a mi percepción personal?	2,75	0,615	2,61	0,717
4. ¿Puedo resolver un problema informático, aunque no disponga de toda la información?	2,25	0,700	2,21	0,708
5. ¿A pesar de las evidencias en mi contra, mantengo firmes mis creencias?	2,69	0,690	2,81	0,821
6. ¿Prefiero aplicar un método conocido, antes de arriesgarme a probar uno nuevo?	2,76	0,693	2,67	0,746
7. ¿Expreso alternativas innovadoras, a pesar de las reacciones que pueda generar?	2,98	0,707	3,03	0,602
8. ¿Sé distinguir entre hechos reales y prejuicios?	3,07	0,539	3,03	0,674
<b>PROMEDIO</b>	<b>2,79</b>	<b>0,65</b>	<b>2,77</b>	<b>0,70</b>

Nota: La puntuación de cada pregunta está entre 1-4 en escala ordinal. Ver Anexo E.

En la Tabla 32 se destacaron las puntuaciones más altas de la media de los datos (valores resaltados en color verde), en los dos grupos de estudio, quienes comparten similares respuestas, y que son descritas a continuación:

- Utilizan el sentido común para juzgar la relevancia de la información.
- Expresan alternativas innovadoras, a pesar de las reacciones que pueda generar.
- Distinguen entre hechos reales y prejuicios.
- El promedio de la media del grupo experimental (2,77) es inferior al grupo de control (2,79); estos resultados indican que el grupo de control, se auto percibe mejor en la habilidad del pensamiento crítico.
- De las 8 preguntas de la sección Autopercepción del Pensamiento Crítico, 1 de ellas tiene una desviación estándar menor en el grupo experimental respecto al grupo de control; esto permite inferir que, en el análisis pos-test las respuestas de los estudiantes del grupo experimental están más distantes a la media de los datos.
- Aunque se destacan los 3 valores más altos de la media, tanto en el grupo experimental como de control, el valor más bajo obtenido es igual al pre-test, es decir corresponde a la pregunta 4, con una media de 2,21 y 2,25 (resaltados en color rojo) respectivamente. Estos hallazgos indican favorablemente que, los dos grupos de estudio mantienen el mismo criterio entre el 1° y 2° Hemi sobre la habilidad para resolver problemas informáticos en cualquier circunstancia.

El sentido común, el expresar alternativas innovadoras y el distinguir hechos reales y prejuicios, son criterios favorables, en tanto que, la asignatura de Programación 1, requiere entre otras habilidades, utilizar alternativas innovadoras para la resolución de problemas con sentido común.

Para contrastar los datos pre-test y pos-test en los dos grupos de estudio, de la autopercepción del pensamiento crítico, se analizaron únicamente el promedio de la media y la desviación estándar de los datos de la autopercepción del pensamiento crítico. Ver Tabla 33.

Tabla 33 – Análisis pre-test y pos-test, sección Autopercepción del Pensamiento Crítico

GRUPOS	PRE-TEST		POS-TEST	
	Media	Desviación Estándar	Media	Desviación Estándar
Grupo de Control	2,78	0,65	2,79	0,65
Grupo Experimental	2,83	0,60	2,77	0,70

Con base a los datos obtenidos en la Tabla 33 y el análisis descriptivo, se derivan los siguientes resultados:

- Se evidenció que no todos los parámetros sufrieron cambios positivos en la sección de la autopercepción del pensamiento crítico para el grupo experimental.
- El grupo experimental denota una leve disminución en la autopercepción del pensamiento crítico, mientras que el grupo de control refleja un reducido incremento.
- El grupo experimental tiene una desviación estándar pos-test mayor al pre-test, valor que es comparable con la disminución del valor de la media.
- En el pos-test, la desviación estándar del grupo experimental es mayor al grupo de control; mientras que la media es menor.
- Una desviación estándar alta y una media baja, indica que las respuestas de los estudiantes del grupo experimental tienen a estar más dispersos. Hallazgos que requieren de un análisis posterior sobre posibles causas de estos resultados.

Aunque el resultado no es el esperado, los estudiantes del grupo experimental expresan alternativas innovadoras en mayor cantidad que los estudiantes del grupo de control. Esta habilidad está asociada con la capacidad de resolver problemas, destreza requerida por los estudiantes que cursan la asignatura de Programación (Compañ-Rosique et al., 2015; Llorens Largo, 2015; Vilanova, 2018); sin embargo, no es posible afirmar que la Estrategia Didáctica JiTTwT genera cambios en los estudiantes en todos los aspectos de la autopercepción del pensamiento crítico, por tanto no se acepta la hipótesis h2 para este caso de estudio.

Medir la autopercepción del pensamiento crítico por parte de los estudiantes de ingeniería, constituye un aporte para la presente investigación doctoral, en tanto que, permite identificar al estudiante en 3 de las dimensiones descritas en la subsección 5.1.6.1. Fase 1: Diseño del instrumento basado en un modelo, esto es: a) interpretación y análisis de información; b) juicio de una situación específica con datos objetivos y subjetivos, y c) inferencias de las consecuencias, basándose en el juicio autorregulado); ya que las respuestas permiten observar desde la perspectiva del estudiante, su nivel de pensamiento crítico en la asignatura de Programación 1, la cual requiere entre otras habilidades, un nivel de criticidad para aplicar el razonamiento lógico y el discernimiento, para resolver diferentes problemas como lo menciona Pérez Angulo y Pedroza Palomar (2018).

El pensamiento crítico contempla diferentes debates sobre la pedagogía crítica, es decir, críticas desde el punto de vista de la política, así como desde la función de la educación en la sociedad; en su nivel más básico, el pensamiento crítico se trata de la adquisición de ciertas habilidades

como el hacer inferencias y el razonamiento, en especial, cuando se aplican a la disciplina de la educación superior (Davies, 2015).

### 5.1.10 Análisis estudiantes “Retirados”

Debido a los resultados no esperados en la sección de la actitud y la autopercepción del pensamiento crítico para el grupo experimental, una vez que se aplicó de la Estrategia Didáctica JiTTwT; surgió la necesidad de investigar las posibles causas asociadas a estos eventos. Para esto, se recurrió a la fuente de los datos, esto es, los registros del docente, para buscar algún indicio que haya motivado los resultados en el análisis entre el pre-test y el pos-test; de estos registros se pudo extraer la información relacionado con el número de estudiantes retirados en la asignatura. Ver Tabla 34.

Tabla 34 – Porcentaje de estudiantes retirados por grupo de estudio

	Número de estudiantes al inicio	Número de estudiantes retirados	% Estudiantes retirados
<b>Grupo de control</b>	64	1	1,56%
<b>Grupo experimental</b>	80	6	7,50%

De la Tabla 34, es posible identificar que el promedio de estudiantes “Retirados” es mayor para el grupo experimental. Resultado que puede haber incidido en los resultados del cuestionario descrito en el Anexo E; ya que la encuesta fue remitida a todos los estudiantes sin excepción; y es posible que haya sido contestado por los estudiantes que se habían retirado de la asignatura, generando resultados no favorables para el conjunto de respuestas.

En el tamaño de la muestra descrito al inicio de la sección, no fue posible excluir a los estudiantes que constaban como “Retirados”, ya que, algunos estudiantes legalizaron su retiro hasta mediados del 2° Hemi, o en otros casos, nunca realizaron el trámite respectivo. Este particular no podía ser conocido por el docente, sino hasta el ingreso final de calificaciones en el sistema SIIU. Por otra parte, la encuesta fue enviada a todos los estudiantes que pertenecían al mismo grupo y al tener la condición de anonimato, no fue posible llevar un control de los estudiantes que habían contestado la encuesta, ni su condición académica. Este hallazgo se considera importante, ya que podría ser un motivo que influyó en los resultados del grupo experimental, sobre todo si los estudiantes no le daban la importancia al cuestionario.

Según los hallazgos del Capítulo 4, sobre la baja participación estudiantil; y mediante el desarrollo del presente Caso de Estudio, se pretendió incrementar este porcentaje a través de

la aplicación de la Estrategia Didáctica JiTTwT. Una vez que la estrategia fue aplicada al grupo experimental, se consiguió un incremento de 10 puntos en el porcentaje y en la media de participación, resultados considerados favorables para aceptar la hipótesis h0. Sin embargo, la desviación estándar también incrementó en 0,02 puntos; valor que puede estar relacionado con el número de estudiantes “Retirados” en el grupo experimental; y que también pueden haber incidido en los resultados del cuestionario de la Actitud y Autopercepción del Pensamiento Crítico.

#### 5.1.11 Análisis posterior del entorno – Caso 1

Luego de la aplicación de la Estrategia Didáctica JiTTwT es posible destacar los siguientes resultados sobre el entorno en que se ejecutaron las diferentes actividades:

- La muestra de estudiantes disminuyó a causa del número de estudiantes “Retirados” en el 2° Hemi, tanto para el grupo de control como el experimental; de 144 estudiantes, al final se contó con 137 estudiantes, que representa el 95,14%; por lo que se considera una muestra significativa para el estudio.
- No se realizó el análisis de la condición de los estudiantes “Repetidores” y el efecto que tiene la estrategia didáctica sobre ellos.
- La actitud de los estudiantes no mejoró con la estrategia, resultado que puede estar asociado al estilo de aprendizaje de los estudiantes (auditivos/visuales), o debido a que los estudiantes pertenecen a los primeros niveles de formación, donde se evidencia falta de compromiso estudiantil.
- No se realizó el análisis del género de los estudiantes y la incidencia que tiene la estrategia didáctica, debido la falta de equidad de género.
- El problema identificado y focalizado en el grupo experimental, fue solventado mediante la Estrategia Didáctica JiTTwT.
- El número de créditos de la asignatura por semana, permite distribuir el tiempo de ejecución de las actividades, de las diferentes fases de la Estrategia Didáctica JiTTwT.
- El tiempo estimado para cada actividad de la Estrategia Didáctica JiTTwT se cumplió sin contratiempos en cada fase, a pesar de que existieron algunos equipos de cómputo no funcionales.
- No fue posible identificar el estilo de aprendizaje de los estudiantes, por lo que es posible que se haya omitido algún factor importante que incida en la Estrategia Didáctica JiTTwT.

- La falta de continuidad de las clases, ayuda al docente a realizar las actividades de la primera fase de la Estrategia Didáctica JiTTwT, esto es, descargar y leer los tweets enviados por los estudiantes.
- La estrategia didáctica motiva la participación activa, para extraer de la red social las principales dificultades que los estudiantes no pueden expresar durante las sesiones de clase.
- Aunque Programación tiene un alto grado de estudiantes que reprueba, tomar la asignatura permite que los estudiantes desarrollen la habilidad del pensamiento crítico, razonamiento lógico, abstracción, entre otras.
- Aunque la sección de la autopercepción del pensamiento crítico no mejoró en su totalidad, se destaca que, los estudiantes consideran a la asignatura de Programación 1 como importante para expresar alternativas innovadoras.
- Mediante la red social Twitter, el docente puede dar un seguimiento de las dificultades de los estudiantes.
- Se pudo aprovechar el uso de los dispositivos móviles de los estudiantes con fines académicos.
- Aunque el estilo de enseñanza del docente no se pueda transformar, la Estrategia Didáctica JiTTwT promueve diferentes habilidades: trabajo en equipo, evaluación entre pares, lo que conduce a un aprendizaje más autónomo por parte del estudiante; y el docente se constituye en un facilitador del conocimiento.

Es importante mencionar que, las hipótesis h1 y h2 no fueron aceptadas, una de las causas se mencionó en la subsección 5.1.10 Análisis estudiantes “Retirados”; pero también puede estar relacionada con el número de ítems eliminados en el cuestionario original; por lo que, existe la posibilidad de mejorar las preguntas del mismo; puesto que, un estudiante que mejora su actitud hacia el aprendizaje, también incrementa su autopercepción del pensamiento crítico; y un estudiante motivado genera una participación más activa (Payne, 2017; Zepke y Leach, 2010).

## 5.2 Caso de estudio 2 – mejorar rendimiento académico

El caso de estudio 2 permite identificar si la Estrategia Didáctica JiTTwT incide en el rendimiento académico, y posibilita alcanzar el objetivo 4, que consiste en validar la estrategia.

### 5.2.1 Introducción

Estudios previos, evidencian el uso de metodologías y estrategias educativas para mejorar el rendimiento académico (Fernández Solo de Zaldivar, 2017); sin embargo, las investigaciones experimentales que relacionan la participación estudiantil durante las sesiones de clases presenciales y el rendimiento académico en asignaturas del área de Ciencias de la Computación, son escasas (Gebre et al., 2014; Griffiths et al., 2016; Payne, 2017).

Como parte de la validación de la Estrategia Didáctica JiTTwT, se realizó un nuevo caso de estudio, que permitió determinar si esta estrategia tenía incidencia en el rendimiento académico de los estudiantes universitarios; para lo cual, se realizó un estudio cuasiexperimental transversal, con un grupo de control y un grupo experimental (Pérez-Suasnavas y Cela, 2022).

### 5.2.2 Muestra

La muestra considerada para este caso de estudio fue la misma que se describió en el caso de estudio 1.

### 5.2.3 Análisis previo del entorno – Caso 2

Al igual que en el primer caso de estudio, el advenimiento de la pandemia posterior al período septiembre/2019 – marzo/2020, no permitió aplicar la estrategia en nuevos períodos académicos.

De acuerdo con la información descrita en el Anexo D, existen algunos aspectos positivos y negativos que son considerados antes de aplicar la Estrategia Didáctica JiTTwT, los cuales son analizados a continuación:

- Contar con estudiantes “Repetidores” se considera un aspecto positivo, porque se asume que tienen un conocimiento previo y tendrían un mejor rendimiento académico.
- Los estudiantes de segundo nivel tienen una actitud poco comprometida con el aprendizaje.
- El alto grado de reprobación de la asignatura de Programación 1, conlleva a buscar mecanismos para que los estudiantes mejoren el rendimiento académico y aprueben la

asignatura; además de fomentar el desarrollo del pensamiento crítico y habilidades como: razonamiento lógico, pensamiento crítico, abstracción, entre otras.

### 5.2.4 Instrumento

Al igual que el párrafo anterior, el instrumento fue tomado del caso de estudio 1, es decir, se contó con los datos del registro del docente, que fueron clasificados por grupo de estudio y tabulados en hojas electrónicas, como se muestra en la Figura 30.

A	B	C	D	E	F	G	H	I	J
<b>ANÁLISIS GRUPO DE CONTROL</b>									
Código Estudiante	1 Hemi	Participa 1 Hemi	2 Hemi	Participa 2 Hemi	RETIRADO	PARTICIPA	MEJORA PROMEDIO	ESTADO	GÉNERO
E0001	18,80	1	18,30	1	NO	SI	NO	APRUEBA	M
E0002	17,50	1	13,10	1	NO	SI	NO	APRUEBA	M
E0003	8,80	0	12,30	0	NO	NO	SI	APRUEBA	M
E0004	11,70	0	11,80	0	NO	NO	SI	REPRUEBA	M
E0005	11,20	1	1,00	0	SI	SI	NO	REPRUEBA	F
....	....	....	....	....	....	....	....	....	....
....	....	....	....	....	....	....	....	....	....

Figura 30 – Tabulación de datos por grupo

De la Figura 30, se deriva la siguiente información:

- Las columnas B y D corresponden al promedio de calificación del 1° y 2° Hemi respectivamente. La comparación entre estos valores se refleja en la columna H.
- Las columnas C y E registran mediante una variable dicotómica (1=si, 0=no) si el estudiante participó al menos una vez en cada Hemi. La comparación se registra en la columna G.
- La columna F registra si el estudiante consta como “Retirado”.
- La columna I, indica el estado del estudiante al finalizar el período académico.
- La columna J registra el género al que pertenece el estudiante.
- Los campos cualitativos fueron transformados a valores cuantitativos para el cálculo de las medidas de tendencia central.

### 5.2.5 Desarrollo

La matriculación en una asignatura en la carrera de Ingeniería Civil hasta la presente fecha se realiza por cada período académico. Con relación a los períodos académicos, estos estaban conformados por 2 Hemis. Cada Hemi era evaluado sobre 20 puntos. La aprobación de una



asignatura requería una nota mínima de 28 puntos entre los 2 Hemi, además de registrar el 70% mínimo de asistencia. Esta forma de distribución del período académico y requisitos de aprobación de una asignatura estuvo vigente hasta el período septiembre/2019 a febrero/2020; ya que a partir del mes de marzo de 2020, como es de conocimiento mundial, el problema de salud pública generado por el virus del COVID-19 afectó todas las áreas de la sociedad, entre ellas la educación (Condori Melendez et al., 2021; Gazzo, 2020; Ordorika, 2020).

Como parte de los datos obtenidos por el docente, se incluyeron a los estudiantes que estaban catalogados como “Retirados”, esto es, debido a la falta de regularizaron de retiro por parte de los estudiantes para el 2 Hemi, por lo que, solo al finalizar el período académico, el docente podía identificar esta condición; además, las calificaciones de estos estudiantes inciden en el número de estudiantes reprobados y el promedio final que consta en el SIU.

### 5.2.5.1 Análisis Cuantitativo en el 1° Hemi

Con la tabulación de los datos del registro docente, se procedió con el cálculo de la media y desviación estándar del promedio de calificaciones y el porcentaje de la participación estudiantil para el 1° Hemi. Ver Tabla 32.

Tabla 35 – Medidas de tendencia central 1° Hemi

Grupos	Promedio calificaciones		Participación estudiantil		(% de participación)
	Media	Desviación Estándar	Media	Desviación Estándar	
Control	13,49	3,31	0,47	0,50	46,9%
Experimental	13,05	3,11	0,33	0,47	32,5%

En la Tabla 35, en el 1° Hemi se puede evidenciar los siguientes resultados:

- El grupo de control tiene una media más alta con relación al grupo experimental, tanto en calificaciones (rango de 0 a 20 puntos), como en participación.
- El porcentaje de participación es más alto en el grupo de control, con relación al grupo experimental.
- La desviación estándar de la participación estudiantil del grupo de control es mayor al grupo experimental, esto denota que las respuestas de los estudiantes del primer grupo son más dispersas; no obstante, la media también es alta para el mismo grupo.

- La desviación estándar y la media del promedio de calificaciones del grupo de control es mayor al grupo experimental; estos resultados permiten inferir que, aunque las calificaciones de los estudiantes del grupo de control están más dispersas, el promedio de calificaciones es mejor que el grupo experimental en el 1° Hemi.

### 5.2.5.2 Aplicación de la Estrategia Didáctica JiTTwT

La aplicación de la estrategia didáctica se realizó en igualdad de condiciones que el caso de estudio 1, es decir se cumplieron con todas las actividades que comprenden las 4 fases. Para posteriormente realizar el análisis en el 2° Hemi y establecer las diferencias encontradas.

### 5.2.5.3 Análisis Cuantitativo en el 2° Hemi

Para el 2° Hemi, se realizó el mismo cálculo que en el 1° Hemi, con relación a las medidas de tendencia central de las calificaciones y participación estudiantil, con la particularidad que se incluyeron las calificaciones de los estudiantes que constaban como “Retirados” en la asignatura, por las condiciones descritas en la subsección 5.2.5. Desarrollo. Ver Tabla 36.

Tabla 36 – Medidas de tendencia central 2° Hemi

Grupos	Promedio calificaciones		Participación estudiantil			Estudiantes retirados		
	Media	Desviación estándar	Media	Desviación estándar	(%) de participación	Media	Desviación estándar	(%) de retirados
	<b>Control</b>	12,02	3,48	0,44	0,50	43,80%	0,02	0,13
<b>Experimental</b>	12,58	4,23	0,43	0,49	42,50%	0,08	0,27	7,50%

En la Tabla 36 se realiza un análisis de los resultados obtenidos:

- La media de calificaciones en el 2° Hemi es mayor en el grupo experimental en comparación con el grupo de control.
- El porcentaje de estudiantes “Retirados” es mayor en el grupo experimental, con relación al grupo de control.
- La desviación estándar de la participación estudiantil del grupo de control es mayor al grupo experimental, esto denota que la participación de los estudiantes del primer grupo es más dispersa; no obstante, la media también es alta para el mismo grupo.
- La desviación estándar y la media del promedio de calificaciones del grupo de experimental es mayor al grupo de control; estos resultados permiten inferir que, aunque

las calificaciones de los estudiantes del grupo experimental están más dispersas, el promedio de calificaciones es mejor que el grupo de control en el 2° Hemi.

- El porcentaje de participación estudiantil en el 2° Hemi es mayor en el grupo de control; no obstante, se debe considerar que el porcentaje de estudiantes “Retirados” para el grupo experimental es mayor que el grupo de control.

#### 5.2.5.4 Análisis Cuantitativo entre el 1° y 2° Hemi sobre participación vs rendimiento y estudiantes retirados

Para evidenciar los cambios generados entre la participación estudiantil y el rendimiento académico entre los dos Hemis, se elaboró una tabla comparativa, con los promedios de calificaciones, participación y estudiantes “Retirados”. Ver Tabla 37.

Tabla 37 – Comparativo de promedios entre 1° y 2° Hemi

	Promedio calificaciones		(% de participación)		Promedio estudiantes retirados
	I Hemi	II Hemi	I Hemi	II Hemi	
<b>Control</b>	13,49	12,02	46,9%	43,80%	1,56%
<b>Experimental</b>	13,05	12,58	32,5%	42,50%	7,50%

De la Tabla 37 se derivan los siguientes resultados:

- El porcentaje de calificaciones disminuyó en los dos grupos de estudio entre 1° y 2° Hemi, aunque en menor valor en el grupo experimental.
- El porcentaje de participación estudiantil denota un incremento para el grupo experimental en el 2° Hemi.
- El porcentaje de estudiantes “Retirados” es mayor en el grupo experimental con relación al grupo de control.
- El promedio de calificaciones del grupo experimental es mayor al grupo de control en el 2° Hemi.
- El promedio final entre el 1° y el 2° Hemi del grupo de control fue de 12,76; mientras que, para el grupo experimental el promedio final entre los dos Hemis fue 12,82; por tanto, se puede denotar un mejor rendimiento académico del grupo experimental.

### 5.2.5.5 Análisis Cuantitativo sobre participación, rendimiento y aprobación

Para el análisis cuantitativo, fueron considerados los datos de la columna G, H e I de la Figura 30, descritos en la subsección 5.2.3. Instrumento. Para relacionar la participación estudiantil y el rendimiento académico, se analizaron los datos por estudiante y por grupo de estudio al final del período académico, de acuerdo con los siguientes cálculos:

- Se totalizó el número de estudiantes por grupo de estudio que participa y NO participa. Es decir, si el estudiante registró participación en el 1° Hemi o en el 2° Hemi, la columna G se marca con SI.
- Se totalizó el número de estudiantes por grupo que mejora y NO mejora su rendimiento académico entre el 1° y el 2° Hemi. Columna H.
- Se totalizó el número de estudiantes que aprueba o reprueba la asignatura. Columna I.

Para visualizar los datos según los cálculos descritos anteriormente, se elaboró una tabla comparativa entre el grupo de control y el grupo experimental. Los porcentajes que se presentan en la Tabla 38, representan el 100% de los estudiantes por grupo de estudio.

Tabla 38 – Análisis comparativo entre la participación estudiantil y el rendimiento académico

Grupo	Participación	% Estudiantes	% Estudiantes mejoran rendimiento		% Estudiantes NO mejoran rendimiento	
			Aprueban	Reprueban	Aprueban	Reprueban
De control	Participa	60,94%	15,63%	0,00%	37,50%	7,81%
	NO Participa	39,06%	6,25%	12,50%	10,94%	9,37%
Experimental	Participa	56,25%	25,00 %	1,25%	22,50%	7,50%
	NO Participa	43,75%	10,00 %	5,00%	13,75%	15,00%

A partir del análisis de los datos presentados en la Tabla 38, se pueden evidenciar los principales resultados:

- El porcentaje de participación es mayor en el grupo de control (60,94%), con relación al grupo experimental (56,25%); hallazgos que pueden estar asociados al número de estudiantes “Retirados” del grupo experimental.
- El mayor porcentaje de aprobación de la asignatura corresponde a los estudiantes del grupo experimental que mejoran su rendimiento; esto incluye a los estudiantes que participan (25%) o NO participan (10%), respecto de los estudiantes del grupo de control, que participan (15,63%) y NO participan (6,25%).

- El porcentaje de estudiantes que mejora el rendimiento, pero reprobaban la asignatura es menor en el grupo experimental, participe o No participe (6,25%), con relación al grupo de control (12,50%).
- El porcentaje de estudiantes del grupo experimental que participa, mejora el rendimiento, pero reprobaba la asignatura, es menor (1,25%) al porcentaje de estudiantes que NO participa (5,00%). Por su parte, el porcentaje de estudiantes del grupo de control que participa, mejora el rendimiento, pero reprobaba la asignatura, es menor (0%) al porcentaje de estudiantes que NO participa (12,50%). Con estos resultados se puede inferir que, a mayor participación, menor es el porcentaje de estudiantes que reprobaban la asignatura.
- El porcentaje de los estudiantes que participan, mejoran el rendimiento y aprueban, es mayor en el grupo experimental (25%), respecto de grupo de control (15,63%).
- Los estudiantes que participan, mejoran el rendimiento (aprueben o NO la asignatura) es mayor para el grupo experimental (26,25%), con relación al grupo de control (15,63%); aunque es importante mencionar que existe un 13,75% de estudiantes del grupo experimental que NO participa, NO mejora el rendimiento, pero aprueba la asignatura.
- Los estudiantes del grupo de control que participan, mejoran el rendimiento y aprueban (15,63%), es menor que el grupo de estudiantes que NO mejora el rendimiento y aprueban (37,50%); resultados que conducen a un análisis futuro.
- Los estudiantes del grupo de control que participan, no mejoran el rendimiento y aprueban (37,50%), es mayor que el grupo experimental (22,50%); resultados que conducen a un análisis futuro.
- Los estudiantes del grupo de control que participan, NO mejoran el rendimiento y reprobaban la asignatura (7,81%) es mayor que el grupo experimental (7,50%).
- El porcentaje de estudiantes que NO participa, reprobaba la asignatura, mejoran o NO el rendimiento (21,87%) es mayor para el grupo de control, con relación al grupo experimental (20%).

#### 5.2.5.6 Correlación de las variables

Para determinar si existió relación entre la participación estudiantil y el rendimiento académico, tanto del grupo de control, como el grupo experimental, se utilizó la Correlación de Pearson (Hernández Lalinde et al., 2018).

Las variables utilizadas fueron: participación estudiantil y rendimiento académico. Para establecer la correlación entre estas variables se utilizó la herramienta SPSS. Ver Tabla 39.

Tabla 39 – Correlación entre participación, rendimiento y estado

GRUPO CONTROL		Participa	Mejora rendimiento
Participa		1	
Mejora rendimiento		-0,229677367	1
GRUPO EXPERIMENTAL		Participa	Mejora rendimiento
Participa		1	
Mejora rendimiento		0,12476375	1

Los datos de la Tabla 39 permiten inferir los siguientes resultados:

- En el grupo de control la participación estudiantil tiene una correlación negativa con relación al rendimiento académico; esto significa que, a medida que la participación aumenta, el rendimiento disminuye.
- Para el grupo experimental, la participación estudiantil, tiene una correlación positiva con el rendimiento académico; es decir a medida que los estudiantes incrementan su participación, estos mejoran su rendimiento. Resultados que son comparables con los obtenidos en la Tabla 38.

Con los resultados del Caso de Estudio 2, se puede inferir que la Estrategia Didáctica JiTTwT incide en el rendimiento académico de los estudiantes; sin embargo, es necesario destacar los principales hallazgos:

- El promedio de calificaciones del grupo experimental no mejoró en el 2° Hemi, respecto del 1° Hemi.
- El porcentaje de estudiantes que mejoran el rendimiento y aprueban, fue mayor para el grupo experimental, con relación al grupo de control. Además, los estudiantes del grupo de experimental con mayor participación, tienen el rendimiento académico más alto. Por tanto, a mayor participación, mejoran el rendimiento y aprueban la asignatura.

### 5.2.6 Análisis posterior del entorno – Caso 2

Luego de la aplicación de la Estrategia Didáctica JiTTwT es posible destacar los siguientes resultados sobre el entorno en que se ejecutaron las diferentes actividades:

- La estrategia se aplicó en un solo período académico, igual que en el Caso de Estudio 1.

- El análisis entre el número de estudiantes “Repetidos” que mejoran el rendimiento y la estrategia didáctica no forma parte de los objetivos del presente trabajo.
- Mediante la Estrategia Didáctica JiTTwT se evidenció que, en el grupo experimental, existió una mejora del rendimiento académico; además se incrementó el número de estudiantes que aprueba y además participan activamente durante la sesión de clase.

### 5.3 Aportes de la Estrategia Didáctica JiTTwT

Con los resultados obtenidos en los dos casos de estudio, es posible inferir los principales aportes de la aplicación de la Estrategia Didáctica JiTTwT, y que forman parte del Objetivo 4 del presente trabajo, las cuales se describen a continuación:

- Definir una muestra significativa, esto es 95,14% de los estudiantes.
- Disponer de un instrumento válido y fiable para realizar el análisis pre y post test, cuya fiabilidad alcanzó el 0,828 y una validez de 0,8775.
- Contar con un conjunto de datos y registros del docente correctamente recolectados y que están acorde al contexto del problema.
- Mejorar la participación estudiantil del grupo experimental, durante las sesiones de clases presenciales, a pesar de las limitaciones encontradas.
- Aprovechar la carga horaria semanal de la asignatura de Programación 1, para aplicar las 4 fases de la Estrategia Didáctica JiTTwT.
- Considerar algunos aspectos negativos del entorno previamente identificados, para ser utilizados de forma positiva en la aplicación de la Estrategia Didáctica JiTTwT.
- La aplicación de la Estrategia Didáctica JiTTwT en los dos casos de estudio presentados, permitió por una parte, incrementar la participación estudiantil y por otra el rendimiento académico; y toda vez que, una participación activa está relacionada con la mejora del rendimiento (Chong González, 2017; Cortez Bailón et al., 2017; Jara et al., 2008; Payne, 2017); se puede inferir que la estrategia contribuye a una mejora de los procesos de enseñanza y aprendizaje; puesto que, los estudiantes exponen sus comentarios con mayor libertad en las redes sociales, y el docente cuenta con información para retroalimentar a los estudiantes en los temas que demanden más atención.
- Aunque la aplicación de la estrategia alcanzó algunos resultados favorables en el período de experimentación, como son: mejorar la participación estudiantil, mejorar el rendimiento de los estudiantes que participan, incrementar el porcentaje de estudiantes que aprueban la asignatura de Programación 1; es conveniente aplicar la

Estrategia Didáctica JiTTwT en otros períodos académicos en igualdad de condiciones; para corroborar los hallazgos de este estudio.

Todo el trabajo que hasta aquí se ha descrito, requirió un trabajo manual por parte del docente, de manera que, la siguiente etapa de la estrategia didáctica, fue automatizar algunos procesos; con la posibilidad de brindar al docente, la oportunidad de anticipar las necesidades de los estudiantes a través de su participación en una sesión de clase presencial; temas que serán abordados en los siguientes capítulos.



## Capítulo 6 – Clasificación y predicción de las dificultades académicas

En el presente capítulo se describen cada una de las etapas, para llegar a la identificación, clasificación de los datos y creación del modelo predictivo de las dificultades expresadas por los estudiantes universitarios; mediante la extracción de datos provenientes de la red social Twitter y el uso de técnicas de Minería de Datos; el entrenamiento y prueba del modelo, así como la validación del mismo con la aplicación de nuevos datos.

Con este capítulo se da cumplimiento al quinto y sexto objetivo de la tesis doctoral.

### 6.1 Introducción

Como se pudo evidenciar en el capítulo 3, los estudios que abordan temas sobre las dificultades de aprendizaje, valores humanos, portafolio estudiantil, motivos de deserción estudiantil, entre otros, son escasos; o solo contemplan la polaridad de los sentimientos o el comportamiento de los estudiantes o los problemas de aprendizaje; o a su vez, estos se limitan a hashtags o palabras clave previamente establecidas en el campo de la ingeniería; por lo que, se desarrolló una herramienta de apoyo para el docente, que permita identificar las dificultades más representativas de los estudiantes durante una sesión de clase, sin limitar el tipo de dificultad que podrían expresar.

Una vez que se dispuso de la Estrategia Didáctica JiTTwT debidamente validada a través de los dos casos de estudio, el siguiente paso fue automatizar los procesos en las distintas fases que incluye esta estrategia; no obstante, a consecuencia del problema de salud mundial experimentado a mediados del mes de marzo de 2020; todas las instituciones educativas en Ecuador se vieron obligadas a cambiar la modalidad de estudios (El Comercio, 2020), en similares condiciones que en otras partes del mundo (Cáceres Piñaloza, 2020; Gazzo, 2020; Valverde Kikut, 2020). Por lo que, la planificación de algunas actividades del presente trabajo doctoral, tuvieron que ser redireccionadas para dar cumplimiento a los objetivos propuestos.

Como parte de la Fase 1 de la Estrategia Didáctica JiTTwT, se solicitó a los estudiantes que, mediante su cuenta de Twitter, enviaran sus comentarios con el hashtag #Dudas, #Aprendizajes, #AlternativaSolucion, previo a la sesión de clase; de forma que, el docente identifique el aprendizaje o dificultades del estudiante, así como nuevas propuestas de solución, en el caso de existir el planteamiento de algún ejercicio en la asignatura de Programación 1. Esta fase debía ser aplicada en al menos dos períodos académicos; sin embargo, debido al cambio de modalidad

de estudios, y debido a políticas institucionales, se consideró otra fuente de recopilación de comentarios por parte de los estudiantes.

Para dar solución a los inconvenientes ocasionados en la modalidad de estudios virtual, se buscó alternativas que puedan mermar los problemas de la falta de continuidad en las sesiones de las clases presenciales; para ello, se tomó como opción el uso del Pensamiento Computacional (PC), debido a que es concebido como una habilidad para la solución de problemas, y puede ser aplicado en áreas como la Matemática, Física, Química, Sociología, Filosofía, entre otras; según lo señalan Rojas-López y García-Peñalvo (2020), y Ribeiro et al., (2013), es decir, el Pensamiento Computacional es una habilidad transversal en el mundo.

## 6.2 Método

El método utilizado para la clasificación y predicción de las dificultades se dividió en tres fases: 1) extracción y clasificación de los datos; 2) creación del modelo predictivo; y 3) aplicación del modelo sobre nuevos datos, que son descritas a continuación:

### 1) Extracción y clasificación de los datos

En esta fase se aplicó un estudio no experimental y longitudinal, durante cuatro períodos académicos, mediante un análisis cualitativo y cuantitativo de las dificultades expresadas por los estudiantes, en el aprendizaje de la asignatura de Programación 1, conforme a los procesos del Pensamiento Computacional, y las fases del ciclo de vida de los Sistemas de Información (SI); además, se cotejaron los resultados obtenidos entre los diferentes períodos académicos, toda vez que la pandemia generó cambios en todos los niveles educativos.

Por una parte, las habilidades que se conciben como parte del Pensamiento Computacional son: descomposición, abstracción, generalización de patrones y diseño algorítmico (Michaelson, 2015; Ortega-Ruipérez y Asensio Brouard, 2018; Quiroz-Vallejo et al., 2021; Zapata-Ros, 2015); y por otra, el ciclo de vida de los Sistemas de Información, incluye cuatro fases principales: análisis del problema, diseño del algoritmo, implementación del algoritmo, y evaluación (Joyanes Aguilar, 2008; Mac Gaul et al., 2008; Salgado Castillo et al., 2013).

