



Universidad del Azuay

Facultad de Ciencias de la Administración

Carrera de Ingeniería de Sistemas y Telemática

**DESARROLLO DE UNA METODOLOGÍA PARA
GENERAR VÍNCULOS RELACIONADOS A
TEXTOS TRANSCRITOS PARA VIDEOS DE
YOUTUBE**

**Trabajo de titulación previo a la obtención del grado en
Ingeniero de Sistemas y Telemática**

Autores:

Pablo Daniel Martínez León

Director:

Ing. Marcos Patricio Orellana Cordero

Cuenca – Ecuador

2023

DEDICATORIA

Dedico este trabajo a ustedes, mis amados papitos, este logro no habría sido posible sin su amor, su apoyo incondicional y constante aliento a lo largo de toda mi vida. Por hacerme la persona que soy y que confíe y crea en mí siempre. Su dedicación, sacrificio y valores han sido pilares fundamentales en mi formación y en mi día a día. Gracias por ser mis guías, mis consejeros y mis mayores admiradores. No hay palabras suficientes para expresar mi gratitud por todo lo que han hecho por mí. Los amo con todo mi corazón y gracias por siempre brindarme su cariño, por ser mi inspiración y por darme las raíces que me han sostenido y las alas que me han permitido volar. Esto es por y para ustedes.

A mis abuelos y abuelas, les agradezco por su sabiduría, consejos y amor incondicional. Sus palabras de aliento y su apoyo constante me han impulsado a superar obstáculos y a perseguir mis sueños desde pequeño. Su presencia en mi vida es un regalo invaluable y su legado será siempre una guía en mi camino. Gracias por darme ese amor único y enseñarme la importancia de ser una persona íntegra en todas las áreas de mi vida. No hay mejor ejemplo a seguir que ustedes.

A mi novia, por todo el cariño, el amor y el apoyo durante toda esta etapa. Gracias por acompañarme y estar ahí en cada momento, por todo lo que has hecho y sigues haciendo por mí y por nunca faltarme. Estoy muy agradecido de tenerte a mi lado y poder compartir estos momentos especiales contigo.

Finalmente a todos mis familiares y amigos incondicionales, por estar ahí en todos los momentos de mi camino.

A todos, espero que esta tesis sea solo el comienzo de muchas alegrías compartidas.

AGRADECIMIENTO

Agradezco a mi director de tesis, Marcos Orellana, por su inigualable experticia y dedicación a lo largo de este tiempo. Su guía y orientación fueron fundamentales para llevar a cabo este estudio con éxito.

De igual manera, quiero expresar mi profundo agradecimiento a todo el grupo de investigación del laboratorio L.I.D.I. Su invaluable ayuda y colaboración han sido imprescindibles en cada etapa de este proyecto.

Agradezco de todo corazón a mis padres por su apoyo incondicional, paciencia y por brindarme las fuerzas necesarias para cumplir esta importante etapa de mi vida. Su amor y aliento han sido mi motor y me han dado la confianza para enfrentar cualquier desafío.

También quiero extender mi agradecimiento a cada uno de los profesores que formaron parte de mi instrucción académica. Su generosidad al compartir sus conocimientos y su paciencia para responder a mis dudas han sido de gran valor para mi formación.

No puedo dejar de mencionar mi profunda gratitud hacia la Universidad del Azuay, por brindarme la oportunidad de realizar mis estudios y por fomentar un ambiente propicio para el aprendizaje y el crecimiento personal.

Por último, quiero agradecer a mis familiares, a mi novia y a mis amigos que fueron parte de esta increíble etapa de mi vida. Su compañía, amor, amistad y apoyo han hecho de este viaje una experiencia inolvidable.

A cada uno de ustedes, mi más sincero agradecimiento por ser parte de este camino y por contribuir de manera significativa a mi desarrollo personal y profesional.