### 2) Creación del modelo predictivo

Debido al objetivo del presente trabajo, esto es, proponer una estrategia didáctica para predecir las dificultades estudiantiles, sobre la base de los tweets enviados por ellos, en respuesta a los recibidos por parte del docente; se consideró la integración de diferentes técnicas como:

Minería de Textos, Procesamiento de Lenguaje Natural y Aprendizaje Profundo, para crear el modelo predictivo.

La Minería de Textos aparece como alternativa para resolver el problema de la sobrecarga de información, mediante la combinación de algoritmos y técnicas de Minería de Datos, Aprendizaje Automático, Procesamiento del Lenguaje Natural, recuperación de información, extracción de información, gestión del conocimiento y lingüística computacional basada en corpus (Feldman y Sanger, 2007), para transformar el texto a una representación más estructurada.

Por lo general, la Minería de Textos es utilizada para aplicaciones de tareas de clasificación y agrupación de grandes volúmenes de datos, provenientes de colecciones de documentos de texto no estructurados. Por ejemplo, para un sistema de clasificación automática, dependiendo del área de aplicación, se requiere de mucho tiempo para predefinir categorías y recopilar datos; mientras que, para tareas de agrupación, es necesario proporcionar elementos de datos sin etiquetar, para posteriormente establecer similitudes entre ellos (Jo, 2019). Para el presente trabajo, se utilizó la tarea de clasificación con aprendizaje supervisado, pues los registros contaban con una etiqueta o clase previa.

El Procesamiento de Lenguaje Natural, o más conocido como «NLP» por sus siglas del inglés; consiste en la habilidad de una máquina para procesar información mediante el uso del lenguaje natural (Eisenstein, 2018). En otras palabras, el NLP se basa en la comunicación del lenguaje natural y la computadora, que requiere el procesamiento de textos y oraciones (Moreira et al., 2021). El NLP tiene distintas aplicaciones, entre las que se puede mencionar: a) traducción automática; b) recuperación de la información; y c) extracción de la información.

En el Aprendizaje Automático los tipos más representativos de algoritmos son aquellos que ayudan a la toma de decisiones a partir de ejemplos conocidos; donde el usuario proporciona al algoritmo datos de entradas y salidas deseadas (Müller y Guido, 2016); mientras que, el Aprendizaje Profundo es un tipo específico de Aprendizaje Automático, que brinda un marco de trabajo más robusto para el aprendizaje supervisado, donde los modelos y conjuntos de datos son lo suficientemente grandes para la fase de entrenamiento con ejemplos etiquetados (Goodfellow et al., 2016).

Como se manifestó en la introducción de este capítulo, la planificación de las actividades de esta tesis fue redireccionada a causa del advenimiento inesperado de la pandemia, por lo que, para desarrollar el modelo predictivo fue necesario analizar y comprender los datos recolectados, ya que cada algoritmo es diferente y debe acoplarse al tipo de dato y al contexto del problema para que funcione mejor (Müller y Guido, 2016).

En primera instancia se había planificado aplicar la estrategia didáctica en mínimo dos períodos académicos, y deseable en cuatro. De acuerdo con el número de estudiantes que se matriculaban por período en la asignatura de Programación 1, se proyectaba recolectar entre 8.000 y 10.000 tweets. Debido a que la estrategia didáctica fue aplicada en un único período presencial, se recolectaron 1.996 comentarios. No obstante, a pesar del número de datos recopilados se desarrolló un modelo basado en redes neuronales recurrentes, para verificar su aplicabilidad.

Las Redes Neuronales Recurrentes «Recurrent Neural Networks» RNN están diseñadas para procesar datos secuenciales. Las RNN son un tipo de red neuronal importante, que puede producir resultados que generan nuevo texto, en contraste con los modelos de clasificación que solo pueden asignar etiquetas de clase (Müller y Guido, 2016). Las redes «feedforward» son la base conceptual de las RNN, ya que impulsan muchas aplicaciones de lenguaje natural (Goodfellow et al., 2016; Jurafsky y Martin, 2023; Tan et al., 2014).

Debido al número reducido de datos disponibles, en segunda instancia se optó por la creación del modelo predictivo mediante el uso de una red neuronal básica, de forma que, se pueda determinar si el modelo se ajusta mejor al número de los datos recolectados.

### 3) Aplicación del modelo sobre nuevos datos

La construcción de un modelo predictivo requiere la validación respectiva, misma que fue realizada sobre un nuevo conjunto de datos, el cual estuvo conformado por los 468 comentarios recolectados de la modalidad de estudios virtual.

## 6.3 Participantes

Al inicio del estudio, la población estuvo conformada por 1.112 estudiantes matriculados en 2° nivel de la carrera de Ingeniería Civil de la Universidad Central del Ecuador, quienes tomaban la asignatura de Programación 1. Las edades de los estudiantes fluctuaban entre 19 y 22 años, donde la media de estudiantes por género masculino y femenino fueron de 72,49% y 27,51% respectivamente. Tanto en la modalidad de estudios presencial como en la modalidad virtual, fueron considerados todos los estudiantes, sin distinción de género, ni de rendimiento académico.

Para la modalidad de estudios presencial, que comprendió un período académico, se contó con 144 estudiantes; mientras que, para la modalidad de estudios virtual, que comprenden tres períodos académicos, se contó con 968 estudiantes. Es importante señalar que, la población se

fue menguando por falta de participación de los estudiantes, particularmente en la modalidad virtual.

#### 6.4 Instrumentos

Los instrumentos que fueron utilizados en el presente estudio se describen a continuación:

- 1) Red social Twitter: este instrumento permitió al docente escribir varios tweets durante el período académico presencial (septiembre/2019 – febrero/2020), con el objetivo de inferir las dificultades y los resultados de aprendizajes expresados por parte de los estudiantes, con relación a las sesiones de clases presenciales de la asignatura de Programación 1. Todos los estudiantes tenían la opción de comentar o no al tweet del docente por más de una ocasión; todo esto con el propósito de recopilar la mayor cantidad de tweets posibles.

La obtención de la información proveniente de la red social Twitter, forma parte de la primera fase de la Estrategia Didáctica JiTTWT; donde, el docente escribe un tweet sobre el tema relacionado a la sesión de clase y espera que los estudiantes respondan con sus resultados de aprendizaje y/o dificultades, y a su vez se solventen las dudas entre compañeros. Para mayor detalle ver Tabla 22.

La extracción de los tweets se realiza mediante una de las funcionalidades de la API Issues, las cuales son descritas en la subsección 6.5.2.1.1 Diseño de la aplicación para extracción de datos. Los registros obtenidos de esta red social, son la base para estructurar el Corpus Ad-hoc de la asignatura de Programación 1, y posteriormente desarrollar el modelo predictivo de las dificultades estudiantiles. El conjunto de datos generado fue utilizado en la primera intervención.

- 2) Formularios de Office: este instrumento fue utilizado para crear 3 preguntas abiertas y recolectar las opiniones de los estudiantes, respecto de las dificultades suscitadas durante los períodos académicos virtuales, esto es entre junio/2020 y octubre/2021.

Los Formularios de Office poseen la opción de descarga de las respuestas en una hoja de cálculo, por lo que, una vez que finalizó el tiempo para contestar el cuestionario, ya no se permitían más respuestas. Con la hoja de cálculo generada, se pretendía construir un nuevo conjunto de datos para el modelo predictivo a ser desarrollado. Los datos obtenidos de este repositorio fueron utilizados para la segunda, tercera y cuarta intervención.

En el estudio se tomaron en consideración dos variables de análisis: a) dificultades de los estudiantes, y b) períodos académicos.

## 6.5 Desarrollo

### 6.5.1 Extracción y clasificación de los datos

De acuerdo con los estudios realizados por Kao (2010) y Michaelson (2015), la aplicación del PC se realizó como un proceso a seguir por parte del docente, el cual incluye los siguientes pasos:

#### 6.5.1.1 Descomposición del problema

Las tareas manuales realizadas por el docente en la Fase 1 de la Estrategia Didáctica JiTTwT, significó una carga laboral adicional para el docente. Además, la afectación en los procesos académicos a causa de la pandemia, condujo a investigar mecanismos de optimización de tareas, a través de la división del problema en diferentes intervenciones.

Una primera intervención fue considerar los datos a extraer del período académico ejecutado de forma presencial, y la segunda, analizar las condiciones y mecanismos para recolectar los datos de los períodos académicos virtuales.

#### 6.5.1.2 Abstracción

A pesar de que la abstracción es considerada una fase del Pensamiento Computacional, ésta fue utilizada en dos momentos diferentes en la primera etapa del problema: 1) para identificar la herramienta más efectiva para la extracción de los tweets, y 2) para identificar los comentarios que denotaban una dificultad y los que no lo tenían; así como aquellos tweets que producían ruido para el análisis.

#### 6.5.1.3 Generalización de patrones

Los tweets recolectados en la primera etapa, fueron clasificados de acuerdo con el tipo de dificultad, según las fases principales del ciclo de vida de los SI; además se aplicó el concepto de generalización en los conjuntos de tweets que implicaban la misma idea.

#### 6.5.1.4 Diseño algorítmico

El diseño algorítmico es la representación de la resolución del problema, el cual se describe paso a paso en el siguiente diagrama. Ver Figura 31.

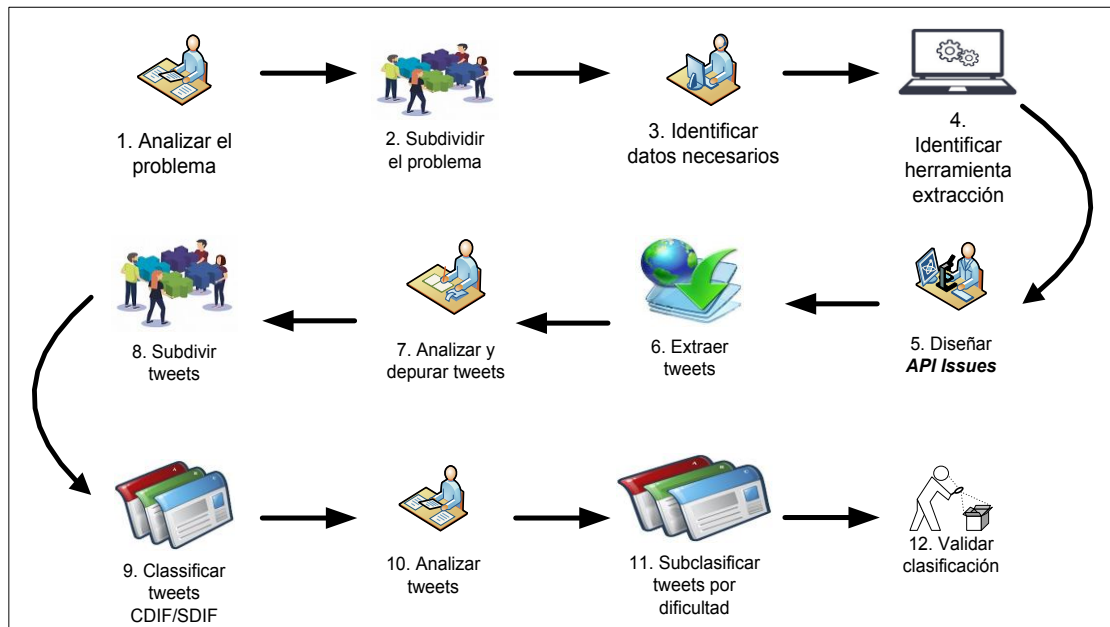


Figura 31 – Diagrama del diseño algorítmico

## 6.5.2 Descripción de las intervenciones

Debido a la existencia de dos instrumentos de recolección de datos, se realizaron dos intervenciones distintas que son descritas a continuación:

### 6.5.2.1 Primera intervención

Esta intervención fue aplicada en el período septiembre/2019 – febrero/2020. La recolección de los datos provenientes de las 144 cuentas de estudiantes-seguidores, además, de los 35 tweets publicados por el docente. Esta tarea se realizó mediante la aplicación de 3 pasos que se describen en las siguientes subsecciones:

#### 6.5.2.1.1 Diseño de la aplicación para extracción de datos

Twitter es una red social que cuenta con opciones de desarrollador, como el producto Twitter API, este producto ofrece amplio acceso a los datos de Twitter que los usuarios desean compartir con la comunidad. Twitter API ofrece diferentes puntos de conexión como: cuentas y usuarios; tweets y respuestas; mensajes directos; anuncios; y herramientas y SDK editor (TWITTER, 2019). Para acceder a los datos de Twitter, es necesario disponer de una cuenta en la red social y registrarse en la aplicación como desarrollador. Una vez que dispone de la autorización de uso de la cuenta de desarrollador, se procede al ingreso a la plataforma (TWITTER, 2022a).

Para el objetivo del presente trabajo doctoral, se trabajó con el punto de conexión tweets y respuestas y la versión utilizada fue la Standard v1.1. Cuando se crea una nueva App se requiere completar varias acciones, cuyo detalle se presenta en el Anexo GG.

Cuando se trabaja con las API, los objetos JSON pueden ser convertidos en formato CSV. Debido a que CSV es un formato versátil y ampliamente utilizado para importar en hojas de cálculos o bases de datos (TWITTER, 2022b); se optó por convertir los objetos descargados en JSON en un archivo CSV, ya que cada campo puede ser visualizado de forma individual.

Con Twitter API y el lenguaje de programación Python, se desarrolló una aplicación denominada API Issues. El nombre API Issues proviene de las siguientes conceptualizaciones: API (Application Programming Interfaces), e Issues, porque hace referencia a los problemas que pueden expresar los estudiantes durante una sesión de clase presencial. La API Issues cumple con cuatro funcionalidades 1) extracción de los datos provenientes de Twitter; 2) preprocesamiento de los datos; 3) construcción y evaluación del modelo; y 4) predicción del tipo de dificultad.

Para cumplir con la primera funcionalidad de la API Issues, que consiste en la extracción de los datos provenientes de Twitter, fueron consideradas las siguientes condiciones:

- a) Que la cuenta del estudiante-seguidor no esté protegida.
- b) Que el estudiante-seguidor haya realizado al menos un comentario, como respuesta a un tweet del docente.
- c) Que el estudiante-seguidor haya mencionado, en su comentario al docente.

Con la API Issues se extrajeron los datos provenientes de los estudiantes-seguidores del docente, y de todos los atributos que JSON proporciona, se utilizaron los siguientes campos: el campo mensaje, tanto del docente como del estudiante, denominados para el presente estudio como post\_docente y post\_estudiante respectivamente.

Mediante la API Issues, se extrajeron 1.049 tweets de la cuenta de los estudiantes-seguidores del docente, relacionados con la asignatura de Programación 1; y los 35 tweets posteados por el docente. Esta primera actividad de extracción de datos provenientes de la red social Twitter, constituye la primera etapa del proceso del KDD, para luego pasar a la fase del preprocesamiento. En la Figura 32, se presenta un extracto del código implementado en Python.





Issues y de la segunda etapa del proceso del KDD, fueron aplicadas a los datos almacenados en el archivo CSV y que son descritas a continuación:

- Eliminar datos o registros que no aportan al problema. Ejemplo: “#cuando no :v”, “#S3P2SEP19”, “...algo nuevo jajajaja”.
- Completar los datos del campo «text» del estudiante-seguidor, con el campo «text» del tweet del docente, el cual contiene el tema a tratar; y de esta manera, se pueda obtener una coherencia semántica del comentario. Ejemplo: Tweet del docente: “Uso de PSeInt, entorno y comandos”, Tweet del estudiante-seguidor: “Tuve un poco de dificultad con los conceptos”. Se puede inferir que, la dificultad está relacionada con los conceptos utilizados en la herramienta PSeInt.
- Corregir datos con ruido. Ejemplo: abreviatura de palabras, palabras con errores gramaticales y ortográficos (“#lacomputsdoralentaa”, “#hacenbulla”), palabras en otro idioma. No fueron considerados como datos con ruido, los términos propios de la asignatura de Programación 1 escritos en idioma inglés. Ejemplo: estructura «while», o ciclo “para”.

Esta tarea fue realizada de forma manual, ya que se requería construir un Corpus Especializado en la asignatura de Programación 1, con lo cual, es posible demostrar la hipótesis H2. En adelante, y para nuevos datos en la misma asignatura, no se requiere realizar esta tarea manual.

- Analizar manualmente los 1.049 tweets, a fin de conseguir mensajes que aborden una sola temática, esto se consiguió con la división de los tweets. Finalmente se obtuvieron 1.996 comentarios, cada uno de los cuales se refería a una dificultad única.

En la etapa de depuración se realizaron tareas automáticas – a través de la API Issues –, entre las que son descritas a continuación:

- Eliminar saltos de línea, los retornos de carro, los caracteres especiales, los emoticones y los símbolos especiales de datos web.
- «Tokenizar» el texto.
- Cambiar las letras mayúsculas del texto a minúsculas.
- Suprimir las menciones a la cuenta del docente, números, caracteres no ASCII, caracteres especiales adicionales.
- Eliminar los «StopWords». Se ajustó el archivo provisto por el Kit de Herramientas de Lenguaje Natural «Natural Language Toolkit» (NLTK) (NLTK Project, 2022), a las necesidades del problema. Por ejemplo, a pesar de que la expresión “no” para «NLTK»

es un «StopWord», para el estudio, es necesario que se la considere palabra significativa, pues sirve para discriminar si el estudiante expresó o no, alguna dificultad.

Debido a las diferencias importantes de algunas palabras y sus derivados, durante el proceso de «lematización», se excluyeron algunas palabras. Por ejemplo, la frase: *“obtuve nuevo conocimiento sobre programación, sin dificultad”*; la raíz de la palabra programación sería programa, mientras que, para el análisis del tweet no tienen el mismo significado, programación y programa; por lo que se requiere el análisis de la palabra completa. Una vez realizada la depuración de los datos, se generó un nuevo archivo CSV con todos los registros «Tokenizados». El archivo CSV generado con los datos depurados, constituye una aproximación a la generación de un Corpus Especializado Ad-hoc, con datos provenientes de redes sociales, que permite satisfacer una necesidad en concreto o como recurso pedagógico para la elaboración de material didáctico, en este caso, para la asignatura de Programación 1.

### 6.5.2.1.3 Análisis y clasificación de tweets

Cada uno de los textos de los 1.996 comentarios fueron analizados detalladamente, con el propósito de seleccionar el método más adecuado para identificar las ideas más representativas expresadas por los estudiantes.

Una vez que se dispuso de registros únicos del Corpus, la siguiente actividad fue etiquetar de forma manual cada tweet y con la ayuda de la herramienta AntConc, software libre utilizado para análisis de concordancia de Corpus y análisis de texto (Laurence, 2022), a través del cual se pudo extraer la lista de palabras más relevantes en función de sus frecuencias. La clasificación fue realizada en dos etapas:

- a) Identificar una dificultad: en esta etapa se aplicó el segundo objetivo del concepto de la abstracción del Pensamiento Computacional para identificar los tweets que expresaban una dificultad, etiquetados como: con dificultad (CDIF) y los que no lo tenían, sin dificultad (SDIF).

Por ejemplo: *“no tuve dificultad”, “sin dificultad”, “sin problema”*; constituyen comentarios SDIF, mientras que expresiones como *“dificultad momento iniciar computador”, “compu lenta”, “sin desayuno”*, reflejan comentarios CDIF.

De los 1.996 comentarios, se catalogaron 1.103 CDIF y 893 comentarios SDIF, que representan el 55,26% y el 44,74% respectivamente.

- b) Subclasificar por tipo de dificultad: debido a que una planificación de clase puede derivar diferentes momentos y también dificultades, que no necesariamente están relacionadas

con cuestiones académicas; los 1.103 tweets CDIF se subclasificaron por tipo de dificultad. De esta forma, las categorías conformadas en el presente estudio son descritas en la Tabla 40.

Tabla 40 – Categorización de dificultades

<b>Código Dificultad</b>	<b>Categoría</b>	<b>Descripción</b>
<b>D001</b>	Aprendizaje	Dificultades de aprendizaje del estudiante, no relacionadas con temas académicos.
<b>D002</b>	Análisis_Diseño_Lógica	Dificultades de comprensión del problema y lógica para resolver el problema mediante algoritmos.
<b>D003</b>	Herramienta_Codificación	Dificultades con el manejo de un programa, sintaxis y uso de sentencias.
<b>D004</b>	Ejecución_Validación_Resultados	Dificultades para visualizar resultados, validación de campos.
<b>D005</b>	Institucional_Personal	Dificultades relacionadas con planificación institucional, docentes, equipo tecnológico, aspectos familiares y personales.

Con la subclasificación descrita en la Tabla 40, el archivo CSV se estructuró con los siguientes campos: número de secuencia, el tweet (post\_estudiante), clase (CDIF/SDIF), tipo de dificultad. Debido a la estructura del archivo CSV, en adelante se lo denominó como «Dataset».

Para la clasificación de cada tweet por tipo de dificultad, se aplicó el concepto de Generalización de Patrones del Pensamiento Computacional, que permite generalizar el conjunto de tweets que implican una misma idea. Además, se contó con la ayuda de tres expertos (2 docentes y 1 especialista informático), con el objetivo de evitar el sesgo del investigador. El «Dataset» se dividió y repartió en partes iguales a todos los expertos, de modo que cada uno no tuviera que catalogar todos los tweets. Los expertos clasificaron el conjunto de tweets asignados según su experiencia, conforme a las categorías identificadas en la Tabla 40. Aquellos tweets que presentaron algún tipo de conflicto, fueron discutidos en conjunto para determinar la categoría final. La clasificación de las dificultades se describe en la Tabla 41.

Tabla 41 – Dificultades detectadas antes de la pandemia

Código Dificultad	Categoría	Principales dificultades	Número de registros	Longitud promedio del texto	Longitud mínima-máxima del texto
D001	Aprendizaje	Bullicio en clase; búsquedas en Internet; diferenciación de conceptos; manejo de volumen de información; concentración, evaluaciones; falta de lectura; comprensión de nuevos temas; enunciados de ejercicios y preguntas; recordar aprendizajes.	245	34,12	7 – 90
D002	Análisis_Diseño_Lógica	Lógica de programación; definición y uso de variables, constantes y tipos de datos; conceptos de programación; flujogramas; análisis de problemas; mapas mentales; desarrollo de algoritmos.	222	38,49	12 – 108
D003	Herramienta_Codificación	Uso de la herramienta; comandos y sintaxis de programación; procedimiento y funciones con parámetros; fórmulas matemáticas; estructuras de control condicionales, repetitivas y anidadas; macros; vectores; operaciones con matrices; contadores; respaldo de archivos.	332	42,56	13 – 105
D004	Ejecución_Validación_Resultados	Solución de problemas; administración del tiempo; ejecución de programas, validación de programas; desplegar resultados; identificar errores; optimizar programas.	147	33	10 – 101
D005	Institucional_Personal	Dificultad con el computador; movilización; sueño,	157	26,78	6 – 92

alimentación; puntualidad en asistencia; falta de preparación; desmotivación; horario de clases, metodología docente, envío deberes.	
<b>TOTAL</b>	<b>1.103</b>

De la Tabla 41 se pueden observar los siguientes resultados:

- La longitud mínima del texto es 6 para la categoría Institucional\_Personal y la máxima es 108 para la categoría Análisis\_Diseño\_Lógica; valores que serán tomados en cuenta para el desarrollo de la aplicación que permite predecir las dificultades de los estudiantes.
- La categoría Herramienta\_Codificación tiene más registros (332) y la categoría Ejecución\_Validación\_Resultados tiene menor cantidad de registros (147); estos factores son importantes para determinar si el conjunto de datos está desbalanceado.

### 6.5.2.2 Segunda, tercera y cuarta intervención

A partir del mes de marzo de 2020, la modalidad de estudio cambió de presencial a virtual, debido al problema de salud mundial como efecto del virus COVID-19, por lo que, para los tres siguientes períodos académicos considerados en el estudio, el instrumento que permitió la recolección de datos tuvo que ser modificado, a causa de ciertos lineamientos institucionales descritos a continuación:

- Se restringió el uso de redes sociales como medio de comunicación entre docentes y estudiantes.
- Se estableció como únicas herramientas de comunicación y evaluación: el correo institucional, Aula Virtual, Microsoft Teams o Formularios de Office.

Por otra parte, los estudiantes matriculados en la UCE, son considerados en su mayoría de escasos recursos económicos, por lo que, muchos de ellos no lograban conectarse a las sesiones de clases por diferentes factores:

- Algunos no disponían de un computador, y aquellos estudiantes que contaban con uno, debían compartir con otros miembros de la familia.
- No contaban con servicio de internet fijo en sus hogares.

- No tenían de plan de telefonía celular, por lo que requerían realizar una recarga según su presupuesto, o disponían de saldo para WhatsApp o para conexión a Microsoft Teams.

De todas las posibilidades que se disponía y por los factores mencionados, se optó por Formularios de Office para elaborar un cuestionario, que permita recolectar los comentarios expresados por los estudiantes respecto de la asignatura de Programación 1.

#### 6.5.2.2.1 Diseño del cuestionario para extracción de datos

El cuestionario estuvo compuesto por tres preguntas abiertas, que alentaban a los estudiantes a compartir exclusivamente sus dificultades en la asignatura de Programación 1. Se decidió indagar únicamente los aspectos negativos, debido al direccionamiento del objetivo de la presente investigación; que consiste en identificar los problemas de los estudiantes que requieren atención por parte del docente. Como parte de las instrucciones del cuestionario proporcionadas a los estudiantes se presentaron opciones de problemas, que pudieron haber incurrido en su aprendizaje, y que se describen a continuación:

- Académico (hardware y software, lógica de programación, variables, constante, manejo PSeInt, estructuras de control condicionales o repetitivas, funciones, procedimientos, macros, módulos, matrices, Matlab, etc.)
- Tecnológicos (computador, internet, electricidad, micrófono, cámara, etc.)
- Personales (salud, trabajo, familia, recursos, etc.)

El estudiante podía escribir hasta 3 dificultades de igual o diferente tipo, según lo mencionado en el listado anterior. El cuestionario fue socializado con todos los estudiantes al finalizar cada período académico. Sin embargo, de los 968 estudiantes en la modalidad virtual, únicamente dieron respuesta 154 estudiantes, resultado que no fue el esperado en la presente investigación. De la mayor parte de estudiantes que dieron respuesta, fue posible extraer los comentarios de las tres preguntas, con lo cual se obtuvo un total de 460 comentarios. Debido a la reducida cantidad de respuestas, se decidió unificar los registros en una sola hoja de cálculo.

##### 6.5.2.2.1.1 Depuración de registros del Formulario

Con la hoja de cálculo unificada, se procedió a realizar la tarea de depuración, siguiendo los pasos descritos a continuación:

- 1) Los datos incompletos de las respuestas, fueron completados manualmente con los tipos de problemas sugeridos en el cuestionario.
- 2) De los 460 comentarios recolectados, se realizó un análisis superficial manual, de forma que cada comentario pertenezca a una sola temática. Con este análisis se dividieron los comentarios en unidades sintácticas y se consiguió obtener 468 comentarios únicos.
- 3) Mediante una de las funcionalidades de la API Issues, fue posible eliminar los saltos de línea, caracteres especiales de los comentarios, de forma similar a lo efectuado en la primera intervención.

#### 6.5.2.2.2 Análisis y clasificación de los comentarios

Cada uno de los 468 comentarios fueron analizados, con el propósito de identificar las ideas más representativas expresadas por los estudiantes.

A partir de la hoja de cálculo generada, y con la ayuda de la herramienta AntcConc, se extrajeron las listas de palabras más relevantes de los comentarios en función de las frecuencias. La clasificación se realizó en dos etapas, de la misma manera que en la primera intervención y mediante la aplicación de los pasos del Pensamiento Computacional, esto es:

- 1) Identificar una dificultad: de los 468 comentarios únicos, se catalogaron 367 comentarios CDIF y, aunque se había solicitado a los estudiantes comentar sobre las dificultades, se identificaron 101 comentarios SDIF.
- 2) Subclasificar por tipo de dificultad: Para evitar el sesgo del investigador, se solicitó la colaboración de uno de los expertos que participó en la primera intervención, con el mismo procedimiento de clasificación de las dificultades expresadas por los estudiantes, según las categorías definidas en la Tabla 40, cuyo detalle se observa en la Tabla 42.

Tabla 42 – Dificultades detectadas durante la pandemia

Código Dificultad	Categoría	Principales dificultades	Número de registros	Longitud promedio del texto	Longitud mínima-máxima del texto
D001	Aprendizaje	Seguir la clase; adaptación a la virtualidad; nivelación de conocimientos; limitar consultas; conocimientos previos; idioma inglés.	36	63,44	12 – 264



## Capítulo 6 – Clasificación y predicción de las dificultades académicas

<b>D002</b>	Análisis_Diseño_Lógica	Lógica de programación, definición y uso de variables, constantes y tipos de datos; conceptos de programación; flujogramas.	11	49,27	9 – 219
<b>D003</b>	Herramienta_Codificación	Uso de la herramienta y comandos, procedimientos; funciones; fórmulas matemáticas; estructuras de control condicionales, repetitivas y anidadas; macros; matrices.	68	42,95	6 – 118
<b>D004</b>	Ejecución_Validación_Resultados	Administración del tiempo.	19	81,84	6 – 351
<b>D005</b>	Institucional (*)_Personal	Dificultad con el computador; trabajos grupales, cortes de energía; conectividad; horario de clases; envío deberes; espacio de estudio; organización personal; metodología enseñanza virtual; relación con el docente; salud, dificultades personales y/o familiares; combinar estudios con trabajo; preparación	233	46,16	5 – 267
<b>TOTAL</b>			<b>367</b>		

*Nota: (\*) En la modalidad virtual se considera el lugar de estudio*

De la Tabla 42 se pueden observar los siguientes resultados:

- La longitud mínima del texto es 5 para la categoría Institucional\_Personal y la máxima es 351 para la categoría Ejecución\_Validación\_Resultados; valores que serán tomados en cuenta para el desarrollo de la aplicación que permite predecir las dificultades de los estudiantes.
- La categoría Institucional\_Personal tiene más registros (233) y la categoría Análisis\_Diseño\_Lógica tiene menor cantidad de registros (11); estos factores son importantes para determinar si el conjunto de datos está desbalanceado; para este caso se evidencia un total desbalance de las clases, que podría significar un problema importante en el uso del modelo predictivo.

### 6.5.2.3 Análisis de las intervenciones

Dado que el interés del estudio se centró en la identificación de los comentarios de los estudiantes que expresaban alguna dificultad, y, a fin de que el docente pueda tomar acciones a tiempo en los procesos con mayor conflicto; para el análisis cuantitativo no se incluyeron los comentarios SDIF. El porcentaje de comentarios por categoría e intervención, se presenta en la Tabla 43.

Tabla 43 – Análisis por período y categoría de dificultad

No.	Período	Modalidad	D001	D002	D003	D004	D005
1	Sep/2019 - Feb/2020	Presencial	22,21%	20,13%	<b>30,10%</b>	13,33%	14,23%
2	Jun/2020 - Oct/2020	Virtual	15,69%	0,00%	16,67%	6,86%	<b>60,78%</b>
3	Nov/2020 - Abr/2021	Virtual	6,96%	2,61%	19,13%	3,48%	<b>67,83%</b>
4	Jul/2021 - Oct/2021	Virtual	8,00%	5,33%	18,00%	6,00%	<b>62,67%</b>
		<b>PROMEDIO</b>	<b>13,21%</b>	<b>7,02%</b>	<b>20,97%</b>	<b>7,42%</b>	<b>51,38%</b>

De la Tabla 43, se derivan los siguientes resultados:

- En la primera intervención, el tipo D003 tiene un mayor porcentaje, y el tipo D004 tiene un menor porcentaje en comparación con los demás tipos de dificultades; esto significa que los estudiantes reportan mayor cantidad de dificultades sobre el manejo del programa, el uso de sentencias y sintaxis correcta.
- En la segunda, tercera y cuarta intervención, las dificultades con mayor porcentaje son del tipo D005; problemas relacionados con factores institucionales y/o personales.
- En la modalidad presencial el tipo D001, D002, D003 y D004 tiene mayor porcentaje que en la modalidad virtual; denotando que el factor institucional y/o personal no tiene tanta incidencia.
- El tipo D002 tiene el promedio más bajo, y el tipo D005 el promedio más alto, con relación a las demás dificultades. Estos hallazgos ponen en evidencia que, los estudiantes de la modalidad virtual tuvieron más dificultades de tipo institucional y/o personal, para este caso, la institución fue reemplazada por el hogar de los estudiantes.

Para comprender gráficamente los resultados antes descritos, se elaboró una gráfica que puede visualizar los porcentajes por período académico y el tipo de dificultad. Ver Figura 33.




Figura 33 – Porcentaje de dificultades por período y por categoría

De la Figura 33 se evidencian los principales resultados:

- Las dificultades con mayor porcentaje, están relacionadas con la categoría Herramienta\_Codificación y la categoría Institucional\_Personal, para la modalidad presencial y virtual respectivamente.
- La categoría que menor incidencia tiene es la de Análisis\_Diseño\_Lógica, con un promedio en todos los períodos académicos de 7,02%, seguida de la categoría Ejecución\_Validación\_Resultados con un promedio general de 7,42%. Estos resultados infieren a pensar que las principales dificultades que reportan los estudiantes están relacionadas con los temas del manejo de la herramienta y la codificación de programas, así como por temas personales e institucionales.

#### 6.5.2.3.1 Análisis cualitativo por modalidad de estudio

Para el análisis cualitativo, se consideraron las dificultades con mayor porcentaje en cada modalidad de estudio.

##### a) Modalidad presencial

Con la ayuda de la herramienta AntConc, se identificaron las 15 palabras más utilizadas en la dificultad tipo D003, debido a que las otras tenían una frecuencia inferior a 6. Ver Figura 34.

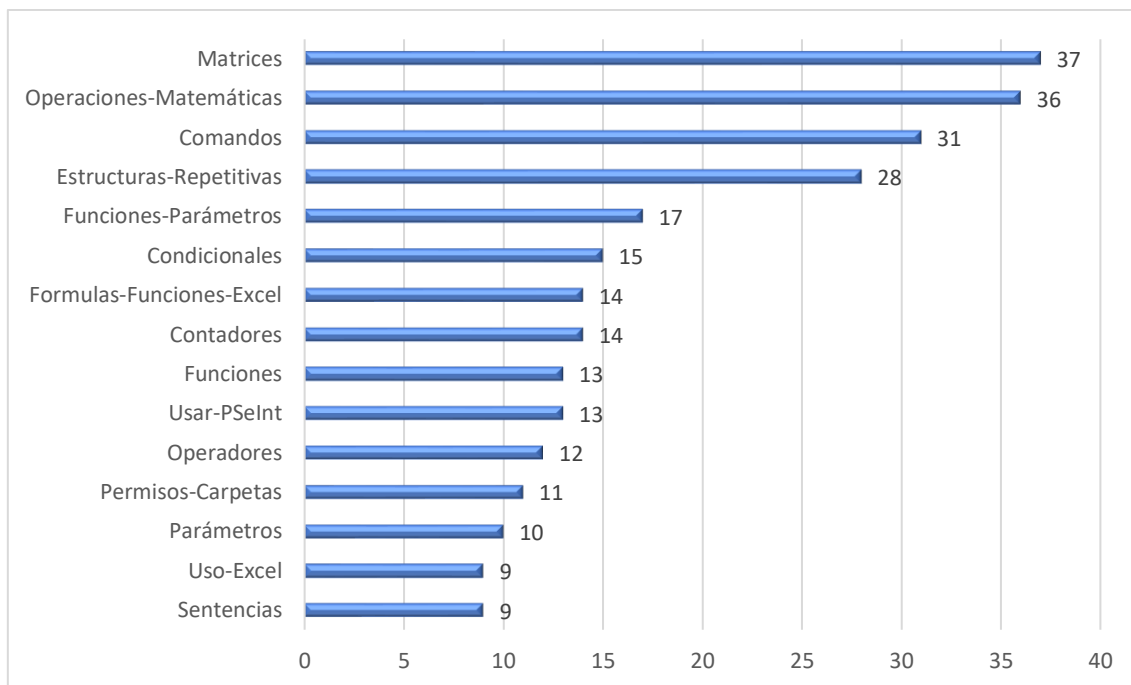


Figura 34 – Dificultades antes de la pandemia

De la Figura 34 se destacan las 5 principales dificultades reportadas por los estudiantes en la modalidad de estudios presencial: 1) matrices, 2) operaciones-matemáticas, 3) comandos, 4) estructuras-repetitivas y 5) funciones-parámetros. Temáticas que están relacionadas con el tipo de dificultad Herramienta\_Codificación; en la que están inmersas problemas con el uso del programa, la sintaxis y comandos propios de la herramienta.