ÍNDICE

Índice de contenido

DEDICATORIA.....	I
AGRADECIMIENTO.....	II
Índice de contenido.....	III
Índice de Tablas.....	V
Índice de Figuras.....	VI
Índice de anexos.....	VII
Resumen:.....	VIII
Abstract:.....	VIII
1. Introducción.....	1
2. Marco Teórico.....	4
3. Estado del Arte.....	8
4. Metodología.....	11
4.1. Extraer Transcripción.....	12
4.2. Aplicar Técnicas de Minería de texto.....	14
4.2.1. Extraer palabras claves.....	14
4.3 Extraer artículos de Wikipedia.....	17
4.4. Clasificar la relación de los temas de interés.....	18
4.5. Generar Mashup.....	20
5. Resultados.....	22
6. Evaluación.....	28
6.1 Goal Question Metric.....	28
6.2 Modelo de aceptación tecnológica (TAM):.....	30
6.2.1. Definición de variables.....	30
6.2.2. Hipótesis.....	31
6.2.3 Ejecución.....	32
6.3 Análisis e interpretación de los datos recolectados.....	33
6.3.1 Resultados de la Encuesta.....	33
6.4 Validación de las Hipótesis.....	34
6.5 Amenazas a la validez.....	35
7. Conclusiones.....	38
8. REFERENCIAS.....	39
ANEXOS.....	42
Anexo 1.....	42

Anexo 2..... 44

Índice de Tablas

Tabla 1. Componentes funcionales de Yake!	17
Tabla 2. Cuestionario para la medición de variables con TAM	32
Tabla 3. Estadística descriptiva de los resultados obtenidos para cada variable	33

Índice de Figuras

Figura 1. Metodología SPEM	12
Figura 2. Metodología SPEM técnicas de minería de texto	14
Figura 3. Página de inicio y campo de texto del enlace de YouTube.....	21
Figura 4. Gráfico de Resultados Temática Informática.....	23
Figura 5. Resultado Temática Informática dentro del Mashup	24
Figura 6. Gráfico de Resultados de la temática de matemáticas	25
Figura 7. Resultados de temática de matemáticas dentro del Mashup	26

Índice de anexos

Anexo 1. Cuestionario para la medición de variables con TAM.....	44
Anexo 2. Resultados del Cuestionario para la medición de variables con TAM.....	42

Resumen:

En la actualidad, las herramientas tecnológicas ayudan en tareas de aprendizaje. Existen diversas fuentes de información donde las personas se apoyan para complementar sus actividades académicas. Se busca contenido en la web, significativamente actualizado y fácil de entender, generalmente en forma de videos o textos cortos. Conforme las personas incrementan su aprendizaje, se enfrentan a términos y conceptos con los que no están familiarizados. Esto genera un proceso complejo de vincular palabras y frases de la transcripción del video con otras fuentes de información que puedan explicar los temas relacionados y que contribuyan a la comprensión del tema tratado. La presente investigación involucra el desarrollo de un método donde se integren diferentes fuentes de datos, a través de un software basado en técnicas de minería de texto. La misma que permitirá extraer el contenido textual de los videos e identificar los términos que se relacionan con el tema de estudio.

Palabras clave: Clasificación de texto, Mashup, Minería de texto, Palabras claves, Procesamiento de lenguaje natural

Abstract:

Nowadays, technological tools assist in learning tasks. There are various sources of information that people rely on to complement their academic activities. Content, significantly updated and easy to understand, usually in the form of videos or short texts is searched on the web. As people increase their learning, they are confronted with terms and concepts with which they are not familiar with. Therefore, a complex process is generated to link words and phrases from the video transcript with other sources of information that can explain the related topics and contribute to the understanding of the subject being addressed. This research involves the development of a method where different data sources are integrated through text mining techniques-based software. This method will allow extracting the textual content from videos and identifying the terms that are related to the topic of study.