#### b) Modalidad virtual

De la misma forma que en la modalidad presencial, se identificaron las 9 principales dificultades, debido a que las otras dificultades tienen una frecuencia inferior a 4, y que están relacionadas con el tipo D005. Ver Figura 35.




Figura 35 – Dificultades durante la pandemia

De la Figura 35 se evidencia que, las dificultades mayormente reportadas son: 1) Internet, 2) equipo, 3) trabajos-grupales, 4) enseñanza-virtual, y 5) personales-familiares. Temáticas que están relacionadas con el tipo de dificultad Institucional\_Personal; en la que están inmersas problemas con la disponibilidad de un equipo, del internet y problemas de índole personal.

### 6.5.2.3.2 Análisis cualitativo antes y durante la pandemia

Esta parte del análisis, contrasta las similitudes y diferencias de las dificultades predominantes en las dos modalidades de estudio. Ver Tabla 44.

Tabla 44 – Análisis cualitativo antes y durante la pandemia

Código Dificultad	Descripción	Presencial	Virtual
<b>D003</b>	Uso de la herramienta	X	X
	Uso de comandos	X	X
	Sintaxis de programación	X	
	Procedimientos, funciones con parámetros	X	X
	Estructuras condicionales y repetitivas	X	X
	Macros	X	X
	Vectores	X	
	Matrices	X	X
	Operaciones matemáticas	X	X
	Contadores	X	

## Capítulo 6 – Clasificación y predicción de las dificultades académicas

	Validaciones	X	
	Respaldo de archivos	X	
	Módulos	X	
	Problemas con el computador	X	X
	Movilización	X	
	Sueño	X	
	Alimentación	X	
	Puntualidad en asistencia	X	
	Falta de preparación	X	X
	Desmotivación	X	
	Horario de clases	X	X
	Metodología docente	X	X
<b>D005</b>	Envío deberes	X	X
	Espacio de estudio		X
	Trabajos grupales		X
	Cortes de energía		X
	Conectividad		X
	Relación con el Docente		X
	Salud		X
	Organización personal		X
	Problemas personales y/o familiares		X
	Combinar estudios con trabajo		X

De la Tabla 44 se extraen los siguientes resultados:

Con relación a la dificultad tipo D003, los estudiantes que tomaron la asignatura de Programación 1, en las dos modalidades expresan similitud en las siguientes dificultades:

- Uso de la herramienta
- Uso de comandos
- Procedimientos y funciones con parámetros
- Estructuras condicionales y repetitivas
- Macros
- Matrices
- Operaciones matemáticas

Para la dificultad tipo D005, los estudiantes de las dos modalidades expresaron los siguientes comentarios:

- Problemas con el computador

- Falta de preparación
- Horario de clases
- Metodología docente
- Envío deberes

Las diferencias entre modalidades de estudio, se describen a continuación:

- Dentro del tipo D003, la sintaxis de programación, vectores, contadores, validaciones, respaldo de archivos y módulos, son dificultades que se identificaron en la modalidad presencial pero no en la modalidad virtual. Una posible causa de esta diferencia, estaría relacionada con la disponibilidad del software en sus equipos personales, que no permitía a los estudiantes utilizar la herramienta para todos los temas propuestos. Además, el reducido número de comentarios recolectados, denotaba la falta de interés en responder el cuestionario.
- En el tipo D005, la movilización, sueño, alimentación, puntualidad en asistencia, desmotivación, se vieron reflejadas solo en la modalidad presencial; mientras que para la modalidad virtual se evidenciaron otras dificultades como: espacio de estudio inadecuado, trabajos grupales, cortes de energía, conectividad, relación con el docente, salud, organización personal, problemas personales y/o familiares, combinar estudios con trabajo.

### 6.5.3 Creación del modelo predictivo

Una vez que se realizaron algunas tareas manuales que contemplan el preprocesamiento de los datos provenientes de los tweets, se añadieron otras funcionalidades a la API Issues, esto es, proveer al docente de una herramienta que, además de identificar las dificultades que experimentan los estudiantes, sea capaz de predecir los tipos de problemas, de forma que, pueda brindar ayuda oportuna, mejorando así los procesos de enseñanza y aprendizaje; para lo cual se desarrolló un modelo de clasificación que integre los temas que son objeto de estudio de la presente tesis doctoral, esto es: técnicas de Minería de Datos, la red social Twitter y una estrategia didáctica, todo esto enmarcado en la educación superior.

Para esta etapa se utilizaron los 35 tweets publicados por el docente, y los comentarios provenientes de 144 cuentas de estudiantes-seguidores del docente, matriculados en la asignatura de Programación 1 de la carrera de Ingeniería Civil de la Universidad Central del Ecuador, durante el período septiembre/2019 a febrero/2020.

### 6.5.3.1 Construcción del modelo

La calidad del conocimiento descubierto no depende únicamente del algoritmo de minería utilizado, sino de la calidad de los datos minados (Hernández Orallo et al., 2004); es decir de los datos que serán incluidos en el modelo; de manera que, al archivo CSV generado en la etapa anterior, se le añadió una cabecera con las columnas “Clase” y “Mensaje”. Es decir, cada registro contenía la etiqueta de acuerdo con el tipo de dificultad con el que fue catalogado, por lo que, la técnica de Minería de Datos utilizada se basa en un aprendizaje supervisado; puesto que requiere de un conjunto de datos de entrenamiento con datos de ejemplo para la entrada, y respuestas etiquetadas para la salida. Por tanto, antes de pasar a la etapa de Minería de Datos del proceso del KDD, se aplica la etapa de transformación.

En esta fase, se utiliza la tercera funcionalidad de la API Issues, que consiste en la construcción del modelo, a partir de los datos provenientes de la fase anterior, así como la integración de diferentes técnicas como: Minería de Textos, Procesamiento de Lenguaje Natural y Aprendizaje Profundo. La tarea utilizada en esta etapa es la de clasificación, cuyo objetivo es la categorización de elementos de los datos en una de las diferentes clases predefinidas, para posteriormente predecir una clase.

Para el objetivo del presente estudio, se trabajó con datos textuales provenientes de la red social Twitter, y que carecen de una estructura establecida, puesto que combinan texto, caracteres especiales, emoticones o referencias de páginas web. Debido al volumen y estructura de los datos en la red social Twitter, la extracción, procesamiento y análisis de los datos supera la capacidad del ser humano, limitando el uso de métodos tradicionales; por lo que, los datos disponibles en la web, debieron ser procesados con métodos complementarios como la extracción y recuperación de la información.

De acuerdo con los resultados de la revisión sistemática descrita en el capítulo 3, el uso de Redes Neuronales denota un menor número de investigaciones en el campo de la educación y el uso de la red social Twitter, con relación a otros estudios que utilizan algoritmos de clasificación probabilística como «Naïves Bayes», o Árboles de decisión o SVM. Por su parte, las redes neuronales pueden construirse tanto para el aprendizaje supervisado como para la agrupación no supervisada. Aunque los tiempos de aprendizaje de las Redes Neuronales son relativamente largos, la evaluación de una red aprendida suele ser muy rápida, por lo que, supera a otras técnicas supervisadas durante la fase de entrenamiento, donde existe gran cantidad de elementos de datos faltantes o ruidosos (Mitchell, 1997; Roiger, 2017).

En la penúltima etapa del proceso del KDD, donde se construye el modelo predictivo, se utilizaron las bibliotecas de Python: «TensorFlow», «Keras», «Numpy», «Pandas», «Sklearn» y



«Tweepy». La biblioteca «TensorFlow» es conocida como una plataforma integral para Aprendizaje Automático «Machine Learning» (ML), que opera en arreglos multidimensionales, llamados tensores (TensorFlow, 2022).

Como se describió en la sección 6.1 Introducción, sobre el cambio de la planificación del trabajo doctoral, hubo dos instancias para crear el modelo: a) utilizando una Red Neuronal Recurrente (RNN) y b) utilizando una Red Neuronal Básica (RN).

Tanto para la construcción del modelo predictivo basado en Redes Neuronales Recurrentes como para la Red Neuronal Básica se consideraron únicamente los 1.103 comentarios que expresaban alguna dificultad (CDIF), ya que estos forman parte del objetivo del presente estudio.

### 6.5.3.1.1 Arquitectura de los modelos

La arquitectura se refiere a la estructura general de la red, es decir: el número de capas (grupos de unidades), neuronas y sus conexiones. La mayoría de las arquitecturas de redes neuronales organizan estas capas en una estructura de cadena, donde cada capa es una función de la capa que la antecede. En una arquitectura basada en cadenas, es necesario considerar: a) la profundidad de la red; y b) el ancho de cada capa. Las redes más profundas «Deep Learning» a menudo usan menos unidades por capa y menos parámetros; además, generalizan el conjunto de prueba, pero son más difícil de optimizar (Goodfellow et al., 2016).

La estructura de redes neuronales más utilizada es la «feedforward», denominada así, porque se componen de muchas funciones diferentes, por ejemplo:

$$f(x) = f^{(3)} \left( f^{(2)} \left( f^{(1)}(x) \right) \right)$$

En este caso:  $f^{(1)}$  se denomina primera capa de la red,  $f^{(2)}$  se denomina segunda capa, y así sucesivamente. La capa final de una red «feedforward» se denomina capa de salida.

La arquitectura ideal de una red se encuentra mediante la experimentación guiada, a través del seguimiento del error del conjunto de validación. De acuerdo con la literatura (Goodfellow et al., 2016; Tan et al., 2014), para los dos tipos de modelos desarrollados, la arquitectura implementada se presenta en la Figura 36.




Figura 36 – Arquitectura de los modelos

A continuación, se describen las características de las capas:

- **Capa de entrada:** en los dos tipos de modelo se utilizó una capa «Embedding», que permite convertir cada secuencia a procesar a una representación vectorial.
- **Capa oculta:** las capas ocultas se diferencian en el número total de capas y el número de neuronas por capa, y son las que permiten diferenciar un modelo de otro.
- **Capa de salida:** en los dos tipos de modelo se utilizó una capa de salida tipo «Dense» que consiste en 5 neuronas (correspondientes a las 5 categorías) y una función de activación «Softmax».

### 6.5.3.1.2 Configuración de parámetros e hiperparámetros

Es importante destacar que no existe una configuración única de parámetros e hiperparámetros que se ajuste a todos los problemas, por lo que es fundamental adaptarlos a la tarea específica; y antes de entrenar una red neuronal para que aprenda una tarea de clasificación, se deben considerar ciertas cuestiones de diseño (Goodfellow et al., 2016; Tan et al., 2014); algunas de estas fueron aplicadas tanto para la construcción del modelo basado en RNN como para el modelo de RN, y que son descritas a continuación:

- Un modelo secuencial «Sequential», cuya característica es una compilación más rápida que el modelo funcional «Functional», ya que las capas de la red se apilan una a continuación de otra y los datos se transportan entre capas en una sola dirección (TensorFlow, 2022).
- El Corpus de 1.103 registros se dividió en dos conjuntos; el 65% para entrenamiento y el 35% para prueba.
- Tamaño del vocabulario «vocabulary size» de 1.500, que fue calculado en función del número palabras únicas existentes en el «Dataset».
- Algoritmo de optimización «adam», método basado en el descenso de gradiente estocástico «SGD». Al tener pocos requisitos de memoria, es apropiado para objetivos no estacionarios y problemas con gradientes muy ruidosos y/o escasos (Keras, 2022; Kingman y Ba, 2014; Müller y Guido, 2016).
- Función de pérdida multiclase «categorical\_crossentropy», cuyo propósito es el cálculo de la cantidad que un modelo debe intentar minimizar durante el entrenamiento. Esta función calcula la pérdida de entropía cruzada entre etiquetas verdaderas y etiquetas predichas, cuando existen dos o más clases de etiquetas (Keras, 2022).

- Métrica de evaluación «accuracy», permite calcular la exactitud; es decir, la frecuencia con la que las predicciones coinciden con etiquetas originales (Goodfellow et al., 2016; Keras, 2022).
- Capa «Dropout», se la pueda considerar como una capa dentro de la red, cuya funcionalidad es reducir el sobreajuste «overfitting» al desactivar algunas neuronas de forma aleatoria en cada iteración, evitando que la red dependa demasiado de cualquier característica o nodo oculto (Eisenstein, 2018).
- Función de activación «Softmax», permite que los nodos ocultos y de salida produzcan valores de salida no lineales en sus parámetros de entrada (Tan et al., 2014). Es utilizada en la capa de salida de la red neuronal para clasificaciones multiclase. Esta función genera probabilidades sobre cada una de las etiquetas (Eisenstein, 2018; Jurafsky y Martin, 2023).

Los demás parámetros e hiperparámetros fueron particularizados por cada tipo de modelo, mismos que son descritos en los siguientes literales, no obstante, se describen los criterios utilizados para su configuración:

- Técnica de incrustación de palabras «word embeddings», para crear vectores de menor dimensión y de longitud fija, conservando la semántica de las palabras (Almeida y Xexéo, 2019; Torres, 2019). Se consideró el número de registros del «Dataset», por lo general para un conjunto de datos grandes el valor es de 1024.
- La longitud máxima del texto «maxlen», se calculó de acuerdo con el promedio de la longitud máxima del texto de los comentarios del «Dataset».
- Número de datos en cada iteración «batch\_size», se probó diferentes tamaños de lote para encontrar el mejor equilibrio entre velocidad de entrenamiento y estabilidad, de acuerdo con el número de registros del «Dataset». Esta configuración estuvo relacionada con la capacidad de procesamiento del equipo (Keras, 2022; Torres, 2019).
- Número de épocas «epochs», es el número de iteraciones durante el entrenamiento del modelo. El valor asignado dependió del «accuracy».

### a) Red Neuronal Recurrente «RNN»

Además de la configuración general de los parámetros e hiperparámetros descritos anteriormente, este primer modelo tuvo las siguientes características específicas:

- Dimensión «embeddings»: 512
- Longitud máxima del texto «maxlen»: 100.

- Número de datos en cada iteración «batch\_size»: 32
- Número de iteraciones «Epochs»: 12.
- Número de capas de la red neuronal: 3.
  - Primera capa «Embedding»: convierte números enteros positivos (índices) en vectores densos de tamaño fijo. Toma como parámetros de entrada: el tamaño del diccionario y la longitud de las palabras.
  - Segunda capa «Dense LSTM»: conocida como red de memoria a largo plazo y a corto plazo. Las LSTM permiten a las RNN recordar sus entradas. Conformada por 256 neuronas y un «Dropout» de 0.20.
  - Tercera capa «Dense»: capa oculta con 5 neuronas, que representa las categorías de las dificultades.

Debido al número reducido de datos obtenidos en la etapa de extracción, y con el objetivo de mejorar los resultados del modelo basado en RNN, dado que, una de las características de las Redes Neuronales es la capacidad para aprender a partir de datos de entrenamiento; se optó por construir un modelo predictivo utilizando una Red Neuronal Básica.

**b) Red Neuronal Básica «RN»**

Para la construcción del modelo de Red Neuronal Básica, se implementó un algoritmo que permitió la creación de 11 modelos diferentes con diferentes características de la Red Neuronal «RN», las cuales se describen a en la Tabla 45.

Tabla 45 – Estructuras de los modelos de Red Neuronal Básica (RN)

Modelo	Capas ocultas: neuronas, neuronas por capa
1	1 capa oculta, 2.000 neuronas
2	1 capa oculta, 1.000 neuronas
3	1 capa oculta, 500 neuronas
4	1 capa oculta, 100 neuronas
5	2 capas ocultas, 100 y 25 neuronas/capa
6	2 capas ocultas, 1000 y 500 neuronas/capa
7	2 capas ocultas, 750 y 250 neuronas/capa
8	2 capas ocultas, 500 y 250 neuronas/capa
9	3 capas ocultas; 1.000, 500 y 250 neuronas/capa
10	3 capas ocultas; 750, 250 y 100 neuronas/capa
11	3 capas ocultas; 500, 200 y 100 neuronas/capa

La configuración de los parámetros e hiperparámetros específicos de la red neuronal se describe a continuación:

- Dimensión «embeddings»: 64.
- Longitud máxima del texto «maxlen»: 500.
- Número de datos en cada iteración «batch\_size»: 256
- Número de iteraciones «Epochs»: 100.
- Número de capas de la red neuronal: 3.
  - Primera capa «Embedding»: convierte números enteros positivos (índices) en vectores densos de tamaño fijo. Toma como parámetros de entrada: el tamaño del diccionario y la longitud de las palabras.
  - Aunque conceptualmente no son consideradas como capas, se utilizó Flatten(), para aplanar la salida de la capa «Embedding»; para convertir la salida en un vector unidimensional.
  - Segunda capa «Dense»: capa oculta con 1.000 neuronas. Función de activación: Unidad rectificadora lineal «ReLU». La función ReLu permite un entrenamiento más rápido y efectivo, a través del mapeo de valores, manteniendo los valores positivos (Eisenstein, 2018; Goodfellow et al., 2016; Müller y Guido, 2016).
  - Capa «Dropout»: de 0.20.
  - Capa de salida: capa oculta con 5 neuronas, que representa las categorías de las dificultades.

Una vez que fueron definidas las diferentes estructuras para el modelo de la Red Neuronal Básica, descritas en la Tabla 45, y mediante la configuración de los parámetros e hiperparámetros, se procedió al entrenamiento de los modelos, con el objetivo de determinar la estructura con mayor «accuracy». Ver Figura 37.




Figura 37 – Evaluación de los modelos

Una vez que se crearon los 11 modelos, se pudo determinar que el modelo con mayor exactitud «accuracy», fue el modelo N° 8, con un valor de 77,00%; es decir, un modelo con dos capas ocultas, de 500 y 250 neuronas respectivamente. Además, es necesario acotar que, el promedio de la exactitud de los 11 modelos generados fue del 75%.

Con los resultados obtenidos del modelo N° 8, se trató de afinar el mismo, cambiando los diferentes hiperparámetros de la Red Neuronal Básica. El conjunto de entrenamiento y de prueba fue el mismo que se utilizó en la creación de los 11 modelos, es decir 65% para entrenamiento (716) y 35% para pruebas (387). Ver Tabla 46:

Tabla 46 – Afinamiento del modelo

N°	Hiperparámetros	Exactitud entrenamiento vs. prueba
1	epochs = 200	99,30% vs. 77,78%
2	epochs = 50; batch_size = 128	99,16% vs. 74,16%
3	epochs = 50; batch_size = 128; tamaño embedding = 256	99,02% vs. 75,71%
4	epochs = 50; batch_size = 128; tamaño embedding = 64; dropout = 50%	99,16% vs. 75,71%

De la Tabla 46, se puede observar que, al afinar el modelo con los hiperparámetros 2, 3 y 4, el modelo no mejoró su «accuracy»; sin embargo, con el cambio en el afinamiento 1, es decir 200 epochs, se alcanzó una exactitud del 77,78%.

### 6.5.3.2 Entrenamiento

En esta tarea de entrenamiento se evaluó el «Dataset» con los 1.103 comentarios CDIF, etiquetados con los 5 tipos de dificultad. En concordancia con los porcentajes previstos, 716 registros conformaron el conjunto de entrenamiento que representa el 65% de los datos. La división del «Dataset» se realizó de forma aleatoria con el uso de la función «train\_test\_split»; y, para garantizar que la función se reproduzca en igualdad de condiciones, se fijó una semilla para el generador de números aleatorios con la función «random\_state». Con los hiperparámetros de la Red Neuronal Recurrente y Red Neuronal Básica, durante el entrenamiento se pretende extraer las características más adecuadas de los datos, para determinar a qué tipo de dificultad pertenece el tweet.

### 6.5.3.3 Prueba del modelo

Elegir la medida de desempeño del modelo debe estar acorde con el comportamiento deseado del sistema; en determinadas situaciones, esta elección puede ser difícil porque se desconoce que se desea medir. En algunos casos se debería medir la precisión, el rendimiento o penalizar el sistema cuando comete errores con frecuencia; este tipo de opciones de diseño dependen de la aplicación (Goodfellow et al., 2016).


Una vez construido el modelo, se procedió a utilizar los 387 registros del conjunto de prueba, que representa el 35% de los datos. Para esta etapa, se utilizaron diferentes métricas que permiten evaluar el modelo. En estadística y ciencia experimental, la calidad del proceso de medición y los datos resultantes se miden mediante precisión y sesgo (Tan et al., 2014); para el presente estudio se describen algunas métricas, cuyos conceptos se describen brevemente a continuación:

- Exactitud «accuracy»: métrica de rendimiento que indica la proximidad de las mediciones al valor real (Tan et al., 2014).
- Pérdida «loss»: número que indica qué tan mala fue la predicción del modelo en un solo ejemplo (Google Developers, 2022).
- Precisión «precision»: determina la fracción de registros que realmente resultan positivos en el grupo, y que el clasificador ha determinado como clase positiva. Cuanto mayor sea la precisión, menor será el número de errores falsos positivos cometidos por el clasificador. (Tan et al., 2014).
- Recuperación «recall»: mide la fracción de ejemplos positivos predichos correctamente por el clasificador (Müller y Guido, 2016).
- Puntaje F1 «f1-score» o «F-measure» o «f1-score»: combina recuperación y precisión en una sola métrica, utilizando la media armónica (Eisenstein, 2018). Un valor alto de la medida F1 garantiza que, tanto la precisión como la recuperación sean razonablemente altas (Tan et al., 2014). Esta métrica es útil para conjuntos de datos desbalanceados.

Con estas métricas se buscó medir el porcentaje de aciertos o desaciertos (Sotaquirá, 2022), así como la exactitud en la predicción del modelo (Barrios Arce, 2019). Para analizar el desempeño del modelo, se utilizó la matriz de confusión multiclase (Bird et al., 2009; Tan et al., 2014).

a) Modelo basado en RNN

El cálculo de los valores del «accuracy» y del «loss» fueron 0.80 y 0.86 respectivamente. El algoritmo fue ejecutado en un entorno de ejecución con GPU en Google Colab. Ver Figura 38.



Nota: «Accuracy» = exactitud en datos de entrenamiento      «Loss» = pérdida en datos de entrenamiento  
 «Val\_accuracy» = exactitud en datos de prueba      «Val\_loss» = pérdida en datos de prueba

Figura 38 – Valor de la Exactitud y Pérdida del Modelo RNN

De la Figura 38 se pueden apreciar los siguientes resultados:

- El valor del «accuracy» con los datos de prueba, son cercanos a los datos de entrenamiento.
- El valor de «loss» con los datos de prueba, se encuentran distantes a los datos de entrenamiento, a medida que se aumentan el número de iteraciones.
- Mediante la implementación de este modelo, basado en una Red Neuronal Recurrente, se alcanzó una exactitud del 80% (Pérez-Suasnavas et al., 2022); sin embargo, existe un porcentaje de pérdida que requiere del análisis sobre las causas de estos resultados.

En esta etapa, fueron utilizadas otras métricas como: «precision», «recall» y «f1-score». Cada una de estas métricas fueron calculadas por cada clase, valores que se presentan en la Tabla 47.

Tabla 47 – Métricas del modelo RNN

Clases	Precision	Recall	F1-score
Análisis_Diseño_Lógica	0.89	0.83	0.86
Aprendizaje	0.72	0.69	0.71
Ejecución_Validación_Resultados	0.89	0.89	0.89
Herramienta_Codificación	0.78	0.86	0.82
Institucional_Personal	0.74	0.71	0.73



## Capítulo 6 – Clasificación y predicción de las dificultades académicas

De la Tabla 47 se observa que, el menor valor obtenido en la métrica de «precision» es de 0.72 en la clase Aprendizaje, y el mayor valor con 0.89 corresponde a las clases Análisis\_Diseño\_Lógica y Ejecución\_Validación\_Resultados. El promedio macro de las métricas fue 0.80.

El valor F1 garantiza que tanto la precisión como la recuperación sean altas, como se puede evidenciar, la clase Ejecución\_Validación\_Resultados tiene los valores más altos en la clasificación (0.89), seguida de la clase Análisis\_Diseño\_Lógica (0.86) y luego la clase Herramienta\_Codificación (0.82). Resultados que son comparables con los resultados obtenidos por Oanh (2020), al implementar el modelo con la red biLSTM, cuyos valores fluctuaban entre 0.77 y 0.94. Los resultados de la presente investigación también son similares a los obtenidos en el estudio realizado por Vora y Iyer (2020), con los siguientes valores: precisión (0.79); exactitud (0.76); y valor-F1 (0.82).

En relación a la clase Institucional\_Personal y Aprendizaje, fueron las clases que obtuvieron el valor más bajo en la métrica F1, por lo que se puede inferir que algunos de los comentarios no fueron clasificados correctamente en la etapa de prueba del modelo; sin embargo, están cercanos a las métricas obtenidas por Oanh (2020).

Para realizar la prueba del modelo, se utilizó la matriz de confusión que permite contrastar las clases reales con las clases predichas. Ver Figura 39.

		Matriz de Confusión				
		Analisis_Diseño_Logica	Aprendizaje	Ejecucion_Validacion_Resultados	Herramienta_Codificacion	Institucional_Personal
Clases Verdaderas	Analisis_Diseño_Logica	71	2	2	11	0
	Aprendizaje	5	59	2	11	8
	Ejecucion_Validacion_Resultados	0	2	50	3	1
	Herramienta_Codificacion	3	8	2	95	3
	Institucional_Personal	1	11	0	2	35
		Analisis_Diseño_Logica	Aprendizaje	Ejecucion_Validacion_Resultados	Herramienta_Codificacion	Institucional_Personal
		Clases Predichas				

Figura 39 – Matriz de confusión, modelo RNN


De la Figura 39 se puede observar los siguientes resultados:

- Del total de registros clasificados, se calculó el porcentaje de las clases clasificadas correctamente (diagonal principal), obteniéndose el 80,10%, valor que se contrasta con el promedio macro (0.80) de las métricas obtenidas de la Tabla 47.

- La categoría mejor clasificada fue Ejecución\_Validación\_Resultados con el 89,29%, porcentaje que se confirma con el valor F1-score obtenido para esta categoría, que refleja el valor más alto. Ver Tabla 47.
- La categoría que obtuvo un porcentaje de clasificación bajo fue Aprendizaje con 69,41%, valor comparable con las métricas obtenidas en la Tabla 47, donde también es la más baja.

### b) Modelo basado en RN

El cálculo de los valores de la exactitud y de pérdida fueron 0.77 y 1.36 respectivamente. Además, se utilizó un entorno de ejecución GPU en Google Colab. Ver Figura 40.



Nota: «Accuracy» = exactitud en datos de entrenamiento      «Loss» = pérdida en datos de entrenamiento  
«Val\_accuracy» = exactitud en datos de prueba      «Val\_loss» = pérdida en datos de prueba

Figura 40 – Valor de la Exactitud y Pérdida del Modelo RN

De la Figura 40 se pueden apreciar los siguientes resultados:

- El valor del «accuracy» con los datos de prueba, son cercanos a los datos de entrenamiento, pero en menor porcentaje al obtenido con el modelo basado en RNN.
- El valor de «loss» con los datos de prueba, se encuentran distantes a los datos de entrenamiento, a medida que se aumentan el número de iteraciones.
- Mediante la implementación de este modelo, basado en una Red Neuronal Básica, se alcanzó una exactitud del 77% (Pérez-Suasnavas, 2023); sin embargo, existe un porcentaje de pérdida que requiere del análisis sobre las causas de estos resultados.

En esta etapa, también fueron utilizadas las siguientes métricas: «precision», «recall» y «f1-score». Cada una de estas métricas fueron calculadas por cada clase, valores que se presentan en la Tabla 48.

Tabla 48 – Métricas del modelo RN

Clases	Precision	Recall	F1-score
Análisis_Diseño_Lógica	0.82	0.80	0.81
Aprendizaje	0.76	0.66	0.70
Ejecución_Validación_Resultados	0.81	0.86	0.83
Herramienta_Codificación	0.77	0.83	0.80
Institucional_Personal	0.67	0.69	0.68

De la Tabla 48 se observa que, el menor valor obtenido en la métrica de la «precision» es de 0.67 en la clase Institucional\_Personal, y el mayor valor corresponde a la clase Análisis\_Diseño\_Lógica (0.82). El promedio macro obtenido fue de 0.77.

El valor F1 más alto fue en la clase Ejecución\_Validación\_Resultados (0.83), seguido de las clases Análisis\_Diseño\_Lógica (0.81) y Herramienta\_Codificación (0.80); resultados que son comparables con el estudio realizado por Vora y Iyer (2020), donde el valor F1 obtenido fue (0.82).

También se puede evidenciar que, los valores obtenidos de F1 en la clase Aprendizaje (0.70) e Institucional\_Personal (0.68), son relativamente más bajos; con estos resultados se puede inferir que, algunos de los comentarios no fueron clasificados correctamente en la etapa de prueba del modelo. Aunque Prem Chander et al. (2020) e Ingole et al. (2018) manifiestan que no existe un clasificador catalogado como el mejor, los resultados del F1-score están cercanos a las métricas obtenidas por Oanh (2020).

Para realizar la prueba del modelo, se utilizó la matriz de confusión que permite contrastar las clases reales con las clases predichas. Ver Figura 41.



realizó de forma manual, para obtener registros que pertenezcan a un solo tipo de dificultad, y luego se utilizó la segunda y cuarta funcionalidad de la API Issues, para la limpieza de los comentarios y la predicción respectivamente.

De forma similar al epígrafe anterior, la aplicación del modelo sobre nuevos datos se realizó tanto para la RNN, como para la RN; sin embargo, durante esta etapa de validación se encontraron los siguientes inconvenientes:

- El valor de «loss» del modelo aumentó y el del «accuracy» disminuyó.
- No todos los registros fueron clasificados correctamente.
- El clasificador no realizó la predicción adecuadamente.

Además, en la matriz de confusión del modelo basado en RNN, se pudo observar lo siguiente:

- En la diagonal principal, es decir, los Verdaderos Positivos, el 96% de los registros de la clase Institucional\_Personal fueron clasificados correctamente, seguidos de los registros de la clase Herramienta\_Codificación con el 57,69%. Las demás clases obtuvieron menos del 30% de una clasificación correcta.
- Respecto de los Falsos Positivos, las clases Análisis\_Diseño\_Lógica y Ejecución\_Validación\_Resultados, tuvieron registros clasificados incorrectamente en menor porcentaje al de las otras clases.
- Sobre los Falsos Negativos, el número de registros clasificados que no pertenecían a la clase verdadera fue menor para la clase Aprendizaje.

Por lo que, la validación con los 367 registros no fue posible realizarla debido a posibles factores que son descritos a continuación:

- El conjunto de datos de validación se encuentra desbalanceado. Esto se puede evidenciar en la Tabla 42, en la columna: Número de registros.
- El conjunto de datos de validación (367 comentarios) es muy pequeño y no clasifica correctamente.
- El «Dataset» podría estar mal etiquetado.
- El modelo está sobreajustado «overfitting».

A pesar de que se presentaron inconvenientes con la validación sobre nuevos datos; se tomó al azar 50 de los 367 registros obtenidos en la modalidad virtual, para estimar el porcentaje de predicción con las etiquetas originales y las etiquetas predichas de un comentario. Ver Tabla 49.

Tabla 49 – Muestra de comentarios etiquetados

Comentario original	Etiquetado manual	Etiqueta predicha
Calidad de Internet	Institucional_Personal	Institucional_Personal
Cortes en la reunión por mal Internet	Institucional_Personal	Institucional_Personal
El tratar de dividir la pantalla del computador para ver lo que enseña y seguir programando	Aprendizaje	Aprendizaje
Falta de tiempo para repasar	Ejecución_Validación_Resultados	Ejecución_Validación_Resultados
Tuve que conseguir trabajo	Institucional_Personal	Institucional_Personal
El no poder seguir la clase mientras realizo la práctica en el programa	Aprendizaje	Institucional_Personal
La primera fue mi aparato tecnológico ya que no era tan actual	Institucional_Personal	Aprendizaje
Las herramientas tecnológicas no tenían muy buen funcionamiento por lo que me costaba seguirle el paso a la Ingeniera	Institucional_Personal	Aprendizaje
Implementación de códigos	Herramienta Codificación	Institucional_Personal
Nivelación de conocimientos por cambio de Facultad	Aprendizaje	Institucional_Personal
Las prácticas de laboratorio, a veces quedan huecos y como es virtual y hay tiempos específicos de los laboratorios no da el tiempo de preguntar.	Ejecución_Validación_Resultados	Ejecución_Validación_Resultados
Mala conexión a Internet	Institucional_Personal	Institucional_Personal
.....	.....	.....

De la Tabla 49, se puede inferir que, de los 50 registros tomados al azar, se calculó que el 64% de los comentarios tuvieron una buena predicción; por lo que, el modelo si realiza una buena predicción de los datos, pero debido al número reducido de registros con los que se dispuso, y un «Dataset» desbalanceado, el modelo podría tener un sobreajuste.

Debido a estos problemas detectados, y frente a la imposibilidad de disponer de un «Dataset» más grande, con las mismas características y sobre la misma temática; se analizó la posibilidad de validar la arquitectura y configuración del modelo con otras bases de datos, diferentes en contenido y temática, con el objetivo de verificar que los parámetros e hiperparámetros de la RNN – la cual obtuvo mejor predicción –, eran correctos y podrían ser acoplados a un nuevo contexto, y además realizaba una buena clasificación y predicción de los datos.

Para cumplir con esta consigna, se trabajó con un «Dataset» con 5.000 registros que contenían noticias en idioma inglés, con igual número de clases y con las siguientes etiquetas: «sport», «business», «politics», «tech», «entertainment». En el modelo, se cambió el nombre de las etiquetas y el archivo «StopWords» ajustado al idioma. Una vez que se entrenó el modelo basado en RNN, el valor de «accuracy» obtenido fue de 0.91, y el valor de «loss» fue de 0.42. Adicionalmente se calcularon las métricas para validar el modelo. Ver Tabla 50.

Tabla 50 – Métricas del modelo RNN para nuevos datos

Clases	Precision	Recall	F1-score
Business	0.95	0.86	0.91
Entertainment	0.86	0.89	0.87
Politics	0.91	0.84	0.87
Sport	0.92	1.00	0.96
Tech	0.90	0.95	0.92

De acuerdo con los datos presentados en la Tabla 50, el cálculo del promedio macro de las métricas fue de 0.91.

Con estos resultados se pudo determinar que el modelo entrenado para el «Dataset» de dificultades académicas posee los parámetros e hiperparámetros correctos.

#### 6.5.4.1 Visualización

La última etapa del proceso del KDD, permite visualizar y representar el conocimiento extraído a los usuarios; para lo cual, mediante la API Issues, se implementó un método para visualizar las

clases y los diferentes temas; de manera que, el docente pueda identificar los tipos de dificultades Ver Figura 42.




Figura 42 – Número registros por clase

La Figura 42, denota que, el código D003 que corresponde a la clase Herramienta\_Codificación, es el tipo de dificultad que más registros posee; esto se destaca principalmente en la modalidad de estudios presencial.

Entre los tipos de dificultades que el estudiante puede expresar, existen los temas más representativos que requerirían más atención por parte del docente. Se caracterizan por un tamaño de letra más grande de acuerdo con su frecuencia de aparición, para este caso se presentan los temas del «Dataset» de la modalidad de estudios presenciales. Ver Figura 43.



Figura 43 – Nube de palabras con mayor incidencia de dificultad



Con los datos visualizados en la Figura 43, se dispone de un material educativo de apoyo, que forma parte de la primera fase de la Estrategia Didáctica JiTTwT, esto es generar los conocimientos previos; donde, el docente recopila de forma automática los tweets de sus estudiantes-seguidores, mediante la primera funcionalidad de API Issues. Con la segunda funcionalidad, los tweets son preprocesados, y luego de la aplicación del modelo predictivo, descrito en diferentes pasos del Flujo de Trabajo, presentado en la Figura 44, permite determinar los temas que demandan mayor atención por parte del estudiante. Todas estas actividades se realizan días previos a la nueva sesión de clase.

El material educativo generado en la primera fase la Estrategia Didáctica JiTTwT, es utilizado en la segunda y tercera fase de la misma, cuyo objetivo es la orientación de la atención del estudiante y organización de la información respectivamente.

En la segunda fase de la estrategia, el docente apertura la nueva sesión de clase y realiza la retroalimentación de los temas o palabras representados en la nube de palabras, de manera que, el estudiante se sienta identificado con sus comentarios, logrando en primer momento, captar la atención del estudiante. En esta fase se evidencia la participación activa de los estudiantes.

En la tercera fase de la estrategia, el docente procede a presentar el material didáctico correspondiente a la planificación académica; y posteriormente procede a la conformación de grupos para realizar el trabajo colaborativo.

En la última fase de la estrategia, el docente recopila las actividades sobre el trabajo colaborativo. Además, plantea un nuevo tweet para concluir la sesión de clase y solicita a los estudiantes que respondan mediante comentarios finales o a su vez, comentarios si persisten dudas. Los tweets generados al finalizar la sesión, son recuperados con la API Issues para la nueva sesión de clase; por tanto, la Estrategia Didáctica JiTTwT es cíclica para cada sesión de clase programada.

Una vez finalizadas las fases del proceso del modelo predictivo, se desarrolló el flujo de trabajo que detalla los pasos descritos en cada etapa. Ver Figura 44.

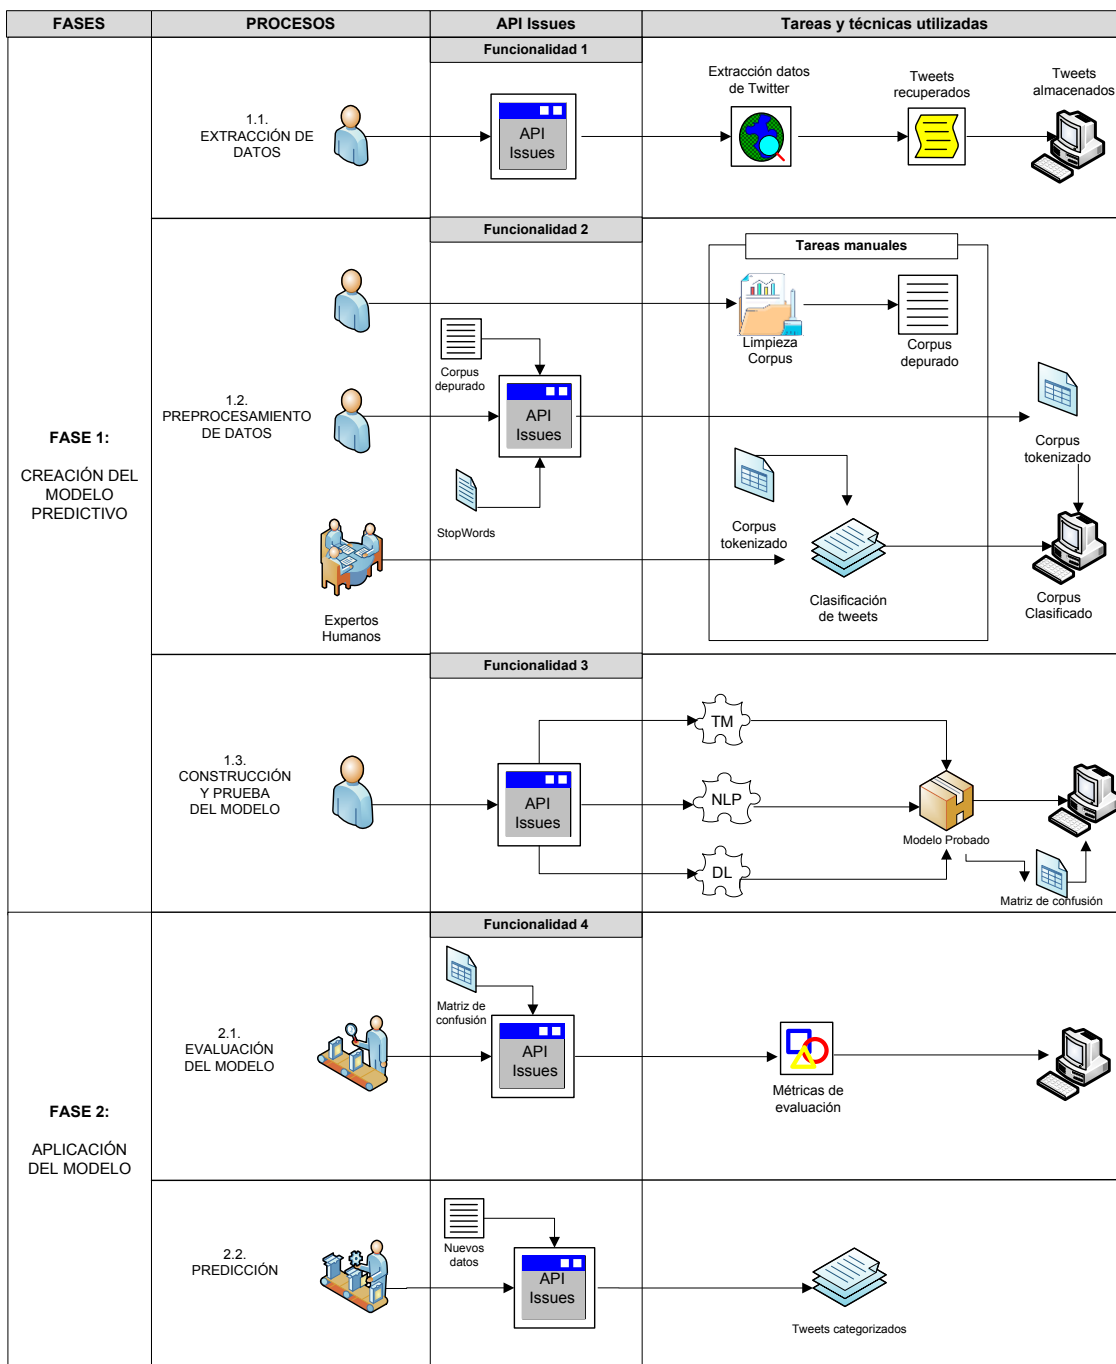


Figura 44 – Flujo de trabajo

## Capítulo 7 – Conclusiones, trabajos futuros y aportes

El séptimo capítulo describe las conclusiones obtenidas a partir del trabajo realizado, en función de los resultados alcanzados; además, se presentan las limitaciones y se exponen las líneas de investigación futuras. Por otra parte, se describen los principales aportes derivados de la investigación, y el resumen de las publicaciones realizadas, que sustentan y validan el trabajo.

### 7.1 Conclusiones

- En el segundo capítulo se sintetizaron los principales enunciados que forman parte del tema central de la presente tesis doctoral. Cada enunciado fue descrito con un criterio conceptual, esto es, descripción del origen, definición, clasificación y aplicación según corresponde a cada tema. Se enfatizó el detalle de los subtemas, que tienen estrecha relación con el enfoque de la revisión sistemática.
- De acuerdo con las preguntas de investigación planteadas y desarrolladas en el capítulo tres, es posible realizar las siguientes conclusiones:
  - La ejecución de la revisión sistemática realizada en dos momentos permitió conocer la evolución del tema propuesto, así como, la tendencia de las investigaciones; por lo que, se justifica el desarrollo y ejecución de la revisión sistemática.
  - Para encontrar todos los posibles artículos relacionados al tema de investigación, adicionalmente de la exploración por la cadena completa de búsqueda, fue necesario realizar la combinación de los diferentes términos de búsqueda para alcanzar un mayor número de estudios relacionados al tema central de la presente tesis.
  - Respecto de la evolución del tema propuesto a lo largo del tiempo, refleja que, en el año 2012, 2017 y 2019, existen mayor cantidad de investigaciones en el área; no obstante, en los últimos tres años existe una tendencia a la baja.
  - Con relación a la ubicación geográfica de los estudios realizados, el continente americano posee la mayor cantidad de investigaciones; donde se destaca USA con 23 estudios de los 96 existentes; el resto de los países de este continente, evidencian un reducido número de investigaciones; por lo que, se considera importante canalizar más investigaciones en estos países.
  - Como parte de la muestra utilizada en los estudios, se determinó que la mayor parte de autores utilizan entre 1 - 19 usuarios o entidades; así como, entre 1.000 y 9.999 tweets para sus experimentaciones. En el presente estudio, la muestra fue de 144 estudiantes y 1.103 tweets, por lo que, se consideran cantidades adecuadas para el trabajo. Es

importante señalar que un gran porcentaje de los estudios no especifican el tamaño de la muestra.

- El proceso de extracción de patrones de los datos provenientes de Twitter implica varias tareas como son: extracción, preprocesamiento, análisis, clasificación o agrupación; por lo que, los estudios utilizan más de una técnica o tarea de Minería de Datos. De los hallazgos, es posible inferir que la tendencia de las investigaciones es trabajar con tareas predictivas, que incluye algoritmos de clasificación, y el más utilizado es «Naïve Bayes» y muy pocos estudios refieren las redes neuronales; factor que incidió en la presentación de la propuesta.
- De forma similar que el párrafo anterior, los estudios combinan diferentes herramientas; ya que, por una parte, se requiere extraer los datos de Twitter, preprocesar el texto, clasificar, predecir o describir. Las herramientas que mayor demanda tienen por parte de los estudios son: Twitter API, Python, NVivo, SPSS y R. Para el presente estudio se optó por software libre, de manera que sea de libre acceso a la comunidad científica.
- Entre los principales usos de Twitter en la educación se encuentran el análisis del contenido de los tweets, que permita identificar los sentimientos, problemas, opiniones, pensamientos, desafíos, percepciones, estilos de aprendizaje. Twitter también es utilizado en la educación para generar comunicación, participación, comunidades de aprendizaje. Entre otras utilidades están el compartir material didáctico, conocimiento, recursos. Todo esto, con el objetivo de mejorar algunos procesos académicos o ayudar a la toma de decisiones, principalmente enfocados en temas relacionados con estudiantes. En la presente investigación, el principal uso que se le otorgó a Twitter es el académico, de forma específica para conocer e identificar las dificultades que expresan los estudiantes durante una sesión de clase.
- Con la revisión sistemática se evidenció que, existe un mínimo porcentaje de estudios que utilizan una práctica pedagógica que complementa el uso de las técnicas de Minería de Datos y la red social Twitter; por lo que, se requirió desarrollar un estudio que complementa estas tres áreas de estudio, y de forma particular en la educación superior, objetivo que fue alcanzado en el presente trabajo.
- De los 96 artículos extraídos, existen algunos estudios que utilizan Twitter para analizar el contenido de los tweets, con énfasis en la detección, clasificación o predicción de sentimientos, emociones, experiencias educativas o problemas que enfrentan los estudiantes en carreras de ingeniería (Altrabsheh et al., 2015; Castillo Landínez y Caicedo Rodríguez, 2019; Chen et al., 2014; Desai y Mehta, 2018; Fahrudin et al., 2019;

Greeshma y Veigas, 2020; Issa et al., 2022; Joshi y Sharma, 2021; Patil y Kulkarni, 2018; Sambhaji, 2021; Saura et al., 2019; Wright, 2010). No obstante, aunque realizan un gran aporte en el campo, con la clasificación de los datos, generación de corpus, implementación de algoritmos predictivos, propuestas para superar los problemas, todos estos estudios presentan un limitante, esto es, la recuperación de los datos a través de hashtags o términos específicos de búsqueda, limitando así otro tipo de contenido que el estudiante pueda generar; además existen estudios que restringen su investigación a determinar la polaridad de los sentimientos (positivo, negativo, neutro), (Barrón Estrada et al., 2020; Fathima Shafana y Safnas, 2022; Jena, 2019). Por otra parte, los estudios en cuestión utilizan como parte de su experimentación corpus escritos en idioma inglés; mientras que, en la presente investigación se analizan textos en idioma español.

- En los últimos tres años, se encontraron importantes estudios relacionados con el análisis de sentimientos y opiniones, pero enmarcados en el nuevo contexto educativo experimentado durante la pandemia a causa del COVID-19 (Alcober y Revano, 2021; Duong et al., 2020; Fu et al., 2020; Makode et al., 2021; Sanchez et al., 2021); estos resultados también fueron identificados en la modalidad de estudios virtual que se llevó a cabo en los 3 períodos académicos en la institución en la cual labora el docente.
- Aquellos estudios que no utilizaron hashtags para recuperar los datos Twitter, no estaban relacionados con el análisis de sentimientos, opiniones o problemas de los estudiantes (Coelho y Figueira, 2021; Gong y D. Lane, 2020; Katia et al., 2020; Maor y Currie, 2017; Nesbet Montecinos y Cárcamo Ulloa, 2020; Salas-Rueda et al., 2019; Valls et al., 2018); más bien, se orientaban al análisis de comunicación entre instituciones, geolocalización de personas, analizar perfiles para comunicación con otros usuarios dentro del contexto educativo.
- Aunque los estudios encontrados en la revisión sistemática son significativos, y proporcionan importantes contribuciones en el ámbito académico con el uso de Twitter y el uso de técnicas de Minería de Datos; la mayor parte de ellos, no emplean, o a su vez, no especifican el uso de alguna práctica pedagógica que complemente la investigación. Por tanto, el desarrollo de la Estrategia Didáctica JiTTwT que integra los temas centrales de la presente tesis doctoral, esto es: la red social Twitter, Minería de Datos y prácticas pedagógicas, sin limitar el análisis de los problemas reportados por los estudiantes, logra cubrir los vacíos de las investigaciones que anteceden.
- Con el diseño de la Estrategia Didáctica JiTTwT desarrollada en el capítulo 4, se realizan las siguientes deducciones:

- La Estrategia Didáctica JiTTwT propuesta tuvo un enfoque constructivista, combina diferentes estrategias como: JiTT, trabajo colaborativo y evaluación entre pares, que permitan favorecer el aprendizaje significativo.
- La Estrategia Didáctica JiTTwT propuesta contempla 4 fases claramente identificadas, que alcanzan diferentes objetivos en cada proceso, integrando las técnicas de Minería de Datos y la red social Twitter aplicadas a la educación superior.
- La recopilación de los tweets en las diferentes etapas de la estrategia, requirió por parte del docente la ejecución de diferentes tareas como: la lectura, análisis y clasificación de los comentarios de forma manual en la primera etapa de desarrollo; por lo que, se identificó la necesidad de implementar una herramienta que automatice estos procesos y simplifique la labor docente, con el objetivo de que el docente brinde ayuda oportuna a las necesidades de los estudiantes, minimizando las tareas manuales.
- Según el estudio realizado por Escobar Díaz y Llumiquinga Latacunga (2018) concluyen que:

El estilo de aprendizaje predominante en los estudiantes de primero, cuarto y noveno semestre de la Carrera de Psicología Educativa y Orientación es reflexivo, teniendo como característica principal la observación, aprenden de experiencias nuevas sin embargo no suelen ser muy participativos en el aula de clase. (p. 65)

Por lo que, esta deducción podría estar alineada a los hallazgos de la presente investigación, infiriendo que los estudiantes no participan durante las sesiones de clases presenciales, porque su estilo de aprendizaje es reflexivo, factor que podría afectar a los resultados de la aplicación de la Estrategia Didáctica JiTTwT.

- Los estudiantes que formaron parte del estudio demostraban una reducida participación en la asignatura de Programación 1 por diferentes factores; además, se evidenció un alto índice de reprobación en la materia SIIU – UCE; así como el uso excesivo de celulares en el aula; lo que motivó el proponer el desarrollo de una estrategia didáctica que permita mermar estas dificultades, y aprovechar el uso de dispositivos tecnológicos y de las redes sociales.
- Una vez que fueron diseñados y aplicados los dos casos de estudio en el capítulo 5, es posible derivar los siguientes resultados:

- Los datos del registro del docente, correspondiente al período septiembre/2019 a febrero/2020, fueron apropiados, ya que permitieron realizar varios análisis con distintos enfoques.
- La aplicación de las 4 fases de la Estrategia Didáctica JiTTwT en el lapso de 6 semanas permitió determinar que los estudiantes del grupo experimental, incrementaron la participación durante una sesión de clase presencial.
- El cuestionario “Encuesta para medir la actitud hacia el aprendizaje de programación y la autopercepción del pensamiento crítico”, se consideró un instrumento válido y fiable para ser utilizado en el primer caso de estudio.
- A pesar que, el cambio de actitud de los estudiantes del grupo experimental una vez aplicada la Estrategia Didáctica JiTTwT no obtuvo los resultados deseados, es posible destacar que algunos criterios se mantuvieron, como: el deseo de los estudiantes por alcanzar un conocimiento más productivo de la asignatura de Programación 1, además de considerarla necesaria para sus estudios en niveles superiores; resultados que pueden ser comparados con lo expresado por Fernández-Ferrer y Cano (2016), quienes expresan que

“Aunque esta innovación impulsada por Twitter no consigue una mejora de la percepción del aprendizaje por parte de los participantes, ni objetivamente del rendimiento total en la asignatura. Aun así, efectivamente mejora la satisfacción de los estudiantes con la materia”. (p. 13)

Para la presente investigación, se destaca el mejoramiento de la participación estudiantil, a pesar del resultado obtenido sobre la actitud de los estudiantes.

- En lo referente a la sección de autopercepción del pensamiento crítico, la aplicación de la Estrategia Didáctica JiTTwT generó cambio en los estudiantes del grupo experimental. Además, los estudiantes mencionan que pueden distinguir hechos reales y prejuicios y pueden expresar ideas innovadoras, siendo esta habilidad considerada fundamental en el campo de Ciencias de la Computación, especialmente en el área de Programación o Desarrollo de Software (Compañ-Rosique et al., 2015).
- Como se pudo evidenciar en la información provista en el caso de estudio 2; luego de la aplicación de la Estrategia Didáctica JiTTwT, el promedio del rendimiento académico mejoró para los estudiantes del grupo experimental; por lo que es posible afirmar que, para el caso de estudio aplicado, la estrategia propuesta incide en la variable de estudio.

- Los estudiantes del grupo de control y del grupo experimental que NO mejoraron el rendimiento académico, y además reprobaron la asignatura de Programación, representan el 39,68%; valor que es comparable con los registros del sistema SIU reportados en los períodos 2015 al 2019 de la carrera de Ingeniería Civil, que denotan un 36,63% de estudiantes reprobados; sin que hasta la presente fecha exista un estudio que permita identificar los motivos del alto porcentaje de reprobación en esta asignatura; ni tampoco alternativas de mejora frente a esta problemática.
- El porcentaje de estudiantes que reprueban la asignatura en las otras carreras de la misma facultad (Beltrán et al., 2015) es alto (48,75%), en relación al identificado en el presente estudio (39,68%); no obstante, estos hallazgos conducen a un análisis más profundo sobre los factores que afectan a toda la facultad.
- En el análisis del rendimiento académico entre el 1° y 2° Hemi, se evidenció una disminución en los dos grupos de estudio; aunque en esta investigación no se analizaron las causas asociadas; es posible que este resultado esté relacionado con la existencia de estudiantes “Retirados”, especialmente en el grupo experimental.
- Con los casos de estudio descritos, es posible determinar que la Estrategia Didáctica JiTTwT propuesta, tiene incidencia favorable en las aulas universitarias, mejorando el nivel de participación estudiantil durante las sesiones de clases presenciales; destacando algunos aspectos positivos de la actitud hacia el aprendizaje, y la autopercepción del pensamiento crítico en la asignatura de Programación 1.
- El porcentaje de estudiantes que asisten solo por cumplir con la normativa (49,3%), y aunque el porcentaje de estudiantes que no toma acciones frente a una duda es mínimo (1,3%); denotaría la existencia de la desmotivación estudiantil; que puede afectar a una participación activa, a la actitud hacia el aprendizaje y al rendimiento académico.
- En la planificación inicial del proyecto doctoral, se había contemplado la aplicación de la Estrategia Didáctica JiTTwT en al menos dos períodos académicos llevados de manera presencial; sin embargo, debido al confinamiento obligado que produjo la pandemia a mediados del mes de marzo del 2020, lo cual derivó el cambio de la modalidad de estudio y las actividades que en ella se realizaron, la aplicación y validación de la metodología se realizó de forma transversal.
- A pesar de que la Estrategia Didáctica JiTTwT fue aplicada en un solo período académico de forma presencial, se pudo evidenciar que hubo un incremento en la participación estudiantil y una mejora en el rendimiento académico de los estudiantes, aspectos que permiten aceptar la hipótesis h1 sobre la participación de los estudiantes en las sesiones de clase. La participación de los estudiantes permite al docente identificar, - entre otras



cosas –, las dificultades que los estudiantes podrían presentar durante una sesión de clase, aspecto que favorece la retroalimentación oportuna por parte del docente.

- Del capítulo 6 se derivan las siguientes conclusiones:
  - La aplicación del Pensamiento Computacional permitió dividir el problema inicial en subproblemas y alcanzar los objetivos propuestos, a pesar de las diferentes y múltiples dificultades presentadas a causa de la pandemia.
  - Las fases del ciclo de vida de los Sistemas de Información utilizadas para catalogar las dificultades de los estudiantes, fueron suficiente para cubrir el espectro de dificultades expresadas por los estudiantes en la asignatura de Programación 1, aunque podrían ser incluidas etapas intermedias, pero, debido al número de registros con los que se dispuso, la clasificación logró ajustarse a las fases generales.
  - El instrumento para recolectar los comentarios de los estudiantes, utilizado en la modalidad de estudios virtual, esto es, los Formularios de Office, logró cumplir con el objetivo propuesto; no obstante, se requiere analizar las causas por las que las respuestas no fueron favorables en número, respecto de la cantidad de encuestados.
  - A pesar de que la «API Issues» requiere una configuración inicial propia de la cuenta de usuario de Twitter; esta aplicación se convierte en la primera etapa de la automatización para la extracción de tweets, con la posibilidad de ser reutilizable; donde los comentarios requieran ser depurados, analizados, clasificados y posteriormente considerarse datos de entrada del modelo predictivo; para este trabajo doctoral, el Corpus Especializado Ad-hoc fue generado en idioma español.
  - Aunque las intervenciones se realizaron en la asignatura perteneciente a la disciplina de Ciencias de la Computación, el proceso implementado es replicable en instituciones educativas donde se imparte la programación o afines, de forma que, la comunidad científica puede validar la utilidad y eficacia del proceso realizado; tanto para la modalidad de estudios presencial como virtual.
  - La «API Issues», es una herramienta que cumple varias funcionalidades, un primer aporte es la extracción de datos provenientes de la red social Twitter; como segunda funcionalidad es el preprocesamiento de los datos, la tercera la creación del modelo, cuarta la predicción de las dificultades, y por último la visualización de la información; con estas funcionalidades de la herramienta, se contempla todos los pasos que implica el proceso del KDD.
  - El modelo predictivo desarrollado mediante la implementación de las diferentes funcionalidades de la «API Issues», alcanzó un promedio macro de 0,80 para RNN y 0,77 para RN en el cálculo de las métricas; sin embargo, constituyen un primer prototipo que

está sujeto a mejoras; pero se aspira a que sea un instrumento de apoyo al docente, de forma que se logre reducir tareas manuales y su labor se encamine en buscar estrategias para resolver las dificultades experimentadas por los estudiantes, durante una sesión de clase.

- Como consecuencia de la pandemia, uno de los principales problemas en la construcción del modelo predictivo estuvo relacionado con la recolección de los datos provenientes de Twitter, ya que, el número de registros requeridos para la construcción del modelo fue inferior a lo esperado; aunque la precisión del modelo es considerada satisfactoria (0,80 con RNN), el valor de pérdida del modelo (0,86 con RNN) sugiere un análisis más profundo de los posibles factores asociados.
- El valor del «accuracy» obtenido en el modelo basado en RNN (80%) es mayor al modelo afinado de RN (77,78%); mientras que el valor de «loss» es mayor para el modelo RN (1,36) respecto al modelo de RNN (0,86); lo que permite concluir que, un modelo con redes neuronales recurrentes alcanza una mejor precisión en la predicción de los datos.
- El valor de «accuracy» obtenido tanto para el modelo basado en RNN (0,80) y el basado en una RN (0,77), son comparables con los estudios de Oanh (2020) y Vora y Iyer (2020), cuyas métricas oscilan entre 0,79-0,94 y 0,76-0,82 respectivamente; sin embargo, como bien lo manifiesta Yu y Wu (2015), la mejor estructura de datos y técnicas analíticas, están determinadas por los tipos de problemas a resolver, por lo que las métricas obtenidas en el presente estudio son aceptables; pero el modelo está sujeto a mejoras por parte de la comunidad científica.
- Los datos del presente estudio reflejan los beneficios de la propuesta de la Estrategia Didáctica JiTTwT; puesto que, la capacidad de comunicación entre el docente y los estudiantes generó oportunidades para actuar de forma casi instantánea sobre las dificultades dentro del aula mediante el uso de las distintas funcionalidades de la «API Issues».
- El valor de «loss» en los dos modelos es alto; hallazgos que derivan una investigación más profunda de los posibles factores que inciden en estos resultados; entre ellos: el número de datos recolectados es inferior al esperado, el «Dataset» está desbalanceado o mal etiquetado, o el modelo tiene un sobreajuste.
- Aunque el enfoque inductivo supone que el modelo entrenado se aplica a ejemplos no analizados, en este caso los 367 registros recuperados de los períodos virtuales; la validación del modelo predictivo no pudo ser efectuada con estos datos, debido a uno de los posibles factores descritos en el párrafo anterior; no obstante, con la validación realizada con una base de datos diferente al área educativa, y los valores obtenidos del

«accuracy» (0.91) y de «loss» (0.42), demuestran que, el modelo realiza una buena predicción de los datos; por tanto, el modelo es replicable en otros campos, en este caso experimentado: las noticias escritas en idioma inglés.

- El análisis de la matriz de confusión con los nuevos datos, permite inferir que, a mayor número de registros en cada clase y disponer de un «Dataset» balanceado, genera una mejor predicción de las clases, respecto de las clases verdaderas.

## 7.2 Limitaciones

La principal limitación que tuvo la presente tesis doctoral, fue el advenimiento inesperado y sin precedentes: el problema de salud mundial a mediados del mes de marzo de 2020, derivado del virus del COVID-19; y que fue citado en el capítulo 2, 3 y principalmente en los capítulos 5 y 6; por una parte, delimitó la aplicación de la Estrategia Didáctica JiTTwT a un solo período académico presencial; y por otra, obligó al uso de otras fuentes de recolección de datos para la experimentación y la toma de decisiones importantes para el cumplimiento de los objetivos propuestos.

Hasta la presente fecha, y luego de casi 3 años desde el apareamiento del virus, las condiciones a nivel educativo, no son las mismas a las existentes antes de la pandemia en la UCE.

La asignatura de Programación 1 al ser una asignatura no profesionalizante en la Carrera de Ingeniería Civil, no fue considerada por parte de las autoridades de la Facultad como una materia crítica, por lo que se mantuvo en la modalidad de estudios virtual en todos los niveles de enseñanza; apenas para el período Noviembre/2022 – Marzo/2023 se retornó a la modalidad presencial; y con la permanencia de algunas materias de forma virtual, debido al alto número de estudiantes matriculados y la falta de disponibilidad de aulas, como es el caso de la asignatura de Liderazgo.

La adaptación a las nuevas condiciones educativas tanto para estudiantes como docentes, luego de dos años de confinamiento, no ha permitido tener una reinserción total para poder replicar la Estrategia Didáctica JiTTwT con todas las condiciones con la que fue propuesta.

El entorno de trabajo, en lo referente al sistema de calificaciones también fue modificado, se eliminó el concepto de Hemisemestres para focalizar a evaluaciones parciales, trabajos grupales e individuales y un examen final, de acuerdo al calendario académico que establecieron las autoridades de la UCE; y que fueron cambiando durante la ejecución de cada período, debido principalmente a la falta de computadoras y conexión a Internet por parte de los estudiantes, derivando en problemas personales; por lo que, los docentes debieron adaptarse a las reformas continuas de la normativa de evaluación estudiantil.

### 7.3 Trabajos futuros

- Aplicar el instrumento “ENCUESTA PARA MEDIR LA ACTITUD HACIA EL APRENDIZAJE DE PROGRAMACIÓN Y LA AUTOPERCEPCIÓN DEL PENSAMIENTO CRÍTICO” a otros grupos de estudio, de forma que puedan compararse los resultados de esta investigación con nuevos hallazgos.
- Analizar los factores que inciden en la actitud hacia el aprendizaje de la asignatura de Programación 1 en la educación superior, para determinar la influencia de la aplicación de la Estrategia Educativa JiTTwT.
- Mejorar la estructura o contenido de los ítems de la “ENCUESTA PARA MEDIR LA ACTITUD HACIA EL APRENDIZAJE DE PROGRAMACIÓN Y LA AUTOPERCEPCIÓN DEL PENSAMIENTO CRÍTICO”, para alcanzar un Alfa de Cronbach más alto, sin requerir la eliminación de algunos ítems, que se consideran importantes para el estudio.
- Analizar las causas por las que, el rendimiento de los estudiantes disminuye en el segundo Hemi, con relación al primer Hemi; sin considerar la pertenencia al grupo de control o al grupo experimental.
- JiTTwT al ser una propuesta de estrategia didáctica, requiere ser validada con nuevos casos de estudio; puesto que, como bien lo señalan Forés Miravalles y Bueno i Torrens (2019), se necesitan datos y tiempo para afianzarla; lo básico es recolectar evidencias, tener parámetros, voces, experiencias; y en el futuro se pueda consolidar como una metodología.
- Utilizar la Estrategia Didáctica JiTTwT en otras instituciones de educación superior, con el objetivo de verificar la aplicabilidad y observar las respuestas de los estudiantes en otros entornos de trabajo, ya sea a nivel público o privado; y observar las posibles diferencias o semejanzas encontradas.
- Identificar los motivos del alto porcentaje de reprobación de la asignatura de Programación 1 en la Carrera de Ingeniería Civil, así como proponer alternativas para minimizar este problema.
- Analizar otros factores que inciden en la aplicación de la Estrategia Didáctica JiTTwT, como son: estudiantes que repiten la asignatura y el rendimiento académico.
- Examinar el estilo de aprendizaje de los estudiantes, antes de la aplicación de la Estrategia Didáctica JiTTwT, de forma que se puede llevar un control sobre la incidencia o no de este factor.

- En la sección actitud, una desviación estándar alta y una media baja al evaluar la actitud, indica que las respuestas tienden a estar más dispersas; hallazgos que requieren de un análisis posterior sobre posibles causas de estos resultados.
- Aunque el porcentaje de participación estudiantil incrementó, al igual que el valor de la media para el grupo experimental, se puede evidenciar que la desviación estándar también incrementó, esto permite inferir que existe mayor dispersión de los datos respecto del registro de participaciones para este grupo, este resultado requiere de un análisis posterior de las causas asociadas.
- Analizar las causas de la existencia de un grupo experimental y de control, que, aunque no participaron y no mejoran el rendimiento, igualmente aprueban la asignatura de Programación 1.
- Como condición de mejora, sería el análisis de la aplicación de la Estrategia didáctica JiTTwT y su incidencia en otros procesos de enseñanza y aprendizaje como la evaluación y la retención.
- En el análisis antes y durante la pandemia, se consideraron los tipos de dificultades con mayor porcentaje de ocurrencias, estos son: el tipo D003 y el tipo D005; sin embargo, conviene analizar los otros tipos de dificultades y evaluar su evolución entre períodos.
- Combinar técnicas de agrupamiento (no incluye visualización de la información), con las de clasificación, de forma que, se evite la tarea de etiquetar manualmente los registros de las dificultades de los estudiantes. Además, el agrupamiento permitiría crear taxonomías que ayudarían a crear categorías y subcategorías de temas afines.
- Incrementar el volumen de los datos, esto es, recopilar un mayor número de tweets proveniente de los estudiantes-seguidores del docente, para conformar el grupo de entrenamiento y de pruebas, de manera que, se persiga mejorar los valores de predicción.
- Aplicar otros algoritmos, como «Naïve Bayes», SVM o Árboles de decisión, que permita comparar los resultados y determinar el más efectivo para el caso de estudio, en función del cálculo de la exactitud del modelo predictivo.
- Utilizar las dos primeras funcionalidades de la API Issues en otros campos de estudio, para extraer y depurar de los datos, de forma que se puede conformar un nuevo Dataset de acuerdo con el objetivo que se persiga.
- Proponer herramientas o estrategias educativas, que permitan minimizar las dificultades encontradas en la última etapa del proceso del KDD, respecto de la enseñanza de la asignatura de Programación 1.

- Aplicar la herramienta API Issues para predecir el aprendizaje de los estudiantes; considerando que, en el presente trabajo no fueron considerados los comentarios sin dificultad (SDIF).

## 7.4 Aportes

Las principales contribuciones de la presente tesis, se resumen en los siguientes puntos:

- Una revisión sistemática de la literatura actualizada al año 2022 y con datos recopilados desde hace 15 años atrás.
- Cuestionario “Social Network & Education” para identificar la tendencia de uso de las redes sociales y aspectos sobre la participación, motivación y asistencia a las clases, validado por expertos y medido con Alfa de Cronbach, por lo que se considera un instrumento fiable y válido.
- Una Estrategia Didáctica denominada JiTTwT para fomentar la participación estudiantil durante las sesiones de clases presenciales; que integra prácticas pedagógicas, la red social Twitter y técnicas de Minería de Datos; y que puede ser aplicada a cualquier asignatura de una carrera universitaria.
- Diagrama de Flujo de la Estrategia Didáctica JiTTwT que permite condensar el proceso y las actividades que incluye la estrategia.
- Cuestionario “Actitud hacia el aprendizaje de Programación y Autopercepción al Pensamiento Crítico”; para identificar la postura del estudiante en la asignatura, y la habilidad del pensamiento crítico; el cual fue validado por expertos y medido con Alfa de Cronbach, por lo que se considera un instrumento fiable y válido.
- Un Corpus Especializado Ad-hoc en la asignatura de Programación 1, escrito en idioma español.
- Un Conjunto de Datos «Dataset» que contiene un registro de las dificultades estudiantiles en la asignatura de Programación 1, clasificadas por tipo de dificultad, escrito en idioma español.
- Una de las funcionalidades de la aplicación informática «API Issues» para la extracción de los datos provenientes de Twitter de una cuenta específica.
- La segunda funcionalidad de la «API Issues» para el preprocesamiento de los datos, de forma que se cuente con un «Dataset» depurado. Esta funcionalidad de la aplicación, puede ser utilizada en cualquier área que requiera el preprocesamiento de los datos.
- La tercera funcionalidad de la «API Issues» permite la construcción y evaluación del modelo predictivo.