Keywords: Keywords, Mashup, Natural Language Processing, Text Classification, Text Mining



Este certificado se encuentra en el repositorio digital de la Universidad del Azuay, para verificar su autenticidad escanee el código QR

Este certificado consta de: 1 página

1. Introducción

En la actualidad, las herramientas tecnológicas apoyan en gran medida la labor de las tareas de enseñanza-aprendizaje. En este sentido, existen diversas fuentes de información en las que las personas se apoyan para complementar sus actividades académicas. Se buscan contenidos en la internet, significativamente actualizados y de fácil comprensión, generalmente en forma de vídeos. A medida que las personas incrementan su aprendizaje, se enfrentan a términos y conceptos con los que no están familiarizados. En este contexto, se genera un complejo proceso de intermitencia en la visualización completa del vídeo, mientras se buscan otras fuentes de información que den explicación a los temas relacionados, y que contribuyan a la comprensión del tema tratado. En este sentido, y considerando la posibilidad de consumir sistemáticamente información de diversas fuentes, es necesario construir un método y una aplicación que orqueste los contenidos de estas fuentes.

Es posible, con las nuevas tecnologías, tratar el texto y el video generado por los usuarios para crear clasificaciones o también predicciones. La disciplina que se encarga del tratamiento digital del texto es el Procesamiento de Lenguaje Natural (NLP por sus siglas en inglés), que se describe como una rama de la inteligencia artificial dentro de la informática que se centra en ayudar a las máquinas a entender la forma en como los humanos escriben y hablan (Litman, 2016). La tarea es compleja, porque implica muchos datos no estructurados, ya que el estilo de habla y de escritura de las personas es único, y evoluciona constantemente. Las funciones de NLP mejoran cuanto más escribimos, hablamos y conversamos con los ordenadores por lo que están aprendiendo todo el tiempo. Un claro ejemplo de este aprendizaje iterativo es Google Translate, su sistema funciona mediante una gran red neuronal artificial para aumentar la fluidez y la precisión en los distintos idiomas. En lugar de traducir una sección de texto cada vez, intenta traducir frases enteras. Como recorre millones de ejemplos, utiliza un contexto más amplio para deducir la traducción más relevante. A diferencia del Google Translate original, que utilizaba el proceso de traducir del idioma de origen al inglés antes de traducir al idioma de destino, el traductor ahora utiliza “*Zero-shot translate*”, es decir, traduce directamente del idioma de origen al de destino (Vaswani et al., 2017).

Zero-shot translate: modelo de traducción automática que permite la traducción entre idiomas que no se incluyeron explícitamente en los datos de entrenamiento. Aprovecha las capacidades generales de comprensión del lenguaje del modelo para realizar traducciones incluso para pares de idiomas en los que no ha sido específicamente entrenado. (Vaswani et al., 2017)

Las palabras clave se utilizan con frecuencia en muchas ocasiones como indicadores de información importante contenida en los documentos. Estos pueden ser utilizados por lectores humanos para buscar sus documentos deseados, pero también en muchas aplicaciones de NLP, como resumen de texto (Pal et al., 2013), categorización de texto (Ozgur et al., 2005), extracción de textos (Marujo et al., 2011), entre otros. Se han propuesto marcos automáticos para extraer palabras clave (Riloff y Lehnert, 1994; Witten et al., 1999; Turney, 2000; Medelyan et al., 2010; Litvak y Campos et al., 2019). Estos sistemas fueron construidos para dominios como datos de noticias o extracción de textos de la Web, donde el contenido todavía se produce de manera controlada. En muchas aplicaciones, los conjuntos de datos y modelos existentes tienden a tener un desempeño significativamente peor en estos dominios como: traducción automática, reconocimiento de entidades nombradas y resumen de textos (Chang et al., 2013).

La clasificación de textos desempeña un papel importante en muchas aplicaciones de NLP, como la clasificación de preguntas, la categorización de noticias, la clasificación de texto, entre otros. (Minaee et al., 2021). Aunque una amplia variedad de métodos ha demostrado ser exitosos en la clasificación supervisada de textos, a menudo se rompen cuando se aplican en las predicciones para clases emergentes incrementales sin datos de entrenamiento etiquetados (Pourpanah et al., 2020). A diferencia del aprendizaje Zero-shot Classification, que tiene como objetivo clasificar las instancias de clase no vistas en el momento de la prueba (Wang et al., 2019). La técnica de Zero-shot que se basa este trabajo, tiene como objetivo clasificar nuevos temas y determinar si pertenece al tema central de un texto.

Zhang et al. (2019), genera características para clases no vistas basadas en información lateral, es decir, atributos a nivel de clase o descripción de texto. Más recientemente Ye et al. (2020), utilizan métodos de auto entrenamiento reforzado para aprovechar los datos no etiquetados durante el entrenamiento. Con la suposición de que no se dispone de conocimientos sobre categorías no vistas está disponible durante la fase de aprendizaje del modelo, recurren a distintos enfoques para manejar la clasificación generalizada de textos sin etiqueta.

Tomando como referencia los estudios mencionados previamente, donde se utilizan diferentes técnicas de minería de texto y NLP como Yake!, y Zero-shot Classification. El objetivo de este estudio es extraer las palabras clave de la transcripción de un video

que se obtiene a través de *API's* y generar nuevos temas de aprendizaje relacionados al mismo a través de una clasificación mediante *Zero-shot*, asociándolos con enlaces hacia fuentes de información.

A la vez que se implementa un *Mashup* donde se visualiza los distintos temas relacionados con un enlace hacia un artículo de Wikipedia. Esta propuesta aplica técnicas recogidas de varios estudios, las cuales se consolidan en un solo proceso para identificar temas relacionados a las palabras claves identificadas de la transcripción de un video, clasificar la relación de los temas extraídos con un video seleccionado de YouTube, y generar enlaces hacia artículos de Wikipedia de estos.

API: API (Application Programming Interface, por sus siglas en inglés) es un conjunto de reglas y protocolos que permiten a diferentes aplicaciones comunicarse y compartir información entre sí de manera estandarizada.

Mashup: Un Mashup es una aplicación o sitio web que combina y muestra contenido de múltiples fuentes o servicios en una única interfaz

2. Marco Teórico

En los últimos años, dentro del área académica se han utilizado distintos métodos para la enseñanza y el aprendizaje. En ciertas ocasiones, cuando se acuden a distintas fuentes de conocimiento para investigar sobre un tema, se puede encontrar con que a partir de esta información se pueden generar varios términos y temas de conocimiento nuevos. Lo mismo que provoca la búsqueda de nuevas fuentes de información, que explican los temas relacionados y contribuyen a la comprensión de los mismos. Esta secuencia, reduce la eficacia del flujo de estudio de la persona, por lo cual, se analiza la creación de una metodología que engloba todo este proceso de manera automática con el uso de técnicas de minería de texto, y procesamiento de lenguaje natural que ayuden a realizar este proceso y a comprender los nuevos temas relacionados a la investigación principal. A través de técnicas de procesamiento de lenguaje natural y minería de texto se pueden encontrar nuevos temas a partir de un texto base (Devlin et al., 2019). Estas propuestas, se basan en un proceso en donde se extraen características de los textos transcritos y se clasifican las palabras clave del texto ingresado. Al mismo tiempo, se utilizará el Procesamiento del Lenguaje Natural (NLP) y procesos de Inteligencia Artificial (IA) para implementar dentro de la metodología

La extracción de información consiste en estructurar datos escritos en lenguaje natural, a través de la extracción automática de entidades, atributos y relaciones. La extracción de información permite a medida que crece la cantidad de información generada, leer y resumir textos de grandes colecciones; se convierte en una tarea desafiante. Muchos documentos, no vienen con términos descriptivos, por lo que requieren humanos para generar palabras clave sobre la marcha. La necesidad de automatizar este tipo de tareas exige el desarrollo de sistemas de extracción de palabras clave con la capacidad de identificar automáticamente palabras clave dentro del texto. Uno de los enfoques es recurrir a algoritmos de aprendizaje automático. Estos, sin embargo, dependen de grandes corpus de texto anotado, que no siempre están disponibles. Una solución alternativa es considerar un enfoque no supervisado (Campos et al., 2019).