- La cuarta funcionalidad de la «API Issues» predice y visualiza las dificultades académicas reportadas por los estudiantes, y que requieren mayor atención por parte del docente.
- Un Flujo de Trabajo que integra técnicas de Minería de Textos, Procesamiento de Lenguaje Natural, Aprendizaje Profundo y estrategias didácticas para predecir las dificultades estudiantiles, no basadas únicamente en aspectos académicos, sino también personales e institucionales.

## 7.5 Publicaciones científicas generadas

Los resultados de la presente tesis, fueron aceptados por parte de la comunidad científica, tanto a nivel nacional como internacional; publicados en revistas indexadas y capítulos de libros; trabajos que son descritos a continuación:

1. En Pérez-Suasnavas et al. (2019), se diseñó la estrategia didáctica para incrementar la participación estudiantil universitaria durante las sesiones de clases presenciales, apoyada en dispositivos móviles y la red social Twitter. El estudio utilizó el método inductivo exploratorio y descriptivo, para indagar y describir los datos recopilados de una encuesta aplicada a 146 estudiantes de la Carrera de Ingeniería Civil en Julio de 2018.
2. En Pérez-Suasnavas et al. (2020a), se realizó una revisión sistemática de la literatura entre enero/2007 y marzo/2019 en diferentes bases de datos reconocidas en el campo, para identificar las investigaciones que han aplicado técnicas de Minería de Datos, para la extracción y análisis de datos de Twitter en la educación superior, así como destacar las prácticas pedagógicas que han incorporado esta red social y Minería de Datos para mejorar los procesos educativos. Para esta revisión sistemática, fueron considerados los lineamientos propuestos por Kitchenham (2007).
3. En Pérez-Suasnavas et al. (2020b) se pudo evaluar el nivel de participación estudiantil durante las sesiones de clases presenciales y fueron determinados los factores asociados a la participación; aspectos que sirvieron como elementos importantes para realizar la propuesta de una estrategia didáctica para mejorar la participación estudiantil y minimizar los factores que la limitan.
4. En Pérez-Suasnavas y Cela (2020), mediante la aplicación de la Estrategia Didáctica JiTTwT, se consiguió mejorar el nivel de participación estudiantil durante las sesiones de

clases presenciales y se pudo constatar que, la estrategia genera cambios en la autopercepción del pensamiento crítico de los estudiantes respecto de la asignatura de Programación 1; no obstante, no existe mejora en la actitud, en relación al aprendizaje en esta materia. La muestra estuvo integrada por 144 estudiantes de 2° y 3° nivel de la carrera de Ingeniería Civil de una universidad pública, matriculados en la asignatura de Programación 1.

5. En Pérez-Suasnavas y Cela (2022), se pudo determinar que, mediante la aplicación de la Estrategia Didáctica JITTWT, la participación estudiantil durante las sesiones de clases presenciales, incide en el rendimiento académico de los estudiantes universitarios. El método utilizado fue cuasiexperimental y transversal, con intervención de dos grupos. La muestra estuvo conformada por 144 estudiantes matriculados en los primeros niveles de la Carrera de Ingeniería Civil de una universidad pública, en el período septiembre/2019 a febrero/2020.
6. En Pérez-Suasnavas y Cela Rosero (2022), se validó un instrumento, para evaluar la actitud y la autopercepción del pensamiento crítico de los estudiantes de ingeniería de una universidad pública. La metodología utilizada fue cuantitativa, transversal, descriptiva y no experimental. La muestra estuvo conformada por 122 estudiantes matriculados en el período septiembre/2019 – febrero/2020, y se contó con la participación de expertos que evaluaron el instrumento. Se pudo determinar que, el instrumento tiene características de viabilidad y confiabilidad para ser utilizado en futuras investigaciones; además existe correlación entre las dos variables.
7. En Pérez-Suasnavas et al. (2022) se diseñó un modelo para predecir las dificultades de los estudiantes universitarios, mediante el uso de técnicas de extracción de datos provenientes de la red social Twitter y que ha sido plasmada en un flujo de trabajo, que integra técnicas de Minería de Textos, Procesamiento de Lenguaje Natural y Aprendizaje Profundo, usando Algoritmos Supervisados y Redes Neuronales Recurrentes.
8. En Pérez-Suasnavas et al. (2023), se utilizó el pensamiento computacional como instrumento para evaluar las dificultades que experimentan los estudiantes en la asignatura de Programación 1, mediante un estudio longitudinal no experimental. El experimento incluyó 1.112 estudiantes de segundo semestre de Ingeniería de una universidad pública ecuatoriana, entre septiembre/2019 y octubre/2021.



9. En Pérez-Suasnavas et al. (2023) se realizó una actualización de la revisión sistemática de la literatura entre abril/2019 y noviembre/2022 en diferentes bases de datos reconocidas en el campo, para identificar las investigaciones que han aplicado técnicas de Minería de Datos, para la extracción y análisis de datos de Twitter en la educación superior, así como destacar las prácticas pedagógicas que han incorporado esta red social y Minería de Datos para mejorar los procesos educativos. Para esta revisión sistemática, fueron considerados los lineamientos propuestos por Kitchenham (2007).
  
10. En Pérez-Suasnavas (2023) se realizó la evaluación del rendimiento de un modelo predictivo de las dificultades estudiantiles, basado en una red neuronal básica. Los resultados son comparados con los obtenidos en el estudio previo, que incluye un modelo con redes neuronales recurrentes.

## **7.6 Méritos obtenidos**

Como parte de la presente tesis doctoral, se obtuvo un reconocimiento en el concurso de Premios UCE 2020; obteniéndose el segundo lugar en la categoría “Producción científica, en el área de ciencias sociales”.

Para el concurso Premios UCE 2020, se contó con la participación de evaluadores internos y externos afines a cada categoría; personal que tenía mínimo 3 años de experiencia como docente titular, y había realizado actividades de investigación y publicado en los últimos 5 años. Ver Figura 45.



Figura 45 – Diploma Mérito

## Referencias

- AAPOR. (2016). *American Association for Public Opinion Research*. Standard Definitions. <https://aapor.org/standards-and-ethics/standard-definitions/>
- Aggarwal, C. C. (2011). An introduction to social network data analytics. En C. C. Aggarwal (Ed.), *Social network data analytics* (pp. 1-15). Springer. [https://doi.org/10.1007/978-1-4419-8462-3\\_1](https://doi.org/10.1007/978-1-4419-8462-3_1)
- Agrawal, R., Imielinski, T., y Swami, A. (1993). Database mining: A performance perspective. *IEEE transactions on knowledge and data engineering*, 5(6), 914-925. <https://doi.org/10.1109/69.250074>
- Aichner, T., Grünfelder, M., Maurer, O., y Jegeni, D. (2021). Twenty-five years of social media: A review of social media applications and definitions from 1994 to 2019. *Cyberpsychology, Behavior, and Social Networking*, 24(4), 215-222. <https://doi.org/10.1089/cyber.2020.0134>
- Alcoba González, J. (2012). La clasificación de los métodos de enseñanza en educación superior. *Contextos Educativos. Revista de Educación*, 15, 93-106. <https://doi.org/10.18172/con.657>
- Alcober, G. M. I., y Revano, T. F. (2021). Twitter Sentiment Analysis towards Online Learning during COVID-19 in the Philippines. *2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)*, 1-6. <https://doi.org/10.1109/HNICEM54116.2021.9731999>
- Alias, N., Sabdan, M. S., Aziz, K. A., Mohammed, M., Hamidon, I. S., y Jomhari, N. (2013). Research Trends and Issues in the Studies of Twitter: A Content Analysis of Publications in Selected Journals (2007 – 2012). *13th International Educational Technology Conference*, 103, 773-780. <https://doi.org/10.1016/j.sbspro.2013.10.398>
- Almeida, F., y Xexéo, G. (2019). Word embeddings: A survey. *ArXiv*. <https://doi.org/10.48550/arXiv.1901.09069>
- Alonso, C., Gallego, D., y Honey, P. (1994). *Los estilos de aprendizaje. Procedimientos de diagnóstico y mejora* (7.ª ed.). Mensajero. <http://bit.ly/396WU5J>
- Al-Samarraie, H., y Saeed, N. (2018). A systematic review of cloud computing tools for collaborative learning: Opportunities and challenges to the blended-learning environment. *Computers & Education*, 124, 77-91. <https://doi.org/10.1016/j.compedu.2018.05.016>
- Altrabsheh, N., Cocea, M., y Fallahkhair, S. (2015). Predicting learning-related emotions from students' textual classroom feedback via Twitter. *Proceedings of the 8th International Conference on Educational Data Mining*, 446-440. <https://bit.ly/3OF4rOu>
- Anijovich, R., y Mora, S. (2009). *Estrategias de enseñanza: Otra mirada al quehacer en el aula* (Primera, Vol. 1). Aique. <http://bit.ly/30b8itH>

- Anisimova, O., Vasylenko, V., y Fedushko, S. (2019). Social networks as a tool for a higher education institution image creation. *arXiv preprint arXiv:1909.01678*.  
<https://doi.org/10.48550/arXiv.1909.01678>
- Araque Ortiz, S. P., Castaneda Avellaneda, M. Y., Fonseca Gómez, L. R., Martínez Reyes, C. J., y Ramírez Agudelo, C. A. (2013). *Fortalecimiento de habilidades matemáticas de cálculo y resolución de problemas mediante la aplicación de estrategias didácticas que contribuyan a mejorar el análisis, contextualización y comprensión de situaciones matemáticas en entornos reales*. [Corporación Universitaria Minuto de Dios].  
<http://hdl.handle.net/10656/2818>
- Area, M. (2008). Las redes sociales en Internet como espacios para la formación del profesorado. *Razón y palabra*, 63.  
<http://www.redalyc.org/articulo.oa?id=199520798005>
- Arrabal-Sánchez, G., y De-Aguilera-Moyano, M. (2016). Comunicar en 140 caracteres. Cómo usan Twitter los comunicadores en España. *Revista Comunicar*, 24(46), 9-17.  
<https://doi.org/10.3916/C46-2016-01>
- Ayala, T. (2017). Redes sociales, poder y participación ciudadana. *Revista Austral de Ciencias Sociales*, 26, 23-48. <https://doi.org/10.4206/rev.austral.cienc.soc.2014.n26-02>
- Azmi, N. A., Yusof, K. M., y Phang, F. A. (2017). How to Motivate Chemical Engineering Undergraduates to Learn Programming? *Chemical Engineering Transactions*, 56, 1303-1308. <https://doi.org/10.3303/CET1756218>
- Barreto, C. R., y Jimenez, A. C. (2010). El uso de Facebook y Twitter en educación. *Lumen-Instituto de Estudios en Educación-IESE*, 11, 1-9.
- Barrios Arce, J. I. (2019, julio 26). *La matriz de confusión y sus métricas*. Health Big Data.  
<https://www.juanbarrios.com/la-matriz-de-confusion-y-sus-metricas/>
- Barrón Estrada, M. L., Zatarain Cabada, R., Oramas Bustillos, R., y Graff, M. (2020). Opinion mining and emotion recognition applied to learning environments. *Expert Systems with Applications*, 150, 113265. <https://doi.org/10.1016/j.eswa.2020.113265>
- Baviera, T. (2017). Técnicas para el Análisis de Sentimiento en Twitter: Aprendizaje Automático Supervisado y SentiStrength. *Revista Dígitos*, 1(3), 33-50.  
<http://dx.doi.org/10.7203/rd.v1i3.74>
- Belanche Gracia, D., Flavián Blanco, C., y Guinalú Blasco, M. (2014). Aplicación de Twitter como herramienta de aprendizaje colaborativo en la enseñanza universitaria. En J. L. Alejandro Marco (Ed.), *Buenas prácticas en la docencia universitaria con apoyo de TIC: experiencias en 2013* (pp. 17-28). Prensas Universitarias de Zaragoza.  
<https://bit.ly/2xcByGf>
- Beltrán, J., Sánchez, H., y Rico, M. (2015). Análisis cuantitativo y cualitativo del aprendizaje de Programación I en la Universidad Central del Ecuador. *Revista Tecnológica-ESPOL*, 28(5), 194-210.
- Beltrán Llerena, J. (2003). Estrategias de Aprendizaje. *Revista de Educación*, 332, 55-73.  
<https://doi.org/10.4438/1988-592X-0034-8082-RE>

- Benítez Cortés, R. P., Aguilar Navarrete, P., Camacho González, M. F. Y., y Torres Covarrubias, V. J. (2017). Medios instruccionales que apoyan el aprendizaje de la programación de computadoras en estudiantes universitarios de carreras de TI. *Revista Internacional de Educación en Ingeniería*, 9(1), 1-7.
- Bhatia, P. (2019). *Data mining and data warehousing: Principles and practical techniques* (Primera). Cambridge University Press.  
<https://dl.ebooksworld.ir/motoman/Cambridge.University.Press.Data.Mining.and.Data.Warehousing.www.EBooksWorld.ir.pdf>
- Bird, S., Klein, E., y Loper, E. (2009). *Natural Language Processing with Python* (First). O'Reilly.
- Blanco Guijarro, R., y Messina Raimondi, G. (2000). *Estado del arte sobre las innovaciones educativas en América Latina*. UNESCO y el Convenio Andrés Bello.
- Bond, M., Buntins, K., Bedenlier, S., Zawacki-Richter, O., y Kerres, M. (2020). Mapping research in student engagement and educational technology in higher education: A systematic evidence map. *International Journal of Educational Technology in Higher Education*, 17(1), 2-30. <https://doi.org/10.1186/s41239-019-0176-8>
- Bonwell, C. C., y Eison, J. A. (1991). *Active Learning: Creating Excitement in the Classroom* (Ashe-Eric Higher Education Report). ERIC.  
<https://files.eric.ed.gov/fulltext/ED336049.pdf>
- Boyd, D. m., y Ellison, N. B. (2007). Social Network Sites: Definition, History, and Scholarship. *Journal of Computer-Mediated Communication*, 13(1), 210-230.  
<https://doi.org/10.1111/j.1083-6101.2007.00393.x>
- Bueno Delgado, M. V., y Pavón Mariño, P. (2011). El uso de las redes sociales como herramienta de apoyo a la docencia en la UPCT. *Congreso Internacional de Innovación Docente*. <http://hdl.handle.net/10317/2285>
- Cáceres Piñalozza, K. F. (2020). Educación virtual: Creando espacios afectivos, de convivencia y aprendizaje en tiempos de COVID-19. *CienciAmérica*, 9(2).  
<http://dx.doi.org/10.33210/ca.v9i2.284>
- Calabuig i Serra, S., y Donaire Benito, J. A. (2012). *El debate y la síntesis de aportaciones colaborativas en la educación superior con el Twitter como protagonista*. XXIII Simposio Internacional Didáctica de las Ciencias Sociales. Educar para la participación ciudadana en la enseñanza de las Ciencias Sociales (2012), p 527-535.  
<https://idus.us.es/xmlui/discover>
- Caldevilla Domínguez, D. (2010). Las Redes Sociales. Tipología, uso y consumo de las redes 2.0 en la sociedad digital actual. *Documentación de las Ciencias de la Información*, 33, 45-68. <https://dx.doi.org/10.5209/DCIN>
- Campillay Briones, S., y Meléndez Araya, N. (2015). Análisis de impacto de metodología activa y aprendizaje heurístico en asignaturas de ingeniería. *Actualidades Investigativas en educación*, 15(2), 330-346. <http://dx.doi.org/10.15517/aie.v15i2.18950>
- Cano, R. J. (2017, septiembre 27). Twitter amplía el límite a 280 caracteres por mensaje. *El País*. <http://bit.ly/2YwNXOv>

- Carlos-Martínez, E. A., Galván Parra, L. A., Hernández Gómez, J. S., y Ruiz Moreno, R. (2018). Factores asociados al rendimiento académico en estudiantes del nivel superior pertenecientes a la etnia Yaqui. *Revista de Pedagogía Crítica*, 2(6), 1-8.
- Carter, P. (2012). An experience report: On the use of multimedia pre-instruction and just-in-time teaching in a CS1 course. *Proceedings of the 43rd ACM technical symposium on Computer Science Education*, 361-366. <https://doi.org/10.1145/2157136.2157244>
- Castelló, M., Clariana, M., Palma, M., y Pérez, M. L. (1999). *Estrategias de enseñanza y aprendizaje Formación del profesorado y aplicación en la escuela* (C. Monereo, Ed.; Sexta). Editorial Graó.
- Castillo Landínez, S. P., y Caicedo Rodríguez, P. E. (2019). Análisis de sentimientos, una herramienta para valorar la actitud del estudiante frente a un curso. *Encuentro Internacional de Educación en Ingeniería*. Encuentro Internacional de Educación en Ingeniería ACOFI 2019, Colombia. <https://doi.org/10.26507/ponencia.141>
- Cengage. (2021, abril 30). *¿Qué metodologías educativas conoces?* <http://bit.ly/3Zm6U4s>
- Cetintas, S., Si, L., Aagard, H. P., Bowen, K., y Cordova-Sanchez, M. (2011). Microblogging in a Classroom: Classifying Students' Relevant and Irrelevant Questions in a Microblogging-Supported Classroom. *IEEE Transactions on Learning Technologies*, 4(4), 292-300. <https://doi.org/10.1109/TLT.2011.14>
- Chávez Márquez, I. L., y Gutiérrez Diez, M. del C. (2015). Redes sociales como facilitadoras del aprendizaje de ciencias exactas en la educación superior. *Revista Apertura*, 7(2), 49-61.
- Chávez Martínez, J. de J. (2015). Uso de las redes educativas en la educación superior. Un caso específico. *Revista Científica de Comunicación*, 6(1), 82-96.
- Chawinga, W. D. (2017). Taking social media to a university classroom: Teaching and learning using Twitter and blogs. *International Journal of Educational Technology in Higher Education*, 14(1), 3. <https://doi.org/10.1186/s41239-017-0041-6>
- Checa García, F. (2013). *La utilización del microblogging y de Twitter como herramienta de enseñanza-aprendizaje*. 19-27. <http://dx.doi.org/10.25115/ecp.v6i11.949>
- Chen, X., Vorvoreanu, M., y Madhavan, K. (2014). Mining Social Media Data for Understanding Students' Learning Experiences. *IEEE Transactions on Learning Technologies*, 7(3), 246-259. <https://doi.org/10.1109/TLT.2013.2296520>
- Chong González, E. G. (2017). Factores que inciden en el rendimiento académico de los estudiantes de la Universidad Politécnica del Valle de Toluca. *Revista Latinoamericana de Estudios Educativos (México)*, 47(1), 91-108. <https://doi.org/10.48102/rlee.2017.47.1.159>
- Chugh, R., y Ruhi, U. (2018). Social media in higher education: A literature review of Facebook. *Education and Information Technologies*, 23(2), 605-616. <https://doi.org/10.1007/s10639-017-9621-2>
- Cobos Peña, B. I. (2015). Perspectivas teóricas sobre estrategias de enseñanza para favorecer el aprendizaje significativo. *Revista de ciencias de la educación ACADEMICUS*, 1(7), 69-74.

- Coelho, T., y Figueira, Á. (2021). Analysis of Top-Ranked HEI Publications' Strategy on Twitter. *2021 IEEE International Conference on Big Data (Big Data)*, 5875-5877. <https://doi.org/10.1109/BigData52589.2021.9671383>
- Compañ-Rosique, P., Satorre-Cuerda, R., Llorens-Largo, F., y Molina-Carmona, R. (2015). Enseñando a programar: Un camino directo para desarrollar el pensamiento computacional. *Revista de Educación a Distancia*, 46. <http://bit.ly/2TaGbHK>
- Condori Melendez, H., Borja Villanueva, C. A., Saravia Alviar, R. A., Barzola Loayza, M. G., y Rodríguez Ruiz, J. R. (2021). Efectos de la pandemia por coronavirus en la educación superior universitaria. *Revista Conrado*, 17(82), 286-292.
- Cortez Bailón, F. M., Tutiven Campos, J. L., y Villavicencio Morejón, M. N. (2017). Determinantes del Rendimiento Académico Universitario. *Revista Publicando*, 4(10 (1)), 284-296.
- Davies, M. (2015). A model of critical thinking in higher education. En M. B. Paulsen (Ed.), *Higher education: Handbook of theory and research* (Vol. 34, pp. 41-92). Springer. [https://doi.org/10.1007/978-3-319-12835-1\\_2](https://doi.org/10.1007/978-3-319-12835-1_2)
- Davis, J. (2009). Experiences with just-in-time teaching in systems and design courses. *Proceedings of the 40th ACM technical symposium on Computer science education*, 41, 71-75. <https://doi.org/10.1145/1508865.1508895>
- Delfín de Manzanilla, B. (2007). Actitud de los estudiantes universitarios hacia el aprendizaje del inglés. *REDHECS*, 2(2), 1-35.
- Delgado-García, M., García-Prieto, F. J., y Gómez-Hurtado, I. (2018). Moodle y Facebook como herramientas virtuales didácticas de mediación de aprendizajes: Opinión de profesores y alumnos universitarios. *Revista complutense de educación*. <https://doi.org/10.5209/RCED.53968>
- Desai, M., y Mehta, M. A. (2018). Descriptive, Dynamic and Hybrid Classification Algorithm to Classify Engineering Students' Sentiments. En P. Bhattacharyya, H. G. Sastry, V. Marriboyina, y R. Sharma (Eds.), *Smart and Innovative Trends in Next Generation Computing Technologies* (pp. 122-138). Springer Singapore. [https://doi.org/10.1007/978-981-10-8657-1\\_10](https://doi.org/10.1007/978-981-10-8657-1_10)
- Díaz, J. (2006). Enseñando programación con C++: Una propuesta didáctica. *Revista de Informática Educativa y Medios Audiovisuales*, 3(7), 12-21.
- Díaz-Barriga, F., y Hernández Rojas, G. (2004). *Estrategias docentes para un aprendizaje significativo. Una interpretación constructivista* (2°). McGraw Hill. <http://bit.ly/394nYCz>
- Díaz-Mendivelso, J. D., y Suarez-Baron, M. J. (2019). Análisis social aplicando técnicas de lenguaje natural a información extraída de Twitter. *Scientia et Technica*, 24(3), 496-503. <https://doi.org/10.22517/23447214.21731>
- Dilman, D. A., Smyth, J. D., y Christian, L. M. (2014). *Internet, phone, mail, and mixed-mode surveys: The tailored design method*. Hoboken (Cuarta). NJ: Wiley. <http://bit.ly/2SYubdD>
- Duong, V., Luo, J., Pham, P., Yang, T., y Wang, Y. (2020). The ivory tower lost: How college students respond differently than the general public to the covid-19 pandemic. *2020*

*IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*, 126-130. <https://doi.org/10.1109/ASONAM49781.2020.9381379>

Eisenstein, J. (2018). *Natural language processing*. MIT press.

El Comercio. (2020, marzo 11). Gobierno decreta emergencia sanitaria en Ecuador por covid-19. *El Comercio*. <https://www.elcomercio.com/actualidad/salud-coronavirus-emergencia-sanitaria-covid19.html>

Escobar Díaz, A. B., y Llumiquinga Latacunga, D. F. (2018). *Estilos de aprendizaje en estudiantes de 1ero, 4to y 9no semestre de la carrera de Psicología Educativa y Orientación de la Universidad Central del Ecuador, de la ciudad de Quito, en el período Marzo-Agosto 2017* [Universidad Central del Ecuador]. <http://bit.ly/3c6zjEh>

Espinar Ruiz, E., y González Río, M. J. (2009). Jóvenes en las redes sociales virtuales. Un análisis exploratorio de las diferencias de género. *Feminismo/s*, 14, 87-106. <http://dx.doi.org/10.14198/fem.2009.14.06>

Euroinnova. (2023). Tipos de estrategias pedagógicas [Educativo]. *Conoce sobre los tipos de estrategias pedagógicas*. <https://www.euroinnova.ec/blog/tipos-de-estrategias-pedagogicas#conoce-los-5-tipos-de-estrategias-pedagoacutegicas-maacutes-usadas>

Fahrudin, T., Buliali, J. L., y Fatichah, C. (2019). Ina-BWR: Indonesian bigram word rule for multi-label student complaints. *Egyptian Informatics Journal*, 20(3), 151-161. <https://doi.org/10.1016/j.eij.2019.03.001>

Fan, W., y Bifet, A. (2013). Mining big data: Current status, and forecast to the future. *ACM SIGKDD explorations newsletter*, 14(2), 1-5. <https://doi.org/10.1145/2481244.2481246>

Fathima Shafana, A. R., y Safnas, S. M. (2022). Does technology assist to continue learning during pandemic? A sentiment analysis and topic modeling on online learning in south asian region. *Social Network Analysis and Mining*, 12(1), 1-7. <https://doi.org/10.1007/s13278-022-00899-4>

Feldman, R., y Sanger, J. (2007). *The Text Mining Handbook: Advanced Approaches in Analyzing Unstructured Data*. Cambridge University Press. <https://dl.icdst.org/pdfs/files/25a6d982ee80e1db7a4ebf7eeca4e0ec.pdf>

Fernández March, A. (2006). Metodologías activas para la formación de competencias. *Educatio siglo XXI*, 24, 35-56.

Fernández Solo de Zaldivar, I. (2017). Mejora de competencias: Introducción de la gestión de calidad en nuevas metodologías educativas. *Profesorado. Revista de Currículum y Formación de Profesorado*, 21(2), 279-308.

Fernández-Ferrer, M., y Cano, E. (2016). The influence of the internet for pedagogical innovation: Using twitter to promote online collaborative learning. *International Journal of Educational Technology in Higher Education*, 13(1), 22. <https://doi.org/10.1186/s41239-016-0021-2>

Ferrer, T. (2015). Métodos de enseñanza comunicativos: El juego como estrategia didáctica en la instrucción del español como segunda lengua. *Lúdicamente*, 4(8), 1-22.



- Fisher, M., King, J., y Tague, G. (2001). Development of a self-directed learning readiness scale for nursing education. *Nurse Education Today*, 21(7), 516-525. <https://doi.org/10.1054/nedt.2001.0589>
- Forés Miravalles, A., y Bueno i Torrens, D. (2019, febrero 20). Hay una fórmula para saber si una metodología educativa tiene solvencia científica. *The Conversation*. <https://theconversation.com/hay-una-formula-para-saber-si-una-metodologia-educativa-tiene-solvencia-cientifica-111969>
- Forma Infancia. (2021). *¿Cuáles son las metodologías educativas?* [Educativo]. Forma Infancia European School. [https://formainfancia.com/metodologias-educativas-tipos-aprendizaje/#%C2%BFQue\\_es\\_una\\_metodologia\\_educativa](https://formainfancia.com/metodologias-educativas-tipos-aprendizaje/#%C2%BFQue_es_una_metodologia_educativa)
- Frías-Navarro, D. (2014). Apuntes de SPSS. *Universidad de valencia*, 1-10.
- Froment, F., García-González, A.-J., y Cabero-Almenara, J. (2022). Relación de la red social Twitter con la credibilidad docente y la motivación del alumnado universitario. *Revista Comunicar*, 30(71), 131-142. <https://doi.org/10.3916/C71-2022-10>
- Fu, Z., Yan, M., Meng, C., Wang, W., Hu, X., Li, Y., Wang, J., He, Z., y Wang, Z. (2020). Opinion mining about online education basing on GDELT and Twitter data. *2020 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology (WI-IAT)*, 741-745. <https://doi.org/10.1109/WIIAT50758.2020.00114>
- Fuentes-Rosado, J. I., y Moo-Medina, M. (2017). Dificultades de aprender a programar. *Revista Educación en Ingeniería*, 12(24), 76-82. <http://dx.doi.org/10.26507/rei.v12n24.728>
- Fumero, F. (2009). Estrategias didácticas para la comprensión de textos. Una propuesta de investigación acción participativa en el aula. *Investigación y Postgrado*, 24(1), 46-73.
- Galicia Alarcón, L. A., Balderrama Trápaga, J. A., y Navarro, R. E. (2017). Validez de contenido por juicio de expertos: Propuesta de una herramienta virtual. *Apertura (Guadalajara, Jal.)*, 9(2), 42-53. <http://dx.doi.org/10.18381/Ap.v9n2.993>
- Gallardo-López, J. A., y López-Noguero, F. (2020). Twitter como recurso metodológico en Educación Superior: Una experiencia educativa con estudiantes de Trabajo Social. *ALTERIDAD. Revista de Educación*, 15(2), 174-189. <https://doi.org/10.17163/alt.v15n2.2020.03>
- Gao, F., Luo, T., y Zhang, K. (2012). Tweeting for learning: A critical analysis of research on microblogging in education published in 2008–2011. *British Journal of Educational Technology*, 43(5), 783-801. <https://doi.org/10.1111/j.1467-8535.2012.01357.x>
- García, J. S. (2015). Desarrollo de las redes sociales como herramienta de marketing. Estado de la cuestión hasta 2015. *Anagramas Rumbos y Sentidos de la Comunicación*, 13(26), 179-196.
- García Suárez, J., Trigueros Cervantes, C., y Rivera García, E. (2015). Twitter as a resource to evaluate the university teaching process. *RUSC: Revista de Universidad y Sociedad del Conocimiento*, 12(3), 32-45. <http://dx.doi.org/10.7238/rusc.v12i3.2092>
- Gargallo López, B., Almerich Cerveró, G., García Félix, E., y Jiménez Rodríguez, M. Á. (2011). Actitudes ante el aprendizaje en estudiantes universitarios excelentes y en estudiantes

medios. *Teoría de la Educación. Educación y Cultura en la Sociedad de la Información*, 12(3), 200-220. <http://dx.doi.org/10.14201/eks.8489>

- Gartner Group. (2019). *Data Mining-Big Data Analytics-Gartner*. IT Glossary. <https://gtnr.it/2SoStLT>
- Gazzo, M. F. (2020). La educación en tiempos del COVID-19: Nuevas prácticas docentes, ¿nuevos estudiantes? *Red Sociales, Revista del Departamento de Ciencias Sociales*, 7(2), 58-63.
- Gebre, E., Saroyan, A., y Bracewell, R. (2014). Students' engagement in technology rich classrooms and its relationship to professors' conceptions of effective teaching. *British Journal of Educational Technology*, 45(1), 83-96. <https://doi.org/10.1111/bjet.12001>
- Gil-Fernández, R., y Calderón, D. (2021). El uso de las redes sociales en educación: Una revisión sistemática de la literatura científica. *Digital Education Review*, 40, 82-109.
- Gong, X., y D. Lane, K. M. (2020). Institutional Twitter usage among US geography departments. *The professional geographer*, 72(2), 219-237. <https://doi.org/10.1080/00330124.2019.1653770>
- González, L. (2018). *Clasificación de Machine Learning*. Aprende IA. <https://aprendeia.com/clasificacion-de-machine-learning/>
- González, L. (2022a). *K vecinos más cercanos*. Aprende IA. <https://aprendeia.com/k-vecinos-mas-cercanos-teoria-machine-learning/>
- González, L. (2022b). *Regresión Lineal – Teoría*. Aprende IA. <https://aprendeia.com/algorithmo-regresion-lineal-simple-machine-learning/>
- Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep learning*. MIT press. <http://www.deeplearningbook.org>
- Google Developers. (2022). *Descending into ML: Training and Loss*. Machine Learning - Foundational courses. <https://developers.google.com/machine-learning/crash-course/descending-into-ml/training-and-loss?hl=es-419>
- Gorunescu, F. (2011). *Data Mining: Concepts, Models and Techniques* (Vol. 12). Springer. 10.1007/978-3-642-19721-5
- Graves, I., y Ziaeehezarjeribi, Y. (2010). *Microblogging with university students 24/7: Twitter comes of age. 2*, 122-128. [https://members.aect.org/pdf/Proceedings/proceedings10/2010I/10\\_18.pdf](https://members.aect.org/pdf/Proceedings/proceedings10/2010I/10_18.pdf)
- Greeshma, A., y Veigas, A. M. (2020). Analyzing Student's Learning Experiences by using Social Media data Through Data Mining. *International Journal of Scientific Research in Computer Science Applications and Management Studies*, 9(1). <http://bit.ly/3iisHtK>
- Griffiths, L., Villarroel, R., y Ibacache, D. (2016). Implementación del modelo de aula Invertida para el aprendizaje activo de la programación en ingeniería. *XXIX Congreso Chileno de Educación en Ingeniería*. <https://bit.ly/2VqBqvi>
- Gunawansyah, Rahayu, R., Nurwathi, Sugiarto, B., y Gunawan. (2020). Automated Essay Scoring Using Natural Language Processing And Text Mining Method. *2020 14th*

*International Conference on Telecommunication Systems, Services, and Applications (TSSA)*, 1-4. <https://doi.org/10.1109/TSSA51342.2020.9310845>

- Gutiérrez Tapias, M., y García Cué, J. L. (2016). Estilos de aprendizaje y diseño de estrategias didácticas desde la perspectiva emocional del alumnado y del profesorado. *Journal of Learning Styles*, 9(18). <http://bit.ly/32AScuv>
- Guzmán Duque, A. P., Del Moral Pérez, M. E., y González Ladrón de Guevara, F. (2012). Usos de Twitter en las universidades iberoamericanas. *RELATEC Revista Latinoamericana de Tecnología Educativa*, 11(1), 27-39.
- Ha, I., Jung, J. J., y Kim, C. (2013). Influence of Twitter Activity on College Classes. En C. Bădică, N. T. Nguyen, y M. Brezovan (Eds.), *Computational Collective Intelligence. Technologies and Applications* (pp. 612-621). Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-40495-5>
- Ha, I., Park, H., y Kim, C. (2014). Analysis of Twitter research trends based on SLR. *16th International Conference on Advanced Communication Technology*, 774-778. <https://doi.org/10.1109/ICACT.2014.6779067>
- Han, J., Pei, J., y Kamber, M. (2011). *Data mining: Concepts and techniques* (Third Edition). Elsevier. <http://bit.ly/309rE2m>
- Handelsman, M. M., Briggs, W. L., Sullivan, N., y Towler, A. (2005). A measure of college student course engagement. *The Journal of Educational Research*, 98(3), 184-192. <https://doi.org/10.3200/JOER.98.3.184-192>
- Hasan, M., Agu, E., y Rundensteiner, E. (2014). Using hashtags as labels for supervised learning of emotions in twitter messages. *ACM SIGKDD workshop on health informatics, New York, USA*, 34(74), 100.
- Hauff, C., Berthold, M., Houben, G.-J., Steiner, C. M., y Albert, D. (2012). Tweets Reveal More Than You Know: A Learning Style Analysis on Twitter. En A. Ravenscroft, S. Lindstaedt, C. D. Kloos, y D. Hernández-Leo (Eds.), *21st Century Learning for 21st Century Skills* (pp. 140-152). Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-642-33263-0\\_12](https://doi.org/10.1007/978-3-642-33263-0_12)
- Hernández Lalinde, J. D., Espinosa Castro, J. F., Peñaloza Tarazona, M. E., Rodríguez, J. E., Chacón Rangel, J. G., Toloza Sierra, C. A., Arenas Torrado, M. K., Carrillo Sierra, S. M., y Bermúdez Pirela, V. J. (2018). Sobre el uso adecuado del coeficiente de correlación de Pearson: Definición, propiedades y suposiciones. *Archivos Venezolanos de Farmacología y Terapéutica*, 35(5). <https://bit.ly/3nqexx>
- Hernández Nieto, R. (2011). *Instrumentos de Recolección de Datos En Ciencias Sociales y Ciencias Biomédicas. Coeficiente de Validez de Contenido*. Createspace. <https://bit.ly/3dEu0fJ>
- Hernández Orallo, J., Ferri Ramirez, C., y Ramirez Quintana, M. J. (2004). *Introducción a la Minería de Datos* (Primera). Pearson Educación. <http://bit.ly/2FGtqP1>
- Hernández Sampieri, R., Fernández Collado, C., y Baptista Lucio, M. del P. (2010). *Metodología de la investigación* (Quinta). McGraw-Hill. <http://bit.ly/385JdT8>
- Herrera Capita, Á. M. (2009). Las estrategias de aprendizaje. *El viso de Alcor*, 45(16). <http://bit.ly/2PlcbT1>

- Hoffbeck, J. P., Dillon, H. E., Albright, R. J., Lu, W., y Doughty, T. A. (2016). Teaching programming in the context of solving engineering problems. *2016 IEEE Frontiers in Education Conference (FIE)*, 1-7.
- HootSuite. (2022). *Digital 2022 Global Overview Report*.  
<https://www.hootsuite.com/it/risorse/digital-trends>
- IBM. (2019). *Software IBM SPSS - España | IBM*. Productos de IBM Analytics.  
<https://ibm.co/2RPZ4yW>
- Ingole, P., Bhoir, S., y Vidhate, A. V. (2018). Hybrid Model For Text Classification. *2018 Second International Conference on Electronics, Communication and Aerospace Technology (ICECA)*, 7-15. <https://doi.org/10.1109/ICECA.2018.8474738>
- Insuasti, J. (2016). Problemas de enseñanza y aprendizaje de los fundamentos de programación. *Revista educación y desarrollo social*, 10(2), 234-246.  
<https://doi.org/10.18359/reds.1966>
- INTECO y AEPD. (2009). *Estudio sobre la privacidad de los datos personales y la seguridad de la información en las redes sociales online*. División de Comunicaciones de AEPD e INTECO, Madrid.
- Issa, M. B., Darwish, O., Allah, D. H., Shatnawi, F., Darweesh, D., y Tashtoush, Y. M. (2022). Analysis of Jordanian University Students Problems Using Data Mining System. *2022 13th International Conference on Information and Communication Systems (ICICS)*, 220-225. <https://doi.org/10.1109/ICICS55353.2022.9811199>
- Janiesch, C., Zschech, P., y Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695. <https://doi.org/10.1007/s12525-021-00475-2>
- Jara, D., Velarde, H., Gordillo, G., Guerra, G., León, I., Arroyo, C., y Figueroa, M. (2008). Factores influyentes en el rendimiento académico de estudiantes del primer año de medicina. *Anales de la Facultad de Medicina*, 69(3), 193-197.  
<https://doi.org/10.15381/anales.v69i3.1140>
- Javaloyes Sáez, M. J. (2016). *La enseñanza de estrategias de aprendizaje en el aula: Estudio descriptivo en profesorado de nieves no universitarios* [Tesis Doctoral, Valladolid].  
<http://bit.ly/2T0hKOC>
- Jena, R. K. (2019). Sentiment mining in a collaborative learning environment: Capitalising on big data. *Behaviour & Information Technology*, 38(9), 986-1001.  
<https://doi.org/10.1080/0144929X.2019.1625440>
- Jenaro-Río, C., Castaño-Calle, R., Martín-Pastor, M. E., y Flores-Robaina, N. (2018). Rendimiento académico en educación superior y su asociación con la participación activa en la plataforma Moodle. *Estudios sobre Educación*, 34, 177-198.  
<https://doi.org/10.15581/004.34.177-198>
- Jo, T. (2019). *Text Mining: Concepts, Implementation, and Big Data Challenge* (Vol. 45). Springer. <https://doi.org/10.1007/978-3-319-91815-0>
- Johnson, R. B., y Christensen, L. (2014). *Educational research: Quantitative, qualitative, and mixed approaches* (Quinta). SAGE Publications.