El problema de extraer palabras clave relevantes de los documentos es que son abundantes en datos, y las soluciones han demostrado ser de gran valor para una gran cantidad de tareas y escenarios incluidos: el resumen de texto, la agrupación en clústeres, la extracción de opiniones, la categorización, la expansión de consultas, la

recomendación, la información. Visualización, recuperación, indexación y bibliotecas digitales. Por lo general, las soluciones de palabras clave se dividen en uno de dos enfoques amplios: asignación de palabras clave y extracción de palabras clave. La asignación de palabras clave es una tarea de clasificación de texto de múltiples etiquetas que asigna un conjunto de palabras clave seleccionadas de un vocabulario controlado (diccionario o tesoro relevante para el dominio que se está discutiendo) a una instancia de datos (documentos). La extracción de palabras clave, por el contrario, implica la extracción de palabras clave de los propios documentos, siguiendo un enfoque no supervisado o supervisado (Campos et al., 2019).

En una era donde el volumen de documentos está aumentando en gran medida, el etiquetado humano de un conjunto de entrenamiento es una tarea laboriosa. Para superar este cuello de botella, los enfoques no supervisados, que van desde métodos estadísticos hasta enfoques basados en gráficos, han ganado importancia en los últimos años. Los enfoques supervisados se refieren a los algoritmos que trabajan con datos etiquetados, intentando encontrar una función que, dadas las variables de entrada, se les asigne la etiqueta de salida adecuada. El algoritmo se entrena con un histórico de datos y así aprende a asignar la etiqueta de salida adecuada a un nuevo valor, es decir, predice el valor de salida (Simeone, 2018). El método de referencia en los enfoques no supervisados es por ejemplo TF-IDF, que proviene de las siglas (del inglés *Term frequency – Inverse document frequency*), el cual se refiere a la frecuencia de un término en un documento con su frecuencia en una gran colección. La misma, es una medida estadística que evalúa qué tan relevante es una palabra para un documento en una colección de documentos. Esto se hace multiplicando dos métricas: cuántas veces aparece una palabra en un documento y la frecuencia inversa del documento de la palabra en un conjunto de documentos. Su principal característica, es la de calificar palabras en algoritmos de aprendizaje automático para el procesamiento del lenguaje natural. TF-IDF, se inventó para la búsqueda de documentos y la recuperación de información. Funciona, aumentando proporcionalmente al número de veces que aparece una palabra en un documento, pero se compensa con el número de documentos que contienen la palabra. Aunque bastante simple de implementar, TF-IDF requiere acceso a un gran corpus, que puede no estar siempre disponible. Para superar esta limitación, se han propuesto algunos enfoques alternativos. Uno de los primeros, fue presentado por El-Beltagy y Rafea, quienes propusieron *KP-Miner*, un sistema de extracción de palabras clave no supervisado que se

basa en la medida TF-IDF, y dos factores de impulso (longitud de la palabra y posición en el documento) para determinar la importancia de una palabra clave.

El NLP tiene más de 50 años de historia como disciplina científica, con aplicaciones en la educación desde la década de 1960 (Litman, 2016). El trabajo inicial, se centró en calificar automáticamente los textos de los estudiantes, así como en el desarrollo de sistemas de tutoría de diálogo basados en texto, mientras que el trabajo posterior también incluyó tecnologías del lenguaje hablado. Si bien, la investigación en estas áreas de aplicación tradicionales sigue progresando, los fenómenos recientes, como los macrodatos, las tecnologías móviles y las redes sociales, han dado como resultado la creación de muchas nuevas oportunidades y desafíos de investigación. Las aplicaciones comerciales ya incluyen evaluaciones de alto riesgo de texto y voz, asistentes de escritura y entornos de instrucción en línea, y las empresas se acercan cada vez más a la comunidad de investigación.

Los avances en NLP y la tecnología educativa, así como la disponibilidad de cantidades sin precedentes de datos de texto y voz relevantes, desde el punto de vista educativo, han llevado a un interés creciente en el uso del NLP para abordar las necesidades de profesores y estudiantes. Sin embargo, las aplicaciones educativas difieren en muchos aspectos de los tipos de aplicaciones para las que se desarrollan normalmente los sistemas de NLP.

En los últimos años, el NLP se ha convertido en el área de más rápida evolución en el aprendizaje profundo junto con la visión artificial. La arquitectura de *transformers* ha permitido desarrollar nuevos modelos capaces de ser entrenados en grandes corpus, siendo mucho mejores que las redes neuronales recurrentes. Los *transformers* son una clase reciente de redes neuronales para secuencias, basadas en la autoatención, que han demostrado estar bien adaptadas al texto y actualmente están impulsando importantes avances en el NLP (Vaswani et al., 2017). Estos modelos, se entrenan en grandes cuerpos de texto en tareas de aprendizaje no supervisadas. Como resultado, proporcionan excelentes extractores de funciones que pueden utilizarse para diversas tareas. Dada una oración, estos modelos generan una lista de vectores numéricos, uno para cada palabra o sub-palabra; estos vectores son una representación numérica del “significado” de cada palabra/sub-palabra. Estos nuevos modelos, se utilizan para la clasificación de secuencias,

la respuesta a preguntas, el modelado de lenguaje, el reconocimiento de entidades nombradas, el resumen o la traducción.

Los *transformers* están compuestos por un codificador y un decodificador. Se trata de codificar las entradas (es decir, oraciones) en un estado. Luego, el estado se pasa al decodificador para generar las salidas. En la traducción automática, el codificador transforma una oración fuente, por ejemplo, “Hola mundo”, en un estado, por ejemplo, un vector, que captura su información semántica. Luego, el decodificador usa este estado para generar la oración de destino traducida, por ejemplo, “Bonjour le monde”. El codificador y el decodificador tienen algunos submódulos, pero ambos utilizan principalmente la atención multicabezal y la red de avance.

En problemas de secuencia a secuencia, como la traducción automática neuronal, las propuestas iniciales, se basaron en el uso de RNN (Red Neuronal Recurrente) en una arquitectura de codificador-decodificador (Vaswani et al., 2017). Estas arquitecturas tienen una gran limitación a la hora de trabajar con secuencias largas, y que su capacidad de retener información de los primeros elementos se perdía cuando se incorporaban nuevos elementos a la secuencia. En el codificador, el estado oculto en cada paso, está asociado con una determinada palabra en la oración de entrada, generalmente una de las más recientes. Por lo tanto, si el decodificador solo accede al último estado oculto del decodificador, perderá información relevante sobre los primeros elementos de la secuencia. Luego, para hacer frente a esta limitación, se introdujo un nuevo concepto, el mecanismo de atención.

3. Estado del Arte

Varios estudios se han enfocado en aplicar diferentes técnicas y mecanismos para crear herramientas que ayuden a las personas a mejorar sus métodos de estudio (Burstein, 2009). Sin embargo, algunos estudios realizados, no cuentan con la combinación de las técnicas propuestas. Metodológicamente, algunos estudios aplican técnicas de procesamiento de lenguaje natural (NLP) y minería de texto para encontrar nuevos temas a partir de un texto base (Devlin et al., 2019). Estas propuestas se basan en un proceso similar, ya que se extraen características de los textos transcritos, o se clasifican las palabras clave del texto ingresado. Al mismo tiempo, algunos estudios utilizan el NLP y procesos de IA para mejorar los procesos de enseñanza y aprendizaje.

La extracción de palabras clave es la tarea más importante al trabajar con los datos de texto. La extracción de palabras clave beneficia al lector para juzgar la parte importante del texto, en lugar de revisar todo el texto. En este artículo, se analiza una técnica para extraer palabras clave de transcripciones de videos educativos de MOOC (Cursos online masivos y abiertos) (Shukla et al., 2016). El método, se basa en el enfoque de la regla gramatical de expresión regular para identificar los fragmentos de sustantivos en el texto de la transcripción. La extracción de palabras clave ayuda a descubrir la parte específicamente importante del material educativo. Para construir un índice de búsqueda para un video, la extracción de palabras clave juega un papel importante, ya que sirven como resumen de un documento; sin embargo, extraer palabras clave destacadas de las transcripciones de video es un problema desafiante. En los sistemas de recuperación de información, los métodos existentes para la extracción de palabras clave, involucran técnicas estadísticas como la frecuencia de términos, n-gramas. El sistema de extracción de palabras clave, tiene como objetivo extraer fragmentos de palabras que son útiles como palabras clave de recuperación de información. Las mismas, se pueden utilizar para una búsqueda eficiente. El sistema de extracción de palabras clave identifica un patrón particular en el texto basado en alguna regla gramatical llamada *Regex*. Esta combinación de patrones se denomina fragmentación. Esta sección revisa los intentos anteriores de extracción de palabras clave. En el estudio de Shukla, se realizó la tarea de extracción automática de palabras clave y extrajo palabras clave en tres grupos: palabras clave basadas en texto, basadas en bases de datos, y basadas en datos extraídos. Para la extracción basada en texto, se empleó un enfoque TF-IDF, para la extracción basada en