- Jones, A. (2011). How Twitter Saved My Literature Class: A Case Study with Discussion. En *Teaching Arts and Science with the New Social Media* (Vol. 3, pp. 91-105). Emerald Group Publishing Limited. [https://doi.org/10.1108/S2044-9968\(2011\)0000003008](https://doi.org/10.1108/S2044-9968(2011)0000003008)
- Joshi, S., y Sharma, S. K. (2021). A Model for Good Learning Environment Using Learning Data Analytics. *Procedia Computer Science*, 194, 156-164. <https://doi.org/10.1016/j.procs.2021.10.069>
- Joyanes Aguilar, L. (2008). *Fundamentos de Programación: Algoritmos, estructura de datos y objetos* (4.ª ed.). McGRAW-HILL.
- Junco, R., Heiberger, G., y Loken, E. (2011). The effect of Twitter on college student engagement and grades. *Journal of computer assisted learning*, 27(2), 119-132. <https://doi.org/10.1111/j.1365-2729.2010.00387.x>
- Jurafsky, D., y Martin, J. H. (2023). *Speech and Language Processing* (3rd. Edition). <https://web.stanford.edu/~jurafsky/slp3/>
- Kahu, E. R. (2013). Framing student engagement in higher education. *Studies in higher education*, 38(5), 758-773. <https://doi.org/10.1080/03075079.2011.598505>
- Kantardzic, M. (2020). *Data mining: Concepts, models, methods, and algorithms* (Third Edition). John Wiley & Sons.
- Kao, E. (2010). Exploring Computational Thinking [Educativo]. *Google AI Blog*. <https://bit.ly/3HP03Zm>
- Kassens-Noor, E. (2012). Twitter as a teaching practice to enhance active and informal learning in higher education: The case of sustainable tweets. *Active Learning in Higher Education*, 13(1), 9-21. <https://doi.org/10.1177/1469787411429190>
- Katia, R., D'Almeida, N., y Chamoun, M. (2020). Social big data: A Twitter text mining approach to the communication of universities during the Lebanese protests. *2020 International Conference on Cyber Security and Protection of Digital Services (Cyber Security)*, 1-8. <https://doi.org/10.1109/CyberSecurity49315.2020.9138876>
- Keles, E. (2018). Use of Facebook for the Community Services Practices course: Community of inquiry as a theoretical framework. *Computers & Education*, 116, 203-224. <https://doi.org/10.1016/j.compedu.2017.09.003>
- Keras. (2022). *Keras API reference*. Losses. <https://bit.ly/3NGCzYF>
- Kimmons, R., y Veletsianos, G. (2016). Education scholars' evolving uses of twitter as a conference backchannel and social commentary platform. *British Journal of Educational Technology*, 47(3), 445-464. <https://doi.org/10.1111/bjet.12428>
- Kimmons, R., Veletsianos, G., y Woodward, S. (2017). Institutional Uses of Twitter in U.S. Higher Education. *Innovative Higher Education*, 42(2), 97-111. <https://doi.org/10.1007/s10755-016-9375-6>
- Kingman, D., y Ba, J. (2014). Adam: A Method for Stochastic Optimization. *ArXiv*. <https://doi.org/10.48550/arXiv.1412.6980>

- Kitchenham, B. (2007). *Guidelines for performing systematic literature reviews in software engineering*. Technical report, Ver. 2.3 EBSE Technical Report. EBSE. <https://www.academia.edu>
- Kleftodimos, A., y Evangelidis, G. (2013). An Overview of Web Mining in Education. *Proceedings of the 17th Panhellenic Conference on Informatics*, 106-113. <https://doi.org/10.1145/2491845.2491863>
- Lambert, R., y Smith, T. (2014). A systematic review investigating the use of Twitter and Facebook in university-based healthcare education. *Health Education*, 114(5), 347-366. <https://doi.org/10.1108/HE-07-2013-0030>
- Laurence, A. (2022). *AntConc* (Version 4.0.3) [Computer Software]. Tokyo, Japan: Waseda University. <https://www.laurenceanthony.net/software/antconc/>
- Leendert, B., Waerden, D., y Marinus Taisbak, C. (2021). *Euclid Encyclopedia Britannica*. <https://www.britannica.com/biography/Euclid-Greek-mathematician>
- Lemay, D. J., Basnet, R. B., Doleck, T., y Bazalais, P. (2019). Social network analysis of twitter use during the AERA 2017 annual conference. *Education and Information Technologies*, 24(1), 459-470. <https://doi.org/10.1007/s10639-018-9787-2>
- Letierce, J., Passant, A., Breslin, J. G., y Decker, S. (2010). Using twitter during an academic conference: The# iswc2009 use-case. *Fourth International AAAI Conference on Weblogs and Social Media*.
- Leung, T. N., Hui, Y. M., Luk, C. K., Chiu, D. K., y Ho, K. K. (2022). Evaluating Facebook as aids for learning Japanese: Learners' perspectives. *Library Hi Tech, ahead-of-print*.
- Llorens Cerdà, F., y Capdeferro Planas, N. (2011). Facebook's potential for collaborative e-learning. *Revista de Universidad y Sociedad del Conocimiento*, 8(2), 197-210.
- Llorens Largo, F. (2015). *Dicen por ahí... que la nueva alfabetización pasa por la programación*. 11-14.
- Lowe, B., y Laffey, D. (2011). Is Twitter for the Birds?: Using Twitter to Enhance Student Learning in a Marketing Course. *Journal of Marketing Education*, 33(2), 183-192. <https://doi.org/10.1177/0273475311410851>
- Mac Gaul, M., López, M. F., y Del Olmo, P. (2008). *Resolución de problemas computacionales: Análisis del proceso de aprendizaje*. III Congreso de Tecnología en Educación y Educación en Tecnología, Argentina. <https://bit.ly/3JJuvET>
- Maimon, O., y Rokach, L. (2010). *Data mining and knowledge discovery handbook* (Segunda). Springer. 10.1007/978-0-387-09823-4
- Makode, A., Chakraborty, A., Darekar, A., y Bist, P. (2021). Impact Of Covid-19 On Education Using Twitter Data. *2021 16th International Workshop on Semantic and Social Media Adaptation & Personalization (SMAP)*, 1-6. <https://doi.org/10.1109/SMAP53521.2021.9610821>
- Malik, A., Heyman-Schrum, C., y Johri, A. (2019). Use of Twitter across educational settings: A review of the literature. *International Journal of Educational Technology in Higher Education*, 16(1), 1-22. <https://doi.org/10.1186/s41239-019-0166-x>

- Mandefro, E. (2019). Analysis of the Determinants of Classroom Participation of Students': Perceptions of University Student. *Journal Of Humanities And Social Science*, 24(11), 4-12. <https://doi.org/10.9790/0837>
- Maor, D., y Currie, J. K. (2017). The use of technology in postgraduate supervision pedagogy in two Australian universities. *International Journal of Educational Technology in Higher Education*, 14(1), 1. <https://doi.org/10.1186/s41239-017-0046-1>
- Marcelo, C., y Marcelo, P. (2021). Influencers educativos en Twitter. Análisis de hashtags y estructura relacional. *Revista Comunicar*, XXIX(68), 73-83. <https://doi.org/10.3916/C68-2021-06>
- Marín-Díaz, V., y Cabero-Almenara, J. (2019). Las redes sociales en educación: Desde la innovación a la investigación educativa. *Revista Iberoamericana de Educación a Distancia*, 22(2), 25-33. <https://doi.org/10.5944/ried.22.2.24248>
- Martínez-Rodrigo, E., y Raya-González, P. (2013). El microblogging en el proceso de enseñanza-aprendizaje. Una experiencia académica con Twitter. *Historia y Comunicación Social*, 18(Esp.), 139-149. [http://dx.doi.org/10.5209/rev\\_HICS.2013.v18.44232](http://dx.doi.org/10.5209/rev_HICS.2013.v18.44232)
- Matas Terrón, A., Leiva Olivencia, J. J., y Franco Caballero, P. D. (2020). Big Data Irruption in Education. *Píxel-BIT Revista de Medios y Educación*, 57, 59-90. <https://doi.org/10.12795/pixelbit.2020.i57.02>
- Matassi, M., y Boczkowski, P. J. (2020). Redes sociales en Iberoamérica. Artículo de revisión. *El profesional de la información (EPI)*, 29(1). <https://doi.org/10.3145/epi.2020.ene.04>
- Matosas-López, L., Luzardo-Briceño, M., Aguilar-Jiménez, A.-S., y Jaimes-Carrillo, L. (2021). Relaciones entre redes sociales y recursos digitales de instrucción en la universidad: Comparativa España – Colombia. *Pixel-Bit. Revista de Medios y Educación*, 60, 77-93. <https://doi.org/10.12795/pixelbit.77522>
- Mayer, R. E. (1984). Aids to text comprehension. *Educational psychologist*, 19(1), 30-42. <https://doi.org/10.1080/00461528409529279>
- Mayer, R. E. (1988). Learning strategies: An overview. En C. E. Weinstein, E. T. Goetz, y P. A. Alexander (Eds.), *Learning and study strategies* (pp. 11-22). Elsevier. <https://doi.org/10.1016/B978-0-12-742460-6.50008-6>
- McKinney, W. (2018). *Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython* (segunda). O'Reilly.
- Medium. (2018). *200codeblog*. Crear aplicación en twitter. <https://medium.com/200codeblog/crear-aplicaci%C3%B3n-en-twitter-4b0b13f86453>
- Méndez Hinojosa, L. M., y González Ramírez, M. T. (2011). Escala de estrategias docentes para aprendizajes significativos: Diseño y evaluación de sus propiedades psicométricas. *Revista Electrónica «Actualidades Investigativas en Educación»*, 11(3), 1-39.
- Mertens, D. M. (2014). *Research and evaluation in education and psychology: Integrating diversity with quantitative, qualitative, and mixed methods*. Sage publications.
- Michaelson, G. (2015). Teaching Programming with Computational and Informational Thinking. *Journal of Pedagogic Development*, 5(1). <http://hdl.handle.net/10547/346506>

- Michavila, F. (2009). La innovación educativa. Oportunidades y barreras. *ARBOR Ciencia, Pensamiento y Cultura*, 185(Extra), 3-8.  
<https://doi.org/10.3989/arbor.2009.extran1201>
- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- Moguel Marín, S. F., Alonzo Rivera, D., y Gasca Santos, J. (2012). Metodología para el uso del twitter como plataforma para la metacognición y otras competencias. *Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 8.  
<https://silo.tips/download/metodologia-para-el-uso-del-twitter-como-plataforma-para-la-metacognicion-y-otra>
- Molina Izurieta, R. E., Padilla Gómez, R. R., y Leyva Vázquez, M. Y. (2019). Estudio y propuesta metodológica para la enseñanza-aprendizaje de la programación informática en la educación superior. *Revista Dilemas Contemporáneos: Educación, Política y Valores*, VII(8). <https://doi.org/10.46377/dilemas.v30i1.1294>
- Monereo, C. (1990). Las estrategias de aprendizaje en la Educación formal: Enseñar a pensar y sobre el pensar. *Infancia y Aprendizaje*, 13(50), 3-25.  
<http://dx.doi.org/10.1080/02103702.1990.10822263>
- Morales, G. L. (2015). *Aspectos educativos de las redes sociales: Un análisis de los factores que determinan su puesta en práctica* [Tesis Doctoral, Universidad de Sevilla].  
<https://idus.us.es/xmlui/>
- Moreira, D., Cruz, I., Gonzalez, K., Quirumbay, A., Magallan, C., Guarda, T., Andrade, A., y Castillo, C. (2021). Análisis del Estado Actual de Procesamiento de Lenguaje Natural. *Revista Ibérica de Sistemas e Tecnologías de Informação*, E42, 126-136.
- Mousalli-Kayat, G. (2015). Métodos y diseños de investigación cuantitativa. *Researchgate*.  
<https://doi.org/10.13140/RG.2.1.2633.9446>
- Müller, A. C., y Guido, S. (2016). *Introduction to Machine Learning with Python* (Primera). O'Reilly.
- Murillo, J. (2011). *Métodos de investigación de enfoque experimental*. Escuela de Posgrado UNE - Perú. <https://www.postgradoune.edu.pe/pdf/documentos-academicos/ciencias-de-la-educacion/10.pdf>
- Nabeel, M., Majeed, S., Awan, M. J., Muslih-ud-Din, H., Wasique, M., y Nasir, R. (2021). Review on Effective Disease Prediction through Data Mining Techniques. *International Journal on Electrical Engineering & Informatics*, 13(3).  
<https://doi.org/10.15676/ijeei.2021.13.3.13>
- Nesbet Montecinos, F. A., y Cárcamo Ulloa, L. R. (2020). Gratuidad en la educación superior chilena: Análisis de prensa basado en minería de datos. *Revista Latinoamericana de Estudios Educativos (México)*, 50(2), 9-30. <https://doi.org/10.48102/rlee.2020.50.2.69>
- NLTK Project. (2022). *Natural Language Toolkit*. NLTK Documentation. <https://bit.ly/3PPzr2>
- Novak, G. M., Patterson, E. T., Gavrin, A. D., y Wolfgang, C. (1999). *Just in time teaching* (Vol. 67). American Association of Physics Teachers. <https://doi.org/10.1119/1.19159>



- NVIVO. (2019). *Software NVivo para investigación cualitativa | NVivo*. NVIVO: Software N 1º para el análisis cualitativo de datos. <http://bit.ly/2ZUuk2m>
- Oanh, T. T. (2020). Attentive biLSTMs for Understanding Students' Learning Experiences. En H. A. Le Thi, H. M. Le, T. Pham Dinh, y N. T. Nguyen (Eds.), *Advanced Computational Methods for Knowledge Engineering* (pp. 267-278). Springer International Publishing.
- Obar, J., y Wildman, S. (2015). Social Media Definition and Governance Challenge: An Introduction to Special Issue. *Telecommunications policy*, 39(9), 745-750. <http://dx.doi.org/10.2139/ssrn.2663153>
- Olivares-Olivares, S. L., y Wong Tamez, M. (2013). Medición de la autopercepción de la disposición al pensamiento crítico en estudiantes de medicina. *XII Congreso Nacional de Investigación Educativa*, 1-12. <http://www.comie.org.mx/congreso/memoriaelectronica/v12/seccion4.htm>
- Ordorika, I. (2020). Pandemia y educación superior. *Revista de la educación superior*, 49(194), 1-8.
- Orlich, D., Harder, R. J., Callahan, R. C., Trevisan, M. S., y Brown, A. H. (2010). *Teaching Strategies: A Guide to Effective Instruction* (novena). Wadsworth.
- Ortega Cuenca, P., Ramírez Solís, M. E., Torres Guerrero, J. L., López Rayón, A. E., Servín Martínez, C. Y., Suárez Téllez, L., y Ruiz Hernández, B. (2007). Modelo de innovación educativa. Un marco para la formación y el desarrollo de una cultura de innovación. *RIED-Revista Iberoamericana de Educación a Distancia*, 10(1), 145-173.
- Ortega-Ruipérez, B., y Asensio Brouard, M. (2018). Robótica DIY: pensamiento computacional para mejorar la resolución de problemas. *Revista Latinoamericana de Tecnología Educativa - RELATEC*, 17(2). <https://doi.org/10.17398/1695-288X.17.2.129>
- Ortiz Ocaña, A. (2013). *Modelos pedagógicos y teorías del aprendizaje* (Primera). Ediciones de la U. <http://bit.ly/2TaAtaG>
- Oviedo Galdeano, M., y Ortiz Uribe, F. G. (2002). *La enseñanza de la Programación*. Silo.Tips. <https://bit.ly/367xyYJ>
- Pardal-Refoyo, J. L., y Pardal-Peláez, B. (2020). Anotaciones para estructurar una revisión sistemática. *Revista ORL*, 11(2), 155-160. <https://doi.org/10.14201/orl.22882>
- Parra Pineda, D. M. (2003). *Manual de estrategias de enseñanza/aprendizaje* (Primera). Pregón Ltda. <https://bit.ly/34gODdN>
- Parselis, M. (2014). Función e innovación social: El caso Twitter. *Revista iberoamericana de ciencia, tecnología y sociedad*, 9(25), 53-71.
- Patel, P., y Mistry, K. (2015). Classification of student's e-learning experiences' in social media via text mining. *IOSR J. Comput. Eng.(IOSR-JCE)*, 17(3), 81-89. <https://doi.org/10.9790/0661-17368189>
- Patil, S., y Kulkarni, S. (2018). Mining Social Media Data for Understanding Students' Learning Experiences using Memetic algorithm. *International Conference on Processing of Materials, Minerals and Energy (July 29th – 30th) 2016, Ongole, Andhra Pradesh, India*, 5(1, Part 1), 693-699. <https://doi.org/10.1016/j.matpr.2017.11.135>

- Payne, L. (2017). Student engagement: Three models for its investigation. *Journal of Further and Higher Education*, 43(5), 641-657.  
<https://doi.org/10.1080/0309877X.2017.1391186>
- Pejić Bach, M., Pulido, C. M., Suša Vugec, D., Ionescu, V., Redondo-Sama, G., y Ruiz-Eugenio, L. (2020). Fostering Social Project Impact with Twitter: Current Usage and Perspectives. *Sustainability*, 12(15). <https://doi.org/10.3390/su12156290>
- Pérez Angulo, J. A., y Pedroza Palomar, O. V. (2018). LM1: Una metodología de estudio para la asignatura "Programación 1". *Educere: Revista Venezolana de Educación*, 22(73), 635-648.
- Pérez-Suasnavas, A.-L. (2023). Performance evaluation of a predictive model of student difficulties, based on neural networks. *En prensa*. XIII International Conference on Virtual Campus (JICV), Porto, Portugal.
- Pérez-Suasnavas, A.-L., y Cela, K. (2020). Aplicación de la Metodología JiTTwT y su incidencia en las aulas universitarias. En G. Gómez García, M. Ramos Navas-Parejo, C. Rodríguez Jiménez, y J. C. de la Cruz Campos (Eds.), *Teoría y práctica en investigación educativa: Una perspectiva internacional* (pp. 1343-1356). Dykinson S. L. <https://bit.ly/3xnXEQe>
- Pérez-Suasnavas, A.-L., y Cela, K. (2022). Incidencia de la Metodología JiTTwT en el rendimiento académico de estudiantes universitarios. *Espiral. Cuadernos del Profesorado*, 15(30), 11-23. <https://doi.org/10.25115/ecp.v15i30.6500>
- Pérez-Suasnavas, A.-L., Cela, K., y Hasperué, W. (2020a). Beneficios del uso de técnicas de minería de datos para extraer y analizar datos de twitter aplicados en la educación superior: Una revisión sistemática de la literatura. *Universidad de Salamanca*, 32(2), 1-38. <http://dx.doi.org/10.14201/teri.22171>
- Pérez-Suasnavas, A.-L., Cela, K., y Hasperué, W. (2020b). Propuesta de Estrategia Educativa, para Fomentar la Participación Estudiantil Universitaria. En E. Archundia Sierra, M. Á. León Chávez, y C. Cerón Garnica (Eds.), *Redes de aprendizaje digital en nodos colaborativos* (pp. 240-261). Benemérita Universidad Autónoma de Puebla. <https://bit.ly/3xmD82M>
- Pérez-Suasnavas, A.-L., y Cela Rosero, K. (2022). Validación de un cuestionario de evaluación de actitud y autopercepción del pensamiento crítico de estudiantes universitarios. *Revista San Gregorio*, 50, 19-35.
- Pérez-Suasnavas, A.-L., Cevallos Martínez, G. F., y Cela, K. (2019, noviembre 9). Uso de Twitter como herramienta de participación estudiantil en la educación superior. *Dialécticas del Sur 3*. IV Congreso Internacional de Innovación en la Educación Superior, Ecuador. <https://bibliotecadigital.uce.edu.ec/s/P-D/item/1391#?c=0&m=0&s=0&cv=0>
- Pérez-Suasnavas, A.-L., Hasperué, W., Molina Bustamante, M. E., y Santamaría C., J. L. (2022). Predicción de dificultades estudiantiles mediante técnicas de minería de textos. *South Florida Journal of Development*, 3(5), 6128-6137. <https://doi.org/10.46932/sfjdv3n5-061>
- Pérez-Suasnavas, A.-L., Salgado Proaño, B. F., Hasperué, W., Cela, K. L., y Santamaría Carrera, J. L. (2023). Evolución de las técnicas de minería de datos para extraer datos provenientes de Twitter aplicadas a la educación superior: Una revisión sistemática.

*South Florida Journal of Development*, 4(1), 33-55. <https://doi.org/10.46932/sfjdv4n1-002>

- Pérez-Suasnavas, A.-L., Salgado-Proañó, B., Cela, K., y Santamaría, J. L. (2023). Computational Thinking as Instrument to Evaluate Student Difficulties in Higher Education: Before and During Pandemic Analysis. En M. Botto-Tobar, O. S. Gómez, R. Rosero Miranda, A. Díaz Cadena, y W. Luna-Encalada (Eds.), *Trends in Artificial Intelligence and Computer Engineering: Proceedings of ICAETT 2022* (Vol. 619, pp. 193-207). Springer, Cham. [https://doi.org/10.1007/978-3-031-25942-5\\_16](https://doi.org/10.1007/978-3-031-25942-5_16)
- Portegal-Vega, M. Á., Oliva-Delgado, A., y Rodríguez-Meirinhos, A. (2019). Revisión sistemática del panorama de la investigación sobre redes sociales: Taxonomía sobre experiencias de uso. *Comunicar: Revista científica iberoamericana de comunicación y educación*, 60, 81-91. <https://doi.org/10.3916/C60-2019-08>
- Pill, S., Harvey, S., y Hyndman, B. (2017). Novel research approaches to gauge global teacher familiarity with game-based teaching in physical education: An exploratory #Twitter analysis. *Asia-Pacific Journal of Health, Sport and Physical Education*, 8(2), 161-178. <https://doi.org/10.1080/18377122.2017.1315953>
- Pimienta Prieto, J. (2012). *Estrategias de enseñanza-aprendizaje. Docencia universitaria basada en competencias* (M. Vega, Ed.; Primera). Pearson. <https://bit.ly/2xBDhoj>
- Prem Chander, K., Sharma, S., Nagaprasad, S., Anjaneyulu, M., y Ajantha Devi, V. (2020). Analysis of Efficient Classification Algorithms in Web Mining. En *Data Engineering and Communication Technology* (pp. 319-332). Springer.
- Presutti, F. (2002). *Metodologías Educativas* (Vol. 2). ISPEF.
- Python. (2022, noviembre 27). *Python About*. <https://www.python.org/about/>
- Quiroz-Vallejo, D. A., Carmona-Mesa, J. A., Castrillón-Yepes, A., y Villa-Ochoa, J. A. (2021). Integración del Pensamiento Computacional en la educación primaria y secundaria en Latinoamérica: Una revisión sistemática de literatura. *Revista de Educación a Distancia (RED)*, 21(68). <http://dx.doi.org/10.6018/red.485321>
- Ramírez, M. S. (2016). Paradigma, modelo, método, técnica y estrategia. En *Modelos de enseñanza y método de casos*. <https://bit.ly/40mkUMU>
- Ribeiro, L., Nunes, D. J., da Cruz, M. K., y de Souza Matos, E. (2013). Computational thinking: Possibilities and challenges. *2013 2nd Workshop-School on Theoretical Computer Science*, 22-25. <https://doi.org/10.1109/WEIT.2013.32>
- Rinaldo, S. B., Tapp, S., y Laverie, D. A. (2011). Learning by tweeting: Using Twitter as a pedagogical tool. *Journal of Marketing Education*, 33(2), 193-203. <https://doi.org/10.1177/0273475311410852>
- Rocha Hernández, J. A., Rodríguez Herrera, D. M., y Rodríguez Rodríguez, J. E. (2016). A research comparative among association rules algorithms. *Visión electrónica*, 10(2), 7. <https://doi.org/10.14483/22484728.11654>
- Rodríguez Gallego, M. R., López Martínez, A., y Martín Herrera, I. (2017). Percepciones de los estudiantes de Ciencias de la Educación sobre las redes sociales como metodología

didáctica. *Pixel-Bit. Revista de Medios y Educación*, 50, 77-93.  
<http://dx.doi.org/10.12795/pixelbit.2016.i50.05>

- Rogers, E. M. (1983). *Diffusion of innovations* (Third Edition). The Free Press.
- Roiger, R. J. (2017). *Data mining: A tutorial-based primer*. Chapman and Hall/CRC.  
<https://www.taylorfrancis.com/>
- Roig-Vila, R., y Álvarez Herrero, J. F. (2019). Repercusión en Twitter de las metodologías activas ABP, Flipped Classroom y Gamificación. *RIED. Revista Iberoamericana de Educación a Distancia*, 2(22), 79-96. <http://dx.doi.org/10.5944/ried.22.2.23272>
- Rojas-López, A., y García-Peñalvo, F. J. (2020). Evaluación del pensamiento computacional para el aprendizaje de programación de computadoras en educación superior. *Revista de Educación a Distancia (RED)*, 20(63), 1-39. <http://dx.doi.org/10.6018/red.409991>
- Ruiz Bolívar, C. (2016). Redes Sociales y Educación Universitaria. *Paradigma*, 37(1), 232-256.
- Saini, C., y Abraham, J. (2019). Implementing Facebook-based instructional approach in pre-service teacher education: An empirical investigation. *Computers & Education*, 128, 243-255. <https://doi.org/10.1016/j.compedu.2018.09.025>
- Salas-Rueda, R.-A., Salas-Rueda, R.-D., y Salas-Silis, J.-A. (2019). Análisis de la percepción de los estudiantes sobre el uso de las tecnologías de la información y la comunicación en el proceso educativo por medio de la ciencia de datos. *Revista Electrónica Calidad en la Educación Superior*, 10(1), 96-124. <http://dx.doi.org/10.22458/caes.v10i1.2463>
- Salgado Castillo, A., Alonso Berenguer, I., Gorina Sánchez, G., y Tardo Fernández, Y. (2013). Lógica algorítmica para la resolución de problemas de programación computacional: Una propuesta didáctica. *Didasc@lia: Didáctica y Educación*, IV(1), 57-76.
- Salinas Ibáñez, J. M., y Marín Juarros, V. I. (2019). Metasíntesis cualitativa sobre colaboración científica e identidad digital académica en redes sociales. *RIED. Revista Iberoamericana De Educación a Distancia*, 22(2), 97-117. <http://dx.doi.org/10.5944/ried.22.2.23238>
- Salinas Lozano, I. (2021). *Uso de las redes sociales en la educación: Una Revisión Sistemática de Bibliografía*. [Universidad de Zaragoza].  
<https://zaguan.unizar.es/record/108139/files/TAZ-TFG-2021-2613.pdf>
- Salvador Mata, F., y Gallego Ortega, J. L. (2009). Metodología de la acción didáctica. En Medina Rivilla y F. Salvador Mata (Eds.), *Colección Didáctica* (2.ª ed., pp. 168-196). Prentice Hall.
- Sambhaji, R. D. (2021). Social Media Content Analysis and Classification Using Data Mining and ML. *International Journal of Data Analytics (IJDA)*, 2(2), 75-84.  
<https://doi.org/10.4018/IJDA.2021070105>
- Sancar, I. V., Duvenci, A., y Odabasi, H. F. (2021). Educational potential of Facebook use in higher education: Last decade research trend. *The Journal of Social Media in Society*, 10(2), 264-288.
- Sanchez, J. M. P., Alejandro, B. A., Jugasan Olvido, M. M., y Veloso Alejandro, I. M. (2021). An analysis of online classes tweets using Gephi: Inputs for online learning. *International*

*Journal of Information and Education Technology*, 11(12).  
<https://doi.org/10.18178/ijiet.2021.11.12.1568>

- Sánchez Rodríguez, J., Ruiz Palmero, J., y Sánchez Rivas, E. (2015). Uso problemático de las redes sociales en estudiantes universitarios. *Revista complutense de educación*, 26. [http://dx.doi.org/10.5209/rev\\_RCED.2015.v26.46360](http://dx.doi.org/10.5209/rev_RCED.2015.v26.46360)
- Santabárbara, J. (2019). Cálculo del intervalo de confianza para los coeficientes de correlación mediante sintaxis en SPSS. *REIRE Revista d'Innovació i Recerca en Educació*, 12(2), 1-14. <https://doi.org/10.1344/reire2019.12.228245>
- Santos, J. F. (2016). Prácticas pedagógicas: Concepciones, roles y métodos en la formación del psicólogo bolivariano1. En *Prácticas pedagógicas* (p. 195). Astro Data. <https://www.researchgate.net>
- Santoveña-Casal, S., y Bernal-Bravo, C. (2019). Explorando la influencia del docente: Participación social en Twitter y percepción académica. *Revista Comunicar*, XXVII(58), 75-84. <https://doi.org/10.3916/C58-2019-07>
- Saura, J. R., Reyes-Menendez, A., y Bennett, D. R. (2019). How to extract meaningful insights from UGC: a knowledge-based method applied to education. *Applied Sciences*, 9(21), 4603. <https://doi.org/10.3390/app9214603>
- Shabgahi, S. L., Ahmad Kharman Shah, N., y Cox, A. M. (2013). A Comparative Review of Research Literature on Microblogging Use and Risk in Organizational and Educational Settings. En A. A. Ozok y P. Zaphiris (Eds.), *Online Communities and Social Computing* (pp. 174-181). Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-642-39371-6\\_20](https://doi.org/10.1007/978-3-642-39371-6_20)
- Simkins, S., y Maier, M. (2004). Using just-in-time teaching techniques in the principles of economics course. *Social Science Computer Review*, 22(4), 444-456. <https://doi.org/10.1177/0894439304268643>
- Simkins, S., y Maier, M. (2010). *Just-in-time teaching: Across the disciplines, across the academy* (F. Glazer, Ed.; 1.ª ed.). Stylus Publishing, LLC. <http://bit.ly/3chaK7F>
- Sotaquirá, M. (2022, septiembre 9). *La Matriz de Confusión*. codificandobits. <https://www.codificandobits.com/blog/matriz-de-confusion/>
- Tan, P.-N., Steinbach, M., y Kumar, V. (2014). *Introduction to Data Mining*. Pearson.
- Tang, Y., y Hew, K. F. (2017). Using Twitter for education: Beneficial or simply a waste of time? *Computers & Education*, 106, 97-118. <https://doi.org/10.1016/j.compedu.2016.12.004>
- Tejedor, S., Coromina, Ó., y Pla-Campas, G. (2021). Microblogging en escenarios curriculares universitarios: El uso de Twitter más allá del encargo docente. *Revista Electrónica de Investigación Educativa*, 23, 1-13. <https://doi.org/10.24320/redie.2021.23.e20.3565>
- Tejera Concepción, J. F., y Cardoso Sarduy, M. A. (2015). Tratamiento de las habilidades comunicativas en el contexto universitario. *Revista Universidad y Sociedad*, 7(2), 168-172.
- TensorFlow. (2022). *TensorFlow basics*. Essential documentation. <https://bit.ly/3lV3qV7>

- Tiwari, D., y Kumar, M. (2020). Social media data mining techniques: A survey. En M. Tuba (Ed.), *Information and Communication Technology for Sustainable Development* (pp. 183-194). Springer. [https://doi.org/10.1007/978-981-13-7166-0\\_18](https://doi.org/10.1007/978-981-13-7166-0_18)
- Toro Araneda, G. (2010). Usos de Twitter en la educación superior. *Serie Bibliotecología y Gestión de Información*. <https://dialnet.unirioja.es/servlet/articulo?codigo=3129744>
- Torres, J. (2019). *Deep Learning, Introducción práctica con Keras (SEGUNDA PARTE)* (Primera).
- Touriñán López, J. M., y Sáez Alonso, R. (2006). La metodología de investigación y la construcción del conocimiento de la educación. *Eduga: revista galega do ensino*, 48, 375-410.
- Tur, G., Marín-Juarros, V., y Carpenter, J. (2017). Uso de Twitter en Educación Superior en España y Estados Unidos. *Revista Comunicar*, 25(51), 19-28. <https://doi.org/10.3916/C51-2017-02>
- TWITTER. (2019). *Twitter Centro de Ayuda*. Información sobre las API de Twitter. <http://bit.ly/2LvPzUc>
- TWITTER. (2022a). *Developer Platform*. <https://bit.ly/3gRwr5f>
- TWITTER. (2022b). *Developer Platform*. Getting Started with Converting JSON Objects to CSV. <https://developer.twitter.com/en/docs/tutorials/five-ways-to-convert-a-json-object-to-csv>
- TWITTER. (2022c). *Twitter Developer Twitter*. Authentication. <https://developer.twitter.com/en/docs/authentication/overview>
- TWITTER. (2022d). *Twitter Developer Twitter*. Standard v1.1. <https://developer.twitter.com/en/docs/twitter-api/v1>
- TWITTER. (2022e). *Twitter Sobre nosotros*. <https://about.twitter.com/es>
- UNESCO. (2005). *Red Innovemos: Red de Innovaciones Educativas para América Latina y el Caribe: Regional—(Mission); informe final* (p. 27) [Informes y Misiones]. <https://unesdoc.unesco.org/ark:/48223/pf0000143118>
- Universidad Europea. (2021). *Tipos de metodologías educativas: Cómo elegir la mejor* [Educativo]. Universidad Europea Online. <https://innovacion-educativa.universidadeuropea.com/noticias/tipos-metodologias-educativas/>
- Valls, F., Redondo, E., Fonseca, D., Torres-Kompen, R., Villagrasa, S., y Martí, N. (2018). Urban data and urban design: A data mining approach to architecture education. *Telematics and Informatics*, 35(4), 1039-1052. <https://doi.org/10.1016/j.tele.2017.09.015>
- Valverde Kikut, L. (2020). Análisis de resultados de la evaluación de la virtualización de cursos en la UCR ante la pandemia por COVID-19: Perspectiva estudiantil. *Centro de Evaluación Académica (CEA)*. <http://bit.ly/3XQJ1lg>
- Vargas, R., Mosavi, A., y Ruiz, R. (2017). Deep learning: A review. *Advances in Intelligent Systems and Computing*. <https://bit.ly/3wUailF>
- Vargas-Murillo, G. (2020). Estrategias educativas y tecnología digital en el proceso enseñanza aprendizaje. *Cuadernos Hospital de Clínicas*, 61(1), 114-129.