Regex: Regex (Expresiones Regulares) es una secuencia de caracteres que define un patrón de búsqueda utilizado para encontrar y manipular texto en cadenas de caracteres

base de datos emplearon información estadística específica de la base de datos junto con las puntuaciones TF-IDF, y para la extracción de texto, y base de datos combinaron la puntuación TF-IDF para texto y base de datos y se promedió.

A través del estudio de Zhang para videos educacionales (Zhang et al., 2019), se analiza el desarrollo de un algoritmo para la extracción automática de palabras clave, y presenta una serie de experimentos en los que se mejora gradualmente el rendimiento del algoritmo. El enfoque, que se adopta es el de aprendizaje automático supervisado, es decir, los modelos de predicción se construyen a partir de documentos con palabras clave conocidas. Antes de que pueda tener lugar cualquier aprendizaje, los datos deben ser preprocesados y representados. En la investigación, se abordan dos problemas relacionados con la representación para la extracción de palabras clave. Dado que una palabra clave puede constar de más de un *token*, el primer problema se refiere a dónde comienza y termina una palabra clave en un texto, es decir, cómo se define un término candidato. Se definen y evalúan tres enfoques de selección de términos. El primer enfoque extrae todos los uni, bi y trigramas, el segundo enfoque, extrae todos los fragmentos de frases, mientras que el tercer enfoque, extrae todos los términos que coinciden con cualquiera de una serie de patrones de parte del texto definidos empíricamente. Ya que la mayoría de los términos candidatos extraídos no son palabras clave, el segundo problema, se refiere a cómo se pueden limitar estos términos, para mantener solo aquellos que son apropiados como palabras clave. Se investigan, cuatro características para filtrar los términos candidatos. Estos son: la frecuencia del término, la frecuencia inversa del documento, la posición relativa de la primera aparición y la etiqueta, o etiquetas de parte del texto asignadas al término candidato. El resultado de las herramientas de NLP de esta investigación es un factor considerable, tanto para el preprocesamiento de los datos, como para el rendimiento de los modelos de predicción. El rendimiento más alto, se logra cuando se combinan las predicciones de los tres modelos.

Se presentan varios enfoques prácticos de la NLP, los mismos que ayudan en entornos educativos, y otros aspectos lingüísticos (Ferreira-Mello et al., 2019). Además, varias soluciones efectivas manejan patrones de gramática, y otros enfoques lingüísticos. Además, la NLP es una técnica efectiva para mejorar la capacidad de los estudiantes, tanto para identificar relaciones de diferentes palabras, así como para usarlas dentro de los motores de búsqueda en la generación de nuevos conocimientos (Campos, R et al.,

Token: Es una unidad individual de texto que se utiliza como base para el análisis y procesamiento de lenguaje natural. Puede ser una palabra, un número, un símbolo o incluso una combinación de ellos.

2019). Por lo tanto, una propuesta práctica, permite a los estudiantes utilizar estas herramientas de manera óptima. El procedimiento de búsqueda requiere ingresar la información correcta en el texto para ingresar al siguiente paso. La NLP posibilita el análisis de la información recopilada de los estudiantes, comparándola con el contenido dentro de la búsqueda realizada (Burstein, 2009).