- Velásquez, J. D. (2015). Una guía corta para escribir revisiones sistemáticas de literatura parte 3. *Dyna*, 82(189), 9-12. <http://dx.doi.org/10.15446/dyna.v82n189.48931>
- Veletsianos, G. (2011). Higher education scholars' participation and practices on Twitter. *Journal of Computer Assisted Learning*, 28(4), 336-349. <https://doi.org/10.1111/j.1365-2729.2011.00449.x>
- Veletsianos, G., y Kimmons, R. (2016). Scholars in an increasingly open and digital world: How do education professors and students use Twitter? *The Internet and Higher Education*, 30, 1-10. <https://doi.org/10.1016/j.iheduc.2016.02.002>
- Vera, A. C., y Vera, L. J. (2011). Estrategias utilizadas por los docentes para promover el aprendizaje de la biología a nivel universitario. *Telos: Revista de Estudios Interdisciplinarios en Ciencias Sociales*, 13(3), 397-411.
- Vilanova, G. E. (2018). Tecnología Educativa para el Desarrollo del Pensamiento Computacional. *Sistemas, Cibernética e informática*, 15(3), 25-32.
- Villasís-Keever, M. Á., y Miranda-Navales, M. G. (2016). El protocolo de investigación IV: las variables de estudio. *Revista Alergia México*, 63(3), 303-310. <http://dx.doi.org/10.29262/ram.v63i3.199>
- Vora, D. R., y Iyer, K. R. (2020). Deep Learning in Engineering Education: Performance Prediction Using Cuckoo-Based Hybrid Classification. En *Machine Learning and Deep Learning in Real-Time Applications* (pp. 187-218). IGI Global.
- Wakefield, J. S., Warren, S. J., y Alsobrook, M. (2011). Learning and teaching as communicative actions: A mixed-methods Twitter study. *Knowledge Management & E-Learning: An International Journal (KM&EL)*, 3(4), 563-584. <https://doi.org/10.34105/j.kmel.2011.03.038>
- Welch, B. K., y Bonnan-White, J. (2012). Twittering to increase student engagement in the university classroom. *Knowledge Management & E-Learning: An International Journal*, 4(3), 325-345. <https://doi.org/10.34105/j.kmel.2012.04.026>
- Wright, N. (2010). Twittering in teacher education: Reflecting on practicum experiences. *Open Learning: The Journal of Open, Distance and e-Learning*, 25(3), 259-265. <https://doi.org/10.1080/02680513.2010.512102>
- Yadranjiaghdam, B., Yasrobi, S., y Tabrizi, N. (2017). Developing a Real-Time Data Analytics Framework for Twitter Streaming Data. *2017 IEEE International Congress on Big Data (BigData Congress)*, 329-336. <https://doi.org/10.1109/BigDataCongress.2017.49>
- Yu, X., y Wu, S. (2015). Typical Applications of Big Data in Education. *2015 International Conference of Educational Innovation through Technology (EITT)*, 103-106. <https://doi.org/10.1109/EITT.2015.29>
- Zaina, L. A. M., Ameida, T. A., y Torres, G. M. (2014). Can the Online Social Networks Be Used as a Learning Tool? A Case Study in Twitter. En L. Uden, J. Sinclair, Y.-H. Tao, y D. Liberona (Eds.), *Learning Technology for Education in Cloud. MOOC and Big Data* (pp. 114-123). Springer International Publishing. <https://doi.org/10.1007/978-3-319-10671-7>

- Zaki, M. J., y Meira, W. (2014). *Data mining and analysis: Fundamental concepts and algorithms*. Cambridge University Press. <http://bit.ly/2Rei6iC>
- Zapata-Ros, M. (2015). Pensamiento computacional: Una nueva alfabetización digital. *Revista de Educación a Distancia (RED)*, 0(46). <https://bit.ly/3oNmJ4I>
- Zeballos, M. (2020). Acompañamiento pedagógico digital para docentes. *Revista Tecnológica-Educativa Docentes 2.0*, 9(2), 192-203. <https://doi.org/10.37843/rted.v9i2.164>
- Zepke, N., y Leach, L. (2010). Improving student engagement: Ten proposals for action. *Active learning in higher education*, 11(3), 167-177. <https://doi.org/10.1177/1469787410379680>
- Zong, C., Xia, R., y Zhang, J. (2021). *Text Data Mining*. Tsinghua University Press. [https://doi.org/10.1007/978-981-16-0100-2\\_1](https://doi.org/10.1007/978-981-16-0100-2_1)
- Zuleta Medina, A., y Chaves Torres, A. (2011). Uso de herramientas informáticas como estrategia para la enseñanza de la programación de computadores. *Revista Unimar*, 29(1), 23-32. <https://doi.org/10.31948/Rev.unimar>



## Anexos

### Anexo A

#### Artículos considerados en la revisión

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
E1	2018	“Pedagogical tweeting” in higher education: boon or bane?	(Adams et al., 2018)	Artículo en revista: International Journal of Educational Technology in Higher Education	<a href="https://doi.org/10.1186/s41239-018-0102-5">https://doi.org/10.1186/s41239-018-0102-5</a>
E2	2019	Social learning analytics for determining learning styles in a smart classroom	(Aguilar et al., 2022)	Artículo en revista: INTERACTIVE LEARNING ENVIRONMENTS	<a href="https://doi.org/10.1080/10494820.2019.1651745">https://doi.org/10.1080/10494820.2019.1651745</a>
E3	2019	Towards a New Indicator for Evaluating Universities Based on Twitter Sentiment Analysis	(Al Bashaireh et al., 2019)	Artículo en conferencia: 2019 International Conference on Computational Science and Computational Intelligence (CSCI)	<a href="https://doi.org/10.1109/CSCI49370.2019.00261">https://doi.org/10.1109/CSCI49370.2019.00261</a>
E4	2020	Twitter Data Collection and Extraction: A Method and a New Dataset, the UTD-MI	(Al Bashaireh et al., 2020)	Artículo en conferencia: ICISDM 2020: Proceedings of the 2020 the 4th International Conference on Information System and Data Mining	<a href="https://doi.org/10.1145/3404663.3404686">https://doi.org/10.1145/3404663.3404686</a>
E5	2022	Improving Sentiment Analysis of Arabic Tweets by One-way ANOVA	(Alassaf y Qamar, 2020)	Artículo en revista: Journal of King Saud University	<a href="https://doi.org/10.1016/j.jksuci.2020.10.023">https://doi.org/10.1016/j.jksuci.2020.10.023</a>
E6	2021	Twitter Sentiment Analysis towards Online Learning during COVID-19 in the Philippines	(Alcober y Revano, 2021)	Artículo en conferencia: 2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNNICEM)	<a href="https://doi.org/10.1109/HNNICEM54116.2021.9731999">https://doi.org/10.1109/HNNICEM54116.2021.9731999</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
E7	2013	Research Trends and Issues in the Studies of Twitter: A Content Analysis of Publications in Selected Journals (2007 – 2012)	(Alias et al., 2013)	Artículo en conferencia: 13th International Educational Technology Conference	<a href="https://doi.org/10.1016/j.sbspro.2013.10.398">https://doi.org/10.1016/j.sbspro.2013.10.398</a>
E8	2018	A systematic review of cloud computing tools for collaborative learning: Opportunities and challenges to the blended-learning environment	(Al-Samarraie y Saeed, 2018)	Artículo en revista: Computers & Education	<a href="https://doi.org/10.1016/j.compedu.2018.05.016">https://doi.org/10.1016/j.compedu.2018.05.016</a>
E9	2015	Predicting learning-related emotions from students' textual classroom feedback via Twitter	(Altrabsheh et al., 2015)	Artículo en conferencia: Proceedings of the 8th International Conference on Educational Data Mining	<a href="https://research.brighton.ac.uk/">https://research.brighton.ac.uk/</a>
E10	2020	Opinion mining and emotion recognition applied to learning environments	(Barrón Estrada et al., 2020)	Artículo en revista: Expert Systems With Applications	<a href="https://doi.org/10.1016/j.eswa.2020.113265">https://doi.org/10.1016/j.eswa.2020.113265</a>
E11	2015	Teacherbot: interventions in automated teaching	(Bayne, 2015)	Artículo en revista: Teaching in Higher Education	<a href="https://doi.org/10.1080/13562517.2015.1020783">https://doi.org/10.1080/13562517.2015.1020783</a>
E12	2012	Twitter usage habits of undergraduate students	(Bicen y Cavus, 2012)	Artículo en conferencia: 4th WORLD CONFERENCE ON EDUCATIONAL SCIENCES (WCES-2012)	<a href="https://doi.org/10.1016/j.sbspro.2012.05.117">https://doi.org/10.1016/j.sbspro.2012.05.117</a>
E13	2014	Student Opinions Regarding Twitter Usage with Mobile Applications for Educational Purposes	(Bicen, 2014)	Artículo en conferencia: GLOBAL CONFERENCE on LINGUISTICS and FOREIGN LANGUAGE TEACHING (LINELT-2013)	<a href="https://doi.org/10.1016/j.sbspro.2014.05.345">https://doi.org/10.1016/j.sbspro.2014.05.345</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
E14	2009	Microblogging for Language Learning: Using Twitter to Train Communicative and Cultural Competence	(Borau et al., 2009)	Artículo en conferencia: Advances in Web Based Learning – ICWL 2009	<a href="https://doi.org/10.1007/978-3-642-03426-8_10">https://doi.org/10.1007/978-3-642-03426-8_10</a>
E15	2012	El debate y la síntesis de aportaciones colaborativas en la educación superior con el Twitter como protagonista	(Calabuig i Serra y Donaire Benito, 2012)	Artículo en conferencia: XXIII Simposio Internacional Didáctica de las Ciencias Sociales	<a href="https://idus.us.es/xmlui/discover">https://idus.us.es/xmlui/discover</a>
E16	2019	Análisis de sentimientos, una herramienta para valorar la actitud del estudiante frente a un curso	(Castillo Landínez y Caicedo Rodríguez, 2019)	Artículo en conferencia: 2° Congreso Latinoamericano de Ingeniería	<a href="https://doi.org/10.26507/ponencia.141">https://doi.org/10.26507/ponencia.141</a>
E17	2019	Big Data e inteligencia de negocios aplicados al estudio de mercado de estudios posgraduales de la Universidad Autónoma de Colombia	(Castillo y Moreno, 2019)	Artículo en revista: Revista Espacios	<a href="http://bit.ly/3XA15De">http://bit.ly/3XA15De</a>
E18	2011	Microblogging in a Classroom: Classifying Students' Relevant and Irrelevant Questions in a	(Cetintas et al., 2011)	Artículo en revista: IEEE Transactions on Learning Technologies,	<a href="https://doi.org/10.1109/TLT.2011.14">https://doi.org/10.1109/TLT.2011.14</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
		Microblogging-Supported Classroom			
E19	2017	Taking social media to a university classroom: teaching and learning using Twitter and blogs	(Chawinga, 2017)	Artículo en revista: International Journal of Educational Technology in Higher Education	<a href="https://doi.org/10.1186/s41239-017-0041-6">https://doi.org/10.1186/s41239-017-0041-6</a>
E20	2014	Mining Social Media Data for Understanding Students' Learning Experiences	(Chen et al., 2014)	Artículo en revista: IEEE Transactions on Learning Technologies	<a href="https://doi.org/10.1109/TLT.2013.2296520">https://doi.org/10.1109/TLT.2013.2296520</a>
E21	2013	Training of self-regulated learning skills on a social network system	(Cho y Cho, 2013)	Artículo en revista: Social Psychology of Education	<a href="https://doi.org/10.1007/s11218-013-9229-3">https://doi.org/10.1007/s11218-013-9229-3</a>
E22	2021	An Analysis of Tweet Relevance, Twitter Activity and Student Preferences for Universities	(Cingillioglu et al., 2021)	Artículo en conferencia: 2021 19th International Conference on Information Technology Based Higher Education and Training (ITHET)	<a href="https://doi.org/10.1109/ITHET50392.2021.9759728">https://doi.org/10.1109/ITHET50392.2021.9759728</a>
E23	2021	Analysis of Top-Ranked HEI Publications' Strategy on Twitter	(Coelho y Figueira, 2021)	Artículo en conferencia: 2021 IEEE International Conference on Big Data	<a href="https://doi.org/10.1109/BigData52589.2021.9671383">https://doi.org/10.1109/BigData52589.2021.9671383</a>
E24	2019	Uncovering cyberincivility among nurses and nursing students on twitter: A data mining study	(De Gagne et al., 2019)	Artículo en revista: Procedia Computer Science	<a href="https://doi.org/10.1016/j.ijnurstu.2018.09.009">https://doi.org/10.1016/j.ijnurstu.2018.09.009</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
E25	2016	Time Aware Knowledge Extraction for microblog summarization on Twitter	(De Maio et al., 2016)	Artículo en revista: Information Fusion	<a href="https://doi.org/10.1016/j.inffus.2015.06.004">https://doi.org/10.1016/j.inffus.2015.06.004</a>
E26	2018	Descriptive, Dynamic and Hybrid Classification Algorithm to Classify Engineering Students' Sentiments	(Desai y Mehta, 2018)	Artículo en conferencia: Smart and Innovative Trends in Next Generation Computing Technologies	<a href="https://doi.org/10.1007/978-981-10-8657-1_10">https://doi.org/10.1007/978-981-10-8657-1_10</a>
E27	2017	A CWTM Model of Topic Extraction for Short Text	(Diao et al., 2017)	Artículo en conferencia: Knowledge Graph and Semantic Computing. Language, Knowledge, and Intelligence	<a href="https://doi.org/10.1007/978-981-10-7359-5">https://doi.org/10.1007/978-981-10-7359-5</a>
E28	2020	The Ivory Tower Lost: How College Students Respond Differently than the General Public to the COVID-19 Pandemic	(Duong et al., 2020)	Artículo en conferencia: International Conference on Advances in Social Networks Analysis and Mining (ASONAM)	<a href="https://doi.org/10.1109/ASONAM49781.2020.9381379">https://doi.org/10.1109/ASONAM49781.2020.9381379</a>
E29	2010	Microblogs in Higher Education – A chance to facilitate informal and process-oriented learning?	(Ebner et al., 2010)	Artículo en revista: Computers & Education	<a href="https://doi.org/10.1016/j.compedu.2009.12.006">https://doi.org/10.1016/j.compedu.2009.12.006</a>
E30	2019	Ina-BWR: Indonesian bigram word rule for multi-label student complaints	(Fahrudin et al., 2019)	Artículo en revista: Egyptian Informatics Journal	<a href="https://doi.org/10.1016/j.eij.2019.03.001">https://doi.org/10.1016/j.eij.2019.03.001</a>
E31	2022	Does technology assist to continue learning during pandemic? A sentiment analysis	(Fathima Shafana y Safnas, 2022)	Artículo en revista: Social Network Analysis and Mining	<a href="https://doi.org/10.1007/s13278-022-00899-4">https://doi.org/10.1007/s13278-022-00899-4</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
		and topic modeling on online learning in south asian region			
E32	2016	The influence of the internet for pedagogical innovation: using twitter to promote online collaborative learning	(Fernández-Ferrer y Cano, 2016)	Artículo en revista: International Journal of Educational Technology in Higher Education	<a href="https://doi.org/10.1186/s41239-016-0021-2">https://doi.org/10.1186/s41239-016-0021-2</a>
E33	2020	Opinion Mining about Online Education Basing on GDELT and Twitter Data	(Fu et al., 2020)	Artículo en conferencia: 2020 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology (WI-IAT)	<a href="https://doi.org/10.1109/WIIAT50758.2020.00114">https://doi.org/10.1109/WIIAT50758.2020.00114</a>
E34	2012	Tweeting for learning: A critical analysis of research on microblogging in education published in 2008–2011	(Gao et al., 2012)	Artículo en revista: British Journal of Educational Technology	<a href="https://doi.org/10.1111/j.1467-8535.2012.01357.x">https://doi.org/10.1111/j.1467-8535.2012.01357.x</a>
E35	2015	Twitter as a resource to evaluate the university teaching process	(García Suárez et al., 2015)	Artículo en revista: Revista de Universidad y Sociedad del Conocimiento	<a href="https://doi.org/10.7238/rusc.v12i3.2092">https://doi.org/10.7238/rusc.v12i3.2092</a>
E36	2019	Institutional Twitter Usage among U.S. Geography Departments	(Gong y D. Lane, 2020)	Artículo en revista: The Professional Geographer	<a href="https://doi.org/10.1080/00330124.2019.1653770">https://doi.org/10.1080/00330124.2019.1653770</a>
E37	2010	Microblogging with University Students 24/7: Twitter Comes of Age	(Graves y Ziaeehezarjeribi, 2010)	Artículo en conferencia: Microblogging with university students 24/7: Twitter comes of age	<a href="https://www.aect.org/index.php">https://www.aect.org/index.php</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
E38	2019	Analyzing Student's Learning Experiences by using Social Media data Through Data Mining	(Greeshma y Veigas, 2020)	Artículo en revista: International Journal of Scientific Research in Computer Science Applications and Management Studies	<a href="http://bit.ly/3iisHtK">http://bit.ly/3iisHtK</a>
E39	2012	Usos de Twitter en las universidades iberoamericanas	(Guzmán Duque et al., 2012)	Artículo en revista: RELATEC	<a href="https://mascvuex.unex.es/revistas/index.php/relatec/article/view/845">https://mascvuex.unex.es/revistas/index.php/relatec/article/view/845</a>
E40	2013	Twitter's contribution to improving strategic communication in Latin American universities	(Guzmán Duque y Del Moral Pérez, 2013)	Artículo en revista: International Journal of Educational Technology in Higher Education	<a href="https://doi.org/10.7238/rusc.v10i2.1744">https://doi.org/10.7238/rusc.v10i2.1744</a>
E41	2013	Influence of Twitter Activity on College Classes	(Ha et al., 2013)	Artículo en conferencia: Computational Collective Intelligence. Technologies and Applications	<a href="https://doi.org/10.1007/978-3-642-40495-5">https://doi.org/10.1007/978-3-642-40495-5</a>
E42	2012	Discerning Actuality in Backstage	(Hadersberger et al., 2012)	Artículo en conferencia: 21st Century Learning for 21st Century Skills	<a href="https://doi.org/10.1007/978-3-642-33263-0">https://doi.org/10.1007/978-3-642-33263-0</a>
E43	2012	Tweets Reveal More Than You Know: A Learning Style Analysis on Twitter	(Hauff et al., 2012)	Artículo en conferencia: 21st Century Learning for 21st Century Skills	<a href="https://doi.org/10.1007/978-3-642-33263-0_12">https://doi.org/10.1007/978-3-642-33263-0_12</a>
E44	2011	Deriving Knowledge Profiles from Twitter	(Hauff y Houben, 2011)	Artículo en conferencia: Towards Ubiquitous Learning	<a href="https://doi.org/10.1007/978-3-642-23985-4_12">https://doi.org/10.1007/978-3-642-23985-4_12</a>
E45	2016	Using Social Media to Promote STEM Education: Matching College Students with Role Models	(He et al., 2016)	Artículo en revista: Machine Learning and Knowledge Discovery in Databases	<a href="https://doi.org/10.1007/978-3-319-46131-1">https://doi.org/10.1007/978-3-319-46131-1</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
E46	2014	Educational digital stories in 140 characters: towards a typology of micro-blog storytelling in academic courses	(Holotescu et al., 2014)	Artículo en conferencia: Procedia-Social and Behavioral Sciences	<a href="https://doi.org/10.1016/j.sbspro.2014.01.936">https://doi.org/10.1016/j.sbspro.2014.01.936</a>
E47	2022	Analysis of Jordanian University Students Problems Using Data Mining System	(Issa et al., 2022)	Artículo en conferencia: 2022 13th International Conference on Information and Communication Systems (ICICS)	<a href="https://doi.org/10.1109/ICICS55353.2022.9811199">https://doi.org/10.1109/ICICS55353.2022.9811199</a>
E48	2019	Sentiment mining in a collaborative learning environment: capitalising on big data	(Jena, 2019)	Artículo en revista: Behavior & Information Technology	<a href="https://doi.org/10.1080/0144929X.2019.1625440">https://doi.org/10.1080/0144929X.2019.1625440</a>
E49	2021	A Model for Good Learning Environment Using Learning Data Analytics	(Joshi y Sharma, 2021)	Artículo en revista: Procedia Computer Science	<a href="https://doi.org/10.1016/j.procs.2021.10.069">https://doi.org/10.1016/j.procs.2021.10.069</a>
E50	2011	The effect of Twitter on college student engagement and grades	(Junco et al., 2011)	Artículo en revista: Journal of computer assisted learning	<a href="https://doi.org/10.1111/j.1365-2729.2010.00387.x">https://doi.org/10.1111/j.1365-2729.2010.00387.x</a>
E51	2012	Twitter as a teaching practice to enhance active and informal learning in higher education: The case of sustainable tweets	(Kassens-Noor, 2012)	Artículo en revista: Active Learning in Higher Education	<a href="https://doi.org/10.1177/1469787411429190">https://doi.org/10.1177/1469787411429190</a>
E52	2020	Social big data: A Twitter text mining approach to the communication of	(Katia et al., 2020)	Artículo en conferencia: 2020 International Conference on Cyber Security and Protection of Digital Services (Cyber Security)	<a href="https://doi.org/10.1109/CyberSecurity49315.2020.9138876">https://doi.org/10.1109/CyberSecurity49315.2020.9138876</a>



ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
		universities during the Lebanese protests			
E53	2017	Institutional Uses of Twitter in U.S. Higher Education	(Kimmons et al., 2017)	Artículo en revista: Innovative Higher Education	<a href="https://doi.org/10.1007/s10755-016-9375-6">https://doi.org/10.1007/s10755-016-9375-6</a>
E54	2016	Education scholars' evolving uses of twitter as a conference backchannel and social commentary platform	(Kimmons y Veletsianos, 2016)	Artículo en revista: British Journal of Educational Technology	<a href="https://doi.org/10.1111/bjet.12428">https://doi.org/10.1111/bjet.12428</a>
E55	2013	An overview of Web Mining in Education	(Kleftodimos y Evangelidis, 2013)	Artículo en conferencia: Proceedings of the 17th Panhellenic Conference on Informatics	<a href="https://doi.org/10.1145/2491845.2491863">https://doi.org/10.1145/2491845.2491863</a>
E56	2015	Higher Education Institutions' Attractiveness: Early Warning Based on Social Media Indicator	(Kuznetsov et al., 2015)	Artículo en conferencia: Proceedings of the 2015 International Conference on Big Data Applications and Services,	<a href="https://doi.org/10.1145/2837060.2837099">https://doi.org/10.1145/2837060.2837099</a>
E57	2014	A systematic review investigating the use of Twitter and Facebook in university-based healthcare education	(Lambert y Smith, 2014)	Artículo en revista: Health Education	<a href="https://doi.org/10.1108/HE-07-2013-0030">https://doi.org/10.1108/HE-07-2013-0030</a>
E58	2019	Social network analysis of twitter use during the AERA 2017 annual conference	(Lemay et al., 2019)	Artículo en revista: Education and Information Technologies	<a href="https://doi.org/10.1007/s10639-018-9787-2">https://doi.org/10.1007/s10639-018-9787-2</a>
E59	2013	Exploring the Relationships between Students' Learning	(Leon y Popescu, 2013)	Artículo en conferencia: 2013 17th International Conference on System Theory, Control and Computing (ICSTCC)	<a href="https://doi.org/10.1109/ICSTCC.2013.6689035">https://doi.org/10.1109/ICSTCC.2013.6689035</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
		Styles and Social Media Use in Educational Settings			
E60	2017	#Problemas Para Pensar: Inspirar, motivar y sugerir aprendizajes. Una experiencia de inclusión de redes sociales en la enseñanza universitaria	(Lescano y Quiroga, 2017)	Artículo en conferencia: IV Jornadas de TIC e Innovación en el Aula	<a href="http://sedici.unlp.edu.ar/handle/10915/65766">http://sedici.unlp.edu.ar/handle/10915/65766</a>
E61	2011	Is Twitter for the Birds?: Using Twitter to Enhance Student Learning in a Marketing Course	(Lowe y Laffey, 2011)	Artículo en revista: Journal of Marketing Education	<a href="https://doi.org/10.1177/0273475311410851">https://doi.org/10.1177/0273475311410851</a>
E62	2016	Enabling microblogging-based peer feedback in face-to-face classrooms	(Luo, 2016)	Artículo en revista: Innovations in Education and Teaching International	<a href="https://doi.org/10.1080/14703297.2014.995202">https://doi.org/10.1080/14703297.2014.995202</a>
E63	2021	Impact Of Covid-19 On Education Using Twitter Data	(Makode et al., 2021)	Artículo en conferencia: 2021 16th International Workshop on Semantic and Social Media Adaptation & Personalization (SMAP)	<a href="https://doi.org/10.1109/SMAP53521.2021.9610821">https://doi.org/10.1109/SMAP53521.2021.9610821</a>
E64	2017	The use of technology in postgraduate supervision pedagogy in two Australian universities	(Maor y Currie, 2017)	Artículo en revista: International Journal of Educational Technology in Higher Education	DOI 10.1186/s41239-017-0046-1
E65	2014	Teaching Twitter: Re-enacting the Paris Commune and the Battle of Stalingrad	(McKenzie, 2014)	Artículo en revista: The History Teacher	<a href="https://www.jstor.org/stable/43264324">https://www.jstor.org/stable/43264324</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
E66	2015	Incorporating microblogging (“tweeting”) in higher education: Lessons learnt in a knowledge management course	(Menkhoff et al., 2015)	Artículo en revista: Computing for Human Learning, Behavior and Collaboration in the Social and Mobile Networks Era	<a href="https://doi.org/10.1016/j.chb.2014.11.063">https://doi.org/10.1016/j.chb.2014.11.063</a>
E67	2015	Metodología para el uso del Twitter como plataforma para la metacognición y otras competencias	(Moguel Marín et al., 2012)	Artículo en revista: Revista Iberoamericana para la Investigación y el Desarrollo Educativo	<a href="http://11.ride.org.mx/index.php/RIDESECUNDARIO/issue/view/1">http://11.ride.org.mx/index.php/RIDESECUNDARIO/issue/view/1</a>
E68	2022	A content based e-learning using classification algorithms	(Mohanasundari et al., 2022)	Artículo en revista: International Research Journal of Modernization in Engineering Technology and Science	<a href="http://bit.ly/3XMDofS">http://bit.ly/3XMDofS</a>
E69	2015	Microblogging And Blended Learning: Peer Response in Tertiary Education	(Montero-Fleta et al., 2015)	Artículo en conferencia: The Proceedings of 6th World Conference on educational Sciences	<a href="https://doi.org/10.1016/j.sbspro.2015.04.384">https://doi.org/10.1016/j.sbspro.2015.04.384</a>
E70	2020	Gratuidad en la educación superior chilena: análisis de prensa basado en Minería de Datos	(Nesbet Montecinos y Cárcamo Ulloa, 2020)	Artículo en revista: Revista Latinoamericana de Estudios Educativos (México)	<a href="https://doi.org/10.48102/rlee.2020.50.2.69">https://doi.org/10.48102/rlee.2020.50.2.69</a>
E71	2021	Uso de Minería de Textos para comparar los contenidos relacionados a calidad y acreditación generados en redes sociales por universidades de Perú y Chile	(Núñez et al., 2021)	Artículo en revista: Formación Universitaria	<a href="http://dx.doi.org/10.4067/S0718-50062021000100111">http://dx.doi.org/10.4067/S0718-50062021000100111</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
E72	2015	Answering questions concisely: analysis of a Twitter activity in a management course	(Olive et al., 2015)	Artículo en conferencia: 4th WORLD CONFERENCE on EDUCATIONAL TECHNOLOGY RESEARCHES (WCETR-2014)	<a href="https://doi.org/10.1016/j.sbspro.2015.04.754">https://doi.org/10.1016/j.sbspro.2015.04.754</a>
E73	2018	Mining Social Media Data for Understanding Students' Learning Experiences using Memetic algorithm	(Patil y Kulkarni, 2018)	Artículo en conferencia: International Conference on Processing of Materials, Minerals and Energy	<a href="https://doi.org/10.1016/j.matpr.2017.11.135">https://doi.org/10.1016/j.matpr.2017.11.135</a>
E74	2020	Beneficios del uso de técnicas de Minería de Datos para extraer y analizar datos de Twitter aplicados en la educación superior: una revisión sistemática de la literatura	(Pérez-Suasnavas et al., 2020)	Artículo en revista: Teoría de la Educación. Revista Interuniversitaria	<a href="http://dx.doi.org/10.14201/teri.22171">http://dx.doi.org/10.14201/teri.22171</a>
E75	2017	Novel research approaches to gauge global teacher familiarity with game-based teaching in physical education: an exploratory #Twitter analysis	(Pill et al., 2017)	Artículo en revista: Asia-Pacific Journal of Health, Sport and Physical Education	<a href="https://doi.org/10.1080/18377122.2017.1315953">https://doi.org/10.1080/18377122.2017.1315953</a>
E76	2011	Learning by Tweeting: Using Twitter as a Pedagogical Tool	(Rinaldo et al., 2011)	Artículo en revista: Journal of Marketing Education	<a href="https://doi.org/10.1177/0273475311410852">https://doi.org/10.1177/0273475311410852</a>
E77	2019	Análisis de la percepción de los estudiantes sobre el uso de las tecnologías de la información y la comunicación en el proceso	(Salas-Rueda et al., 2019)	Artículo en revista: REVISTA ELECTRÓNICA CALIDAD EN LA EDUCACIÓN SUPERIOR	<a href="http://dx.doi.org/10.22458/caes.v10i1.2463">http://dx.doi.org/10.22458/caes.v10i1.2463</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
		educativo por medio de la ciencia de datos			
E78	2021	Social Media Content Analysis and Classification Using Data Mining and ML	(Sambhaji, 2021)	Artículo en revista: International Journal of Data Analytics	10.4018/IJDA.2021070105
E79	2021	An Analysis of Online Classes Tweets Using Gephi: Inputs for Online Learning	(Sanchez et al., 2021)	Artículo en revista: International Journal of Information and Education Technology	<a href="http://dx.doi.org/10.18178/ijiet.2021.11.12.1568">http://dx.doi.org/10.18178/ijiet.2021.11.12.1568</a>
E80	2019	How to Extract Meaningful Insights from UGC: A Knowledge-Based Method Applied to Education	(Saura et al., 2019)	Artículo en revista: MDPI	<a href="https://doi.org/10.3390/app9214603">https://doi.org/10.3390/app9214603</a>
E81	2020	Social networking mood recognition algorithm for conflict detection and management of Indian educational institutions	(Sengupta y Vaish, 2020)	Artículo en revista: Social Network Analysis and Mining	<a href="https://doi.org/10.1007/s13278-020-00701-3">https://doi.org/10.1007/s13278-020-00701-3</a>
E82	2013	A Comparative Review of Research Literature on Microblogging Use and Risk in Organizational and Educational Settings	(Shabgahi et al., 2013)	Artículo en conferencia: Online Communities and Social Computing	<a href="https://doi.org/10.1007/978-3-642-39371-6_20">https://doi.org/10.1007/978-3-642-39371-6_20</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
E83	2017	Mining of Social Media data of university students	(Singh, 2017)	Artículo en revista: Journal of Data Mining & Digital Humanities,	<a href="https://doi.org/10.1007/s10639-016-9501-1">https://doi.org/10.1007/s10639-016-9501-1</a>
E84	2010	Let's Go Formative: Continuous Student Ratings with Web 2.0 Application Twitter	(Stieger y Burger, 2010)	Artículo en revista: Cyberpsychology, Behavior, and Social Networking	<a href="https://doi.org/10.1089/cyber.2009.0128">https://doi.org/10.1089/cyber.2009.0128</a>
E85	2016	Utilizing Relevant Academic and Personality Features from Big Unstructured Data to Identify Good and Bad Fit Students	(Uddin y Lee, 2016)	Artículo en conferencia: Complex Adaptive Systems Los Angeles	<a href="https://doi.org/10.1016/j.procs.2016.09.349">https://doi.org/10.1016/j.procs.2016.09.349</a>
E86	2016	A Framework to Identify Educational Relevance in Social Networking Posts	(Uddin, 2016)	Artículo en conferencia: 2016 IEEE 7th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)	<a href="https://doi.org/10.1109/UEMCON.2016.7777873">https://doi.org/10.1109/UEMCON.2016.7777873</a>
E87	2018	Urban data and urban design: A data mining approach to architecture education	(Valls et al., 2018)	Artículo en revista: Telematics and Informatics	<a href="https://doi.org/10.1016/j.tele.2017.09.015">https://doi.org/10.1016/j.tele.2017.09.015</a>
E88	2017	Selective openness, branding, broadcasting, and promotion: Twitter use in Canada's public universities	(Veletsianos et al., 2017)	Artículo en revista: Educational Media International	<a href="https://doi.org/10.1080/09523987.2017.1324363">https://doi.org/10.1080/09523987.2017.1324363</a>
E89	2016	Scholars in an increasingly open and digital world: How do education professors and students use Twitter?	(Veletsianos y Kimmons, 2016)	Artículo en revista: The Internet and Higher Education	<a href="https://doi.org/10.1016/j.iheduc.2016.02.002">https://doi.org/10.1016/j.iheduc.2016.02.002</a>

ID	Año	Título	Autor	Nombre de Revista o Conferencia	DOI
E90	2011	Higher education scholars' participation and practices on Twitter	(Veletsianos, 2011)	Artículo en revista: Journal of Computer Assisted Learning	<a href="https://doi.org/10.1111/j.1365-2729.2011.00449.x">https://doi.org/10.1111/j.1365-2729.2011.00449.x</a>
E91	2017	Toward a generalizable understanding of Twitter and social media use across MOOCs: who participates on MOOC hashtags and in what ways?	(Veletsianos, 2017)	Artículo en revista: Journal of computing in higher education	<a href="https://doi.org/10.1007/s12528-017-9131-7">https://doi.org/10.1007/s12528-017-9131-7</a>
E92	2011	Learning and Teaching as Communicative Actions: A Mixed-Methods Twitter Study	(Wakefield et al., 2011)	Artículo en revista: Knowledge Management & E-Learning: An International Journal (KM&EL)	<a href="http://kmel-journal.org/ojs/index.php/index/index">http://kmel-journal.org/ojs/index.php/index/index</a>
E93	2012	Twittering to increase student engagement in the university classroom	(Welch y Bonnan-White, 2012)	Artículo en revista: Knowledge Management & E-Learning: An International Journal	<a href="http://kmel-journal.org/ojs/index.php/index/index">http://kmel-journal.org/ojs/index.php/index/index</a>
E94	2010	Twittering in teacher education: reflecting on practicum experiences	(Wright, 2010)	Artículo en revista: Open Learning: The Journal of Open, Distance and e-Learning	<a href="https://doi.org/10.1080/02680513.2010.512102">https://doi.org/10.1080/02680513.2010.512102</a>
E95	2018	Exploring the relationship between online discourse and commitment in Twitter professional learning communities	(Xing y Gao, 2018)	Artículo en revista: Computers & Education	<a href="https://doi.org/10.1016/j.compedu.2018.08.010">https://doi.org/10.1016/j.compedu.2018.08.010</a>

<b>ID</b>	<b>Año</b>	<b>Título</b>	<b>Autor</b>	<b>Nombre de Revista o Conferencia</b>	<b>DOI</b>
E96	2014	Can the Online Social Networks Be Used as a Learning Tool? A Case Study in Twitter	(Zaina et al., 2014)	Artículo en conferencia: Learning Technology for Education in Cloud. MOOC and Big Data	<a href="https://doi.org/10.1007/978-3-319-10671-7">https://doi.org/10.1007/978-3-319-10671-7</a>



## Anexo B

### Encuesta Social Network & Education

La presente encuesta es anónima y el objetivo es la mejora continua de los procesos de enseñanza y aprendizaje.

#### 1. ¿Qué red social utilizas con más frecuencia?

	Nunca	Poco	Algunas veces	Casi siempre
WhatsApp				
Facebook				
Twitter				
YouTube				
LinkedIn				

#### 2. ¿Con qué objetivo utilizas la red social? (opción múltiple)

- Diversión
- Académicos
- Comunicación con otras personas
- Investigación y consulta
- Otro (especifique)

#### 3. ¿Qué red social utilizas o utilizarías con fines educativos, investigación o consulta académica? (opción múltiple)

- Facebook
- YouTube
- WhatsApp
- LinkedIn
- Twitter
- Otro (especifique)

#### 4. ¿En qué lugar buscar información académica? (opción múltiple)

- Libros físicos
- Wikipedia
- Libros digitales
- Yahoo! respuestas
- Revistas digitales
- YouTube
- Google
- Bibliotecas Digitales
- Google Académico
- Otro (especifique)



## Anexo C

### VALIDACIÓN DE CUESTIONARIO “SOCIAL NETWORK & EDUCATION” POR EXPERTOS

Sr. /Srta. Experto: usted ha sido seleccionado para evaluar el instrumento: **Social Network & Education**, que forma parte de la primera fase de investigación sobre la medición de la participación estudiantil durante las sesiones de clases presenciales y el uso de redes sociales en la educación. La evaluación de los instrumentos es de gran relevancia para determinar su validez y cuyos resultados aportan al área de investigación. Se agradece su valiosa colaboración.

**Nombre completo:**

**Formación académica:**

**Áreas de experiencia profesional:**

Se requiere que usted evalúe la claridad, coherencia y relevancia de cada pregunta. Además, determine si las preguntas son suficientes, **marcando con una X** de acuerdo con su criterio en la tabla correspondiente.

No.	Ítem	CLARIDAD				COHERENCIA				RELEVANCIA			
		No es claro	Requiere muchas modificaciones	Requiere modificación específica	Es claro	No tiene relación lógica	Tiene algo de relación	Tiene relación moderada	Completamente relacionado	No es relevante, puede eliminarse	Tiene algo de relevancia	Relativamente importante	Muy relevante
1	Señala las redes sociales que												

No.	Ítem	CLARIDAD				COHERENCIA				RELEVANCIA			
		No es claro	Requiere muchas modificaciones	Requiere modificación específica	Es claro	No tiene relación lógica	Tiene algo de relación	Tiene relación moderada	Completamente relacionado	No es relevante, puede eliminarse	Tiene algo de relevancia	Relativamente importante	Muy relevante
	utilizas con más frecuencia												
2	Señala los objetivos de uso de las redes sociales												
3	Señala las redes sociales que utilizas o utilizarías con fines educativos, investigación o consulta académica												
4	Señala los lugares en que buscas información académica												

No.	Ítem	CLARIDAD				COHERENCIA				RELEVANCIA			
		No es claro	Requiere muchas modificaciones	Requiere modificación específica	Es claro	No tiene relación lógica	Tiene algo de relación	Tiene relación moderada	Completamente relacionado	No es relevante, puede eliminarse	Tiene algo de relevancia	Relativamente importante	Muy relevante
5	¿Cuáles opciones tienes, si no comprendes algún concepto o explicación del profesor?, ¿qué haces?												
6	Si no preguntas al profesor ¿Qué opciones utilizas para solventar tus dudas?												
7	¿Cuál es la razón de no realizar preguntas en clase?												
8	Señala las opciones que consideras más												

No.	Ítem	CLARIDAD				COHERENCIA				RELEVANCIA			
		No es claro	Requiere muchas modificaciones	Requiere modificación específica	Es claro	No tiene relación lógica	Tiene algo de relación	Tiene relación moderada	Completamente relacionado	No es relevante, puede eliminarse	Tiene algo de relevancia	Relativamente importante	Muy relevante
	importantes de asistir a clases												
9	Selecciona las opciones que consideras te permiten un mejor aprendizaje												
10	Si fueras profesor ¿cómo solventarías las dudas de los estudiantes?												

Dimensión	SUFICIENCIA			
	Los ítems no son suficientes para medir la dimensión	Los ítems miden algún aspecto de la dimensión, pero no corresponden a la dimensión total	Se deben incrementar algunos ítems para poder evaluar la dimensión completamente	Los ítems suficientes
Objetivo del uso de redes sociales				
Uso de redes sociales en la educación				

Búsqueda de ayuda académica				
Participación estudiantil en el aula				
Estilos de enseñanza y aprendizaje				

**Observaciones:**

## Anexo D

### Características del entorno para la aplicación de la Estrategia Didáctica JiTTwT

Característica	Pasos para aplicación de la estrategia	Descripción de la aplicación	Aspecto Positivo	Aspecto Negativo
<b>Lugar de la Institución</b>	Identificar la institución, departamento, o facultad, en la que sea posible desarrollar y aplicar la estrategia didáctica.	La institución en la que fue desarrollada y aplicada la estrategia didáctica es la Universidad Central de Ecuador (UCE), Facultad de Ingeniería y Ciencias Aplicadas, lugar en que labora el docente.		
<b>Carrera</b>	Aplicar la estrategia a la carrera seleccionada.	La carrera seleccionada fue Ingeniería Civil, por ser el lugar en que labora el docente.		
<b>Modelo educativo</b>	Identificar el modelo educativo que persigue la institución para estar alineado.	Aunque no existe un modelo claramente definido en la institución en que labora el docente, predomina el modelo constructivista.		
<b>Malla curricular</b>	Considerar la malla curricular vigente en la carrera, para identificar la pertenencia de la asignatura dentro de la formación curricular del estudiante y contrastar con los resultados de aprendizajes esperados.	Malla curricular de Ingeniería Civil (vigente desde 2017). Resultados de aprendizaje de la asignatura: <i>"Desarrollar aplicaciones en una interfaz gráfica utilizando lógica de programación, utilizando un lenguaje de programación específico, a través del uso de técnicas, metodologías y software actualizado para la práctica en la Ingeniería Civil"</i> . Fuente: (Syllabus Programación I, 2017, p. 2)		
<b>Período de aplicación</b>	Identificar el período académico en que será aplicada la estrategia didáctica	El período académico de aplicación fue entre septiembre/2019 – marzo/2020.		Por el advenimiento de la pandemia no fue posible



Característica	Pasos para aplicación de la estrategia	Descripción de la aplicación	Aspecto Positivo	Aspecto Negativo
				aplicar en otros períodos académicos presenciales.
<b>Tiempo de aplicación de la estrategia por período académico</b>	Determinar las condiciones y el momento en que la estrategia didáctica puede ser aplicada y el tiempo mínimo de experimentación.	El tiempo de experimentación fue de 6 semanas, y de forma particular para el 2° Hemi; para cotejar los resultados de la experimentación llevada a cabo, con las evidencias del 1° Hemi.		
<b>Nivel/semestre/curso en el cual se dicta la asignatura</b>	Seleccionar el nivel en el que será aplicada la estrategia, que permita analizar el grupo de estudiantes con los que se realizará la experimentación.	La estrategia didáctica fue aplicada en el segundo nivel de la carrera, por ser el grado en que imparte clases el docente.	Algunos estudiantes cursaban por segunda ocasión la asignatura, pero estaban matriculados en tercer nivel; se presume que tienen conocimientos y aportan al grupo.	Estudiantes que apenas han ingresado a la Universidad, no cuentan con algunas habilidades, como son la responsabilidad y el trabajo autónomo.
<b>Asignatura</b>	Seleccionar la asignatura que forma parte de la experimentación, en la cual se identificó el problema.	La estrategia didáctica fue aplicada de forma específica para la asignatura y los contenidos de Programación 1.	Aprender programación permite desarrollar diferentes habilidades, entre ellas, la resolución de problemas mediante el pensamiento computacional, que incluye diferentes habilidades como: razonamiento lógico,	Es una asignatura con alto grado de reprobación.

Característica	Pasos para aplicación de la estrategia	Descripción de la aplicación	Aspecto Positivo	Aspecto Negativo
			abstracción, pensamiento crítico, entre otras.	
<b>Área a la que pertenece la asignatura dentro de la malla curricular</b>	Reconocer el área a la cual pertenece la asignatura, de forma que se pueda analizar los resultados con otras asignaturas que pertenecen al área.	El área a la que pertenece la asignatura de Programación 1, es las Ciencias Básicas, área no profesionalizante de la carrera de Ingeniería Civil.		Programación 1 no pertenecer al área profesionalizante de la carrera, por lo que, los estudiantes le restan importancia.
<b>Problema</b>	Identificar el problema y la necesidad de aplicar una mejora.	El problema identificado es la reducida participación estudiantil en la asignatura de Programación 1, de la carrera de Ingeniería civil.		
<b>Número de cursos evaluados:</b>	Analizar el número de cursos que forman parte de la muestra.	Contemplar los cuatro (4) cursos en los que el docente imparte la cátedra.		
<b>Número de estudiantes</b>	Analizar el número de estudiantes que forman parte de la muestra.	Se consideraron los 144 estudiantes para la experimentación, sin distinción de género, ni condición académica, esto incluye a los estudiantes repetidores.	Número de estudiantes significativo para la experimentación.	
<b>Número de estudiantes matriculados:</b>	Observar el número de estudiantes efectivos en cada curso.	El número de estudiantes por curso estaba entre 35 y 45 estudiantes.		No se logra captar la atención de todos los estudiantes y es difícil mantener el seguimiento académico y personal de todos los estudiantes.
<b>Acuerdos de confidencialidad</b>	Determinar si el experimento requiere o no la firma de confidencialidad o la	Al ser una actividad académica y forma parte del micro currículo, no requirió la autorización de los directivos. Sobre la confidencialidad de	Los estudiantes no tenían conocimiento del experimento, por lo que no hubo un sesgo en	

Característica	Pasos para aplicación de la estrategia	Descripción de la aplicación	Aspecto Positivo	Aspecto Negativo
	autorización por parte de las autoridades.	los datos, el consentimiento informado se lo realizó de forma verbal con los estudiantes.	cuanto a los comentarios realizados en la red social. Los estudiantes podían comentar libremente cualquier dificultad.	
<b>Recopilación y registro de los datos académicos</b>	Determinar y construir un registro con los datos necesarios para la realizar la experimentación, como son: código y género del estudiante, número de matrícula (1, 2 o 3 vez), calificaciones grupales, individuales, exámenes, pruebas para el 1° y 2° Hemi; asistencias; número de participaciones; estado del estudiante (retirado, vigente); observaciones finales (aprueba, reprobada, retirado); y otras que se consideren relevantes para el estudio.	Tomar del registro docente los campos requeridos para el presente estudio, de cada uno de los cursos, esto son: a) promedios finales del 1° y 2° Hemi; b) estado del estudiante (retirado, vigente); c) observaciones finales (aprueba, reprobada, retirados); d) número de participaciones por Hemi; e) género del estudiante.	El registro es personal del docente, con acceso a toda la información académica de los estudiantes.	Registro manual que requiere ser administrado por el docente.
<b>Género de los estudiantes:</b>	Identificar el porcentaje de estudiantes por género para analizar si los resultados de la aplicación de la estrategia didáctica tienen relación con el género del estudiante.	Del grupo de estudiantes de la muestra, se calculó que el 71,53% pertenecían al género masculino y el 28,47% al género femenino.		No hay equidad de género.

Característica	Pasos para aplicación de la estrategia	Descripción de la aplicación	Aspecto Positivo	Aspecto Negativo
<b>Conformación de grupos de estudio</b>	Establecer un criterio para la conformación de los grupos de control y de experimentación.	El criterio seleccionado fue el análisis de la participación estudiantil en el 1° Hemi; donde, el grupo experimental refleja menor participación que el grupo de control. Grupo experimental 80 estudiantes y grupo de control 64 estudiantes.	Tomar el grupo experimental para mejorar la participación estudiantil.	La conformación previa podría excluir alguna característica importante de los estudiantes.
<b>Número de créditos de la asignatura (carga horaria semanal)</b>	Identificar el número de horas por semana que dispone el docente para impartir la cátedra.	El número de créditos de la asignatura de Programación 1, es de tres (3) horas por sesión. Las 3 horas son utilizadas para la ejecución de la 2da., 3ra. y 4ta. fases de la estrategia didáctica, con los tiempos establecidos por cada actividad.	Inclusión de diferentes actividades didácticas dentro del aula.	Las tres horas seguidas de clase dificulta mantener la concentración y motivación de los estudiantes; por lo que, el docente requiere el cambio continuo de actividades para motivar a los estudiantes, que implica estar en constante preparación.
<b>Número de clases por semana</b>	Considerar el número de horas a la semana que el docente imparte la cátedra, y mantiene contacto con los estudiantes.	Se recibe 3 horas semanales; es decir, el docente solo dispone de un día a la semana para impartir las clases de forma presencial. Aprovechando el aspecto negativo de la falta de continuidad de la asignatura, se aplica la fase 1 de la estrategia didáctica para recolectar y leer los tweets, y complementar el material didáctico para la siguiente sesión de clase.	Preparar material didáctico para la siguiente sesión de clase.	Al recibir una vez por semana, no se genera continuidad de las clases y se requiere emplear más tiempo en la retroalimentación al iniciar la sesión de clase.

Característica	Pasos para aplicación de la estrategia	Descripción de la aplicación	Aspecto Positivo	Aspecto Negativo
<b>Aula de clase</b>	Reconocer el espacio de trabajo en la que se impartirá la cátedra y será aplicada la estrategia didáctica.	Aula de clase con capacidad de 24 a 30 equipos de cómputo, se dispone de mesas y sillas para 60 estudiantes.	El aula tiene iluminación y ventilación adecuada para impartir la cátedra.	Las aulas, no son de uso exclusivo del docente de programación, por lo que, en ocasiones se encuentran novedades que deben ser resueltas durante la sesión de clase, retrasando la planificación.
<b>Recursos de aula</b>	Identificar y registrar los recursos del aula: proyector, pizarra, computadores, dispositivos móviles, conexión a Internet, sillas, mesas, previos a la aplicación de la Estrategia Didáctica JiTTwT.	El aula dispone de proyector correctamente funcionando, una pizarra de tiza líquida, computador personal y computadores para los estudiantes, existe conexión a Internet en todos los equipos, se cuenta con sillas y mesas para todos los estudiantes. Con los recursos del aula, es posible realizar las siguientes actividades: 1) Con el proyector y la pizarra, el docente inicia la clase con las actividades de la fase 2 de la estrategia didáctica; 2) los estudiantes utilizan los equipos para el trabajo grupal en la fase 3 de la estrategia; 3) con el proyector y la pizarra el docente resume los objetivos de la clase y emite las conclusiones finales, actividades que forman parte de la fase 4 de la estrategia didáctica.		Algunos equipos tienen fallas tecnológicas, por lo que, dificulta el trabajo en algunas actividades. Además, los estudiantes deben compartir el computador entre dos y hasta tres alumnos por equipo.

Característica	Pasos para aplicación de la estrategia	Descripción de la aplicación	Aspecto Positivo	Aspecto Negativo
<b>Recursos de los estudiantes</b>	Constatar los recursos con los que cuenta el estudiante para recibir la clase, para realizar las actividades programadas en la Estrategia Didáctica JiTTwT.	Los estudiantes utilizan sus dispositivos móviles para comentar sobre la práctica de laboratorio realizada en la fase 4 de la estrategia.	Facilidad de acceso a material actualizado. El uso de dispositivos móviles es una oportunidad para realizar actividades académicas.	Los estudiantes usan excesivamente los dispositivos móviles y se pueden distraer al navegar por Internet.
<b>Estilo de enseñanza</b>	Reconocer el estilo de enseñanza del docente, de forma que se establezcan las condiciones en las que será aplicada la Estrategia Didáctica JiTTwT.	El docente tiene el estilo Autoridad Formal, en la que mantiene su posición entre los estudiantes por su conocimiento y dentro de la institución (Oviedo et al., 2010). Retroalimenta a los estudiantes, de acuerdo con los objetivos del curso, de la clase y de los comentarios realizados por los estudiantes en la red social Twitter. Además, brinda un conocimiento estructurado de a los estudiantes, partiendo de ejercicios base hasta ejercicios más complejos. Estas actividades forman parte de la 2, 3 y 4 fase de la estrategia didáctica.		Debido al número de estudiantes por aula, no siempre es posible ser un Docente Facilitador.
<b>Estilo de aprendizaje</b>	Identificar el estilo de aprendizaje de los estudiantes para aplicar la Estrategia Didáctica JiTTwT.	El estilo de aprendizaje no fue considerado en el presente estudio; por lo que, la estrategia se aplicó al grupo experimental sin tomar en consideración la forma en que aprenden los estudiantes.		No se conoce el estilo de aprendizaje del estudiante, por lo que, los resultados de la aplicación de la estrategia didáctica podrían verse afectados por este factor.

## Anexo E

### ENCUESTA PARA MEDIR LA ACTITUD HACIA EL APRENDIZAJE DE PROGRAMACIÓN Y LA AUTOPERCEPCIÓN DEL PENSAMIENTO CRÍTICO

La presente encuesta es de carácter confidencial y anónimo, su objetivo se enmarca en determinar la autopercepción de la habilidad de pensamiento crítico y la actitud hacia el aprendizaje del estudiante, hacia la asignatura de Programación 1 que puede influir en su desempeño académico.

Las respuestas serán utilizadas con fines puramente investigativos, dirigidos a brindar mejores oportunidades a los estudiantes para aprender y a los profesores para enseñar.

Género: Masculino / Femenino      Edad: \_\_\_\_\_

Código Curso: \_\_\_\_\_

Indique el grado de acuerdo o desacuerdo que tenga con las preguntas sobre la asignatura de Programación 1, conforme a los siguientes criterios:

1. Totalmente en desacuerdo
2. En desacuerdo
3. De acuerdo
4. Totalmente de acuerdo

SECCIÓN ACTITUD HACIA EL APRENDIZAJE DE LA ASIGNATURA DE PROGRAMACIÓN					
Aspecto a evaluar	Pregunta	1	2	3	4
DIVERSIÓN	1. ¿Realizar ejercicios en Programación es una diversión para mí?				
CONTENIDOS TEÓRICOS	2. ¿Programación es una asignatura demasiada teórica para que pueda servirme de algo?				
PROFUNDIDAD	3. ¿Deseo alcanzar un conocimiento más productivo en Programación?				
CONFIANZA	4. ¿Tengo confianza en mí cuando me enfrento a un problema a resolver con Programación?				
SOCIALIZACIÓN	5. ¿Me divierte hablar con otros sobre Programación?				
FUTURA UTILIDAD	6. ¿Crees que saber Programación te ayudará cuando estés en un nivel superior?				

SECCIÓN DE LA AUTOPERCEPCIÓN DEL PENSAMIENTO CRÍTICO					
Dimensión de competencia a evaluar	Pregunta	1	2	3	4
Interpretación y análisis de información	1. ¿Puedo establecer comparaciones entre diferentes métodos de resolución de problemas informáticos?				
	2. ¿Utilizo mi sentido común para juzgar la relevancia de la información?				
Juicio de una situación específica con datos objetivos y subjetivos	3. ¿Prefiero la resolución de problemas informáticos basados en evidencias a mi percepción personal?				
	4. ¿Puedo resolver un problema informático, aunque no disponga de toda la información?				
	5. ¿A pesar de las evidencias en mi contra, mantengo firmes mis creencias?				
	6. ¿Prefiero aplicar un método conocido, antes de arriesgarme a probar uno nuevo?				
Inferencias de las consecuencias, basándose en el juicio autorregulado	7. ¿Expreso alternativas innovadoras, a pesar de las reacciones que pueda generar?				
	8. ¿Sé distinguir entre hechos reales y prejuicios?				



## Anexo F

### VALIDACIÓN DE CUESTIONARIO “ACTITUD Y PENSAMIENTO CRÍTICO” POR EXPERTOS

Sr. /Srta.: Usted ha sido seleccionado como Experto en el área de Programación, con la finalidad de evaluar el instrumento: ENCUESTA DE ACTITUD ESTUDIANTIL Y HABILIDAD DE PENSAMIENTO CRÍTICO EN LA ASIGNATURA DE PROGRAMACIÓN, el mismo que constituye un Pre-Test del "Proyecto de investigación sobre participación estudiantil durante las sesiones de clases presenciales en la universidad". Su criterio sobre las preguntas utilizadas en la encuesta, es de gran relevancia para determinar su aplicabilidad en la investigación. Se agradece su valiosa colaboración.

Nombre completo:

Formación académica:

Área de experiencia profesional:

Años de experiencia:

Las preguntas fueron presentadas a los estudiantes, para que respondan conforme a su nivel de acuerdo o desacuerdo, utilizando la siguiente escala:

1 = Totalmente en desacuerdo

2 = En desacuerdo

3 = De acuerdo

4 = Totalmente de acuerdo

Se requiere que usted evalúe la claridad, coherencia y relevancia de cada pregunta. Para el efecto se han definido dos tablas que evalúen la **Actitud** y el **Pensamiento Crítico**. Además, determine si las preguntas son suficientes, **marcando con una X** de acuerdo con su criterio en la tabla correspondiente.

N°	DIMENSIÓN	Preguntas	CLARIDAD DE LA PREGUNTA				COHERENCIA DE LA PREGUNTA				RELEVANCIA DE LA PREGUNTA			
			No es claro	Requiere muchas modificaciones	Requiere modificación específica	Es claro	No tiene relación lógica	Tiene algo de relación	Tiene relación moderada	Completamente relacionado	No es relevante, puede eliminarse	Tiene algo de relevancia	Relativamente importante	Muy relevante
1	ACTITUD	¿Realizar ejercicios en Programación es una diversión para mí?												
2		¿Programación es una asignatura demasiada teórica para que pueda servirme de algo?												
3		¿Deseo alcanzar un conocimiento más productivo en Programación?												
4		¿Tengo confianza en mí cuando me enfrento a un problema a resolver con Programación?												
5		¿Me divierte hablar con otros sobre Programación?												
6		¿Crees que saber Programación te ayudará cuando estés en un nivel superior?												

N°	DIMENSIÓN	Preguntas	CLARIDAD DE LA PREGUNTA				COHERENCIA DE LA PREGUNTA				RELEVANCIA DE LA PREGUNTA			
			No es claro	Requiere muchas modificaciones	Requiere modificación específica	Es claro	No tiene relación lógica	Tiene algo de relación	Tiene relación moderada	Completamente relacionado	No es relevante, puede eliminarse	Tiene algo de relevancia	Relativamente importante	Muy relevante
1	<b>PENSAMIENTO CRÍTICO</b>	¿Puedo establecer comparaciones entre diferentes métodos de resolución de problemas informáticos?												
2		¿Utilizo mi sentido común para juzgar la relevancia de la información?												
3		¿Prefiero la resolución de problemas informáticos basados en evidencias a mi percepción personal?												
4		¿Puedo resolver un problema informático, aunque no disponga de toda la información?												
5		¿A pesar de las evidencias en mi contra, mantengo firmes mis creencias?												
6		¿Prefiero aplicar un método conocido, antes de arriesgarme a probar uno nuevo?												

7		¿Expreso alternativas innovadoras, a pesar de las reacciones que pueda generar?												
8		¿Sé distinguir entre hechos reales y prejuicios?												

SUFICIENCIA DE LAS PREGUNTAS				
DIMENSIÓN	Las preguntas NO son suficientes para medir la dimensión	Las preguntas miden algún aspecto de la dimensión, pero no corresponden a la dimensión total	Se deben incrementar algunas preguntas para poder evaluar la dimensión completamente	Las preguntas SON suficientes
Actitud				
Pensamiento Crítico				

Sugerencias:

## Anexo G

### CREACIÓN DE APP DE TWITTER COMO DESARROLLADOR

Para crear la App se requirió completar ciertos datos de un formulario con los siguientes campos: Nombre, Descripción, Sitio Web (host), además de aceptar los términos y condiciones de la plataforma. Ver Figura 46.

**Twitter Apps** Create New App

Aplicacion para hacer test de git

Create custom twit from terminal

**Application Details**

**Name \***  
PostTweetFromTerminal 1

Your application name. This is used to attribute the source of a tweet and in user-facing authorization screens. 32 characters max.

**Description \***  
Create custom twit from terminal 2

Your application description, which will be shown in user-facing authorization screens. Between 10 and 200 characters max.

**Website \***  
http://enmisac.com/ 3

Your application's publicly accessible home page, where users can go to download, make use of, or find out more information about your application. This fully-qualified URL is used in the source attribution for tweets created by your application and will be shown in user-facing authorization screens. (If you don't have a URL, yet, just put a placeholder here but remember to change it later.)

**Callback URLs**  
4

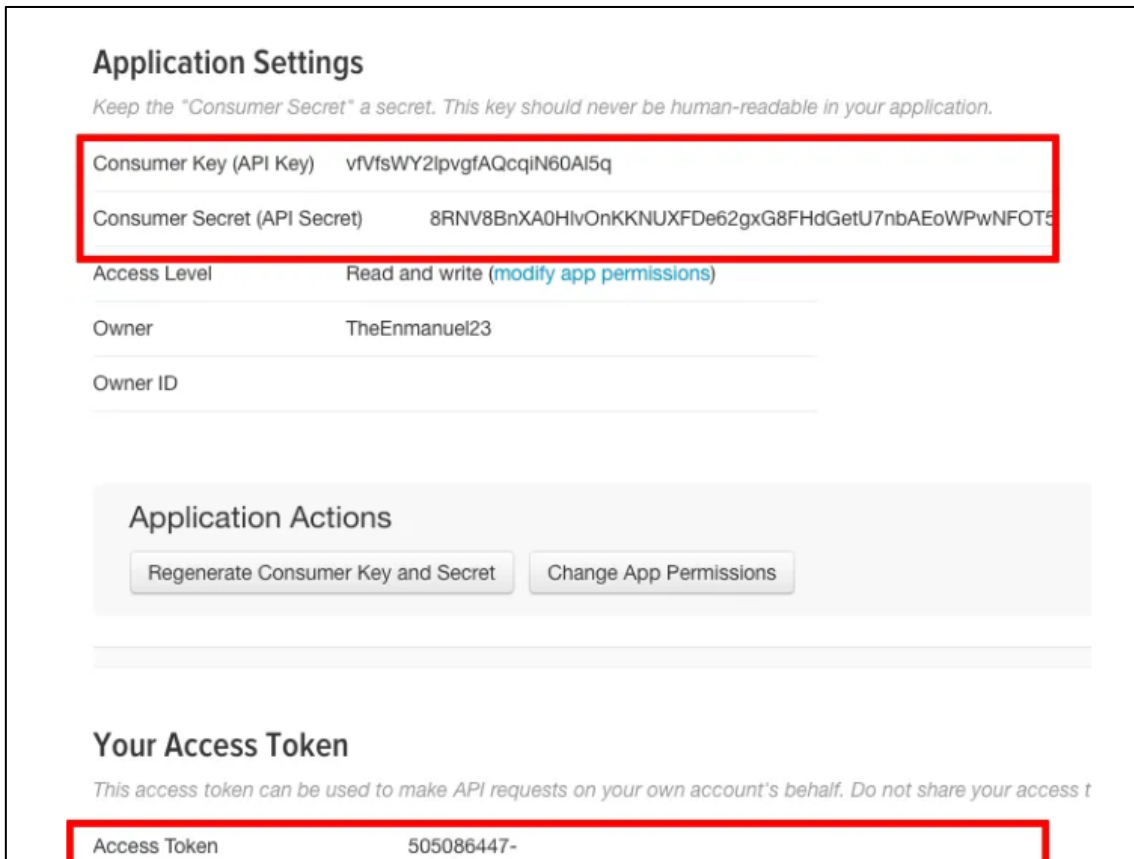
Where should we return after successfully authenticating? OAuth 1.0a applications must explicitly specify their oauth\_callback URL(s) here, as well as include the one of the URLs below in the request token step. To restrict your application from using callbacks, leave this field blank.

*Nota: Fuente de (Medium, 2018)*

Figura 46 – Creación de Apps en Twitter

- 1) El nombre de la aplicación debe ser único.
- 2) En la descripción se escribe un breve detalle de lo que se trata la App.
- 3) En sitio Web «Website», se puede escribir cualquiera, en caso de que no se disponga de una propia.
- 4) El último campo no es necesario llegar, a menos que se desee redireccionar un lugar donde Twitter debe ingresar en el inicio de sesión.

Una vez aceptado los acuerdos de desarrollador, es posible visualizar la App creada. En esta pantalla existen diferentes pestañas, como se visualiza en la Figura 47.



Nota: Fuente de (Medium, 2018)

Figura 47 – Pestaña de configuración de Apps en Twitter

La pestaña más importante es la de «Key and Access Tokens»; ya que, a través de la autenticación, Twitter se asegura que los datos estén protegidos para desarrolladores y usuarios, debido al alto volumen de datos que la red social maneja (TWITTER, 2022a). Existen diferentes métodos de autenticación: OAuth 1.0a Contexto de Usuario; Solo Aplicación, Autenticación Básica, y OAuth 2.0 con PKCE.

Para el presente trabajo doctoral, se utilizó el método de autenticación OAuth 1.0a, cuyo propósito es permitir que una aplicación de desarrollador de Twitter autorizado, acceda a la información de la cuenta privada o realice una acción de Twitter en nombre de una cuenta de Twitter (TWITTER, 2022a).

El Consumer Key (API Key) y el Consumer Secret (API Secret) son credos por defecto. La clave y el secreto de la API, también conocidos como clave y secreto del consumidor, son las credenciales necesarias para acceder a Twitter API. Estas credenciales actúan como el nombre de usuario y la contraseña de la aplicación creada y Twitter API y son utilizadas para determinar la procedencia de las solicitudes (TWITTER, 2022a).

Al final de la página se contó con un botón que permitió crear el Access Token y Access Secret. Los Tokens permiten autorizar a las aplicaciones la conexión a Twitter API; por ejemplo: obtener una lista de tweets, realizar accesos (TWITTER, 2022a). Los Tokens son credenciales específicas del usuario para autenticar las solicitudes a la API OAuth 1.0.a e indican la cuenta de Twitter de que realiza la solicitud.

Con estas 4 credenciales es posible realizar requerimientos a Twitter API y empezar con la extracción de los datos. Una vez que se dispuso de las credenciales de autenticación, se procedió con el desarrollo de la aplicación que permitió extraer los datos requeridos de Twitter, para ello se decidió utilizar el lenguaje de programación Python.

En el mercado, existen diferentes herramientas para la extracción de datos provenientes de la red social Twitter, entre las que se pueden citar: SPSS, Radian, NVivo, Java, R, MediaToolKit, entre otras; sin embargo, las razones por las que se decidió trabajar con el lenguaje de programación Python fueron: ser un software libre, disponer de amplias bibliotecas para trabajar con Twitter API como Tweepy, tener la posibilidad de interactuar con la comunidad de desarrolladores y principalmente por el conocimiento del tesista. En este análisis fue aplicado el concepto de la fase de abstracción del Pensamiento Computacional, para identificar la herramienta más afectiva para extraer datos provenientes de Twitter.

Todas las Twitter API que recuperan tweets, proporcionan datos codificados mediante la notación de objetos de JavaScript (JSON). JSON tiene sus campos con el atributo: nombre y valores asociados (estructura de par: clave-valor). Estos atributos y su estado, se utilizan para describir objetos. Todos estos objetos encapsulan atributos centrales que describen el objeto. Cada tweet contiene la siguiente información: autor, mensaje, identificación única, marca de tiempo de cuándo se publicó y en ocasiones metadatos geográficos compartidos por el usuario. Cada usuario tiene un nombre de Twitter, una identificación, una cantidad de seguidores y en la mayoría de los casos, una biografía de la cuenta. Con cada tweet también se generan objetos llamados "entidad", que son conjuntos de contenidos comunes de tweet, como hashtags, menciones, medios y enlaces. Si existen enlaces, JSON también puede proporcionar metadatos como la URL completamente desplegada, el título y la descripción de la página web. De forma que, además del contenido de texto, un tweet puede tener más de 150 atributos asociados (TWITTER, 2022d). Ver Figura 48.

```

{
  "id": 1273277578359513088,
  "id_str": "1273277578359513088",
  "name": "Christian Ovaco",
  "screen_name": "ChristianOvaco",
  "location": "",
  "description": "",
  "url": null,
  "entities": {
    "description": {
      "urls": []
    }
  },
  "protected": false,
  "followers_count": 1,
  "friends_count": 22,
  "listed_count": 0,
  "created_at": "Wed Jun 17 15:34:03 +0000 2020",
  "favourites_count": 1,
  "utc_offset": null,
  "time_zone": null,
  "geo_enabled": false,
  "verified": false,
  "statuses_count": 1,
  "lang": null,
  "status": {
    "created_at": "Thu Jun 25 23:51:53 +0000 2020",
    "id": 1276302124666806272,
    "id_str": "1276302124666806272",
    "text": "@Anilupss2015 Mi mayor dificultad es al momento de usar las estructuras de control, creo que con pr\u00e1ctica voy a mejorar",
    "truncated": false,
    "entities": {
      "hashtags": [],

```

Figura 48 – Ejemplo de objetivo codificado en formato JSON