Con base en el estudio del mecanismo de atención (Vaswani, A et al., 2017), se llevó a cabo una técnica denominada clasificación *zero-shot*, la misma que, asocia clases observadas y no observadas, a través de información auxiliar, que codifica las propiedades observables distintivas de los objetos, y detecta tipos que el modelo nunca ha visto durante el entrenamiento. Se caracteriza, por tener la capacidad humana de generalizar e identificar cosas nuevas sin supervisión directa.

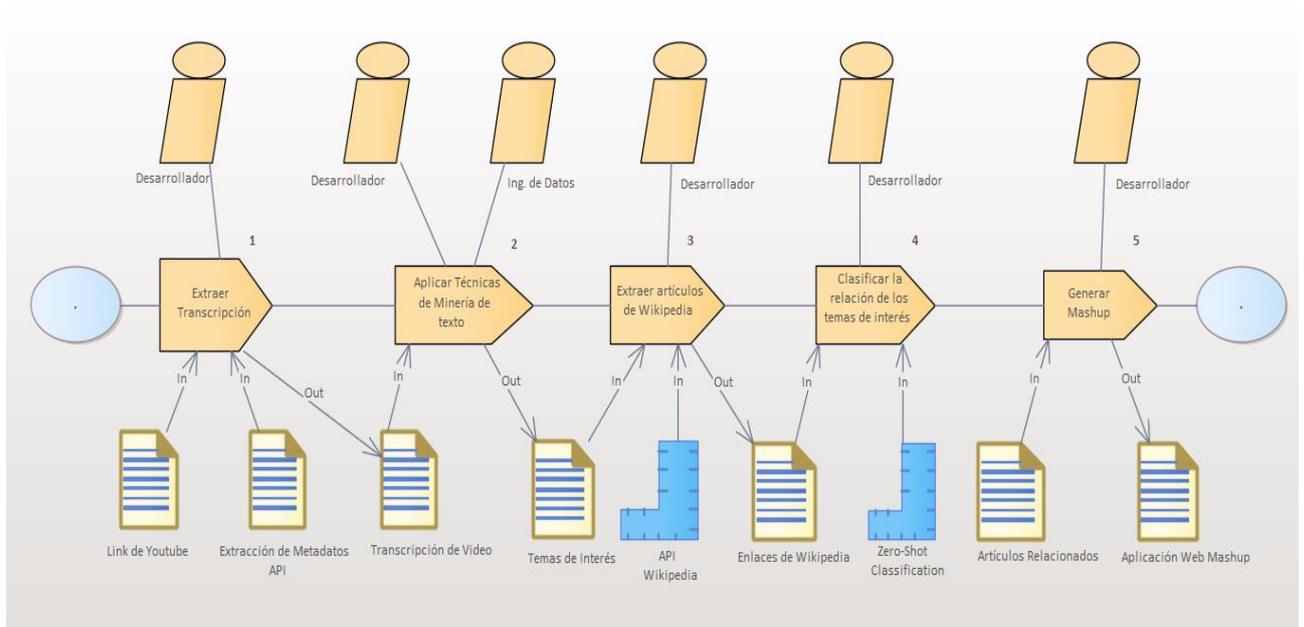
A diferencia de los estudios mencionados previamente, en donde, se utilizan diferentes técnicas de minería de texto y NLP como Yake! y TF-IDF para identificar palabras claves. El objetivo del presente estudio, es la extracción de las palabras clave de la transcripción de un video que se obtiene a través de APIs, y generar nuevos temas de aprendizaje relacionados al mismo anclándolos con enlaces hacia fuentes de información. A la vez, también se implementa un Mashup, en donde, se visualiza los distintos enlaces. Sin embargo, en los estudios relacionados, las técnicas que se utilizan no tienen como finalidad generar enlaces hacia nuevas fuentes de información, por lo que la propuesta, aplica técnicas recogidas de los estudios mencionados, las cuales se consolidan en un solo proceso para identificar temas relacionados a las palabras claves identificadas de la transcripción de un video, y generar enlaces hacia artículos de Wikipedia relacionados.

4. Metodología

Cada día, aumenta el volumen de información que se puede manejar a partir de transacciones, datos científicos, datos de sensores, imágenes, videos, etc. Por lo tanto, se requiere de un sistema, que sea capaz de extraer la esencia de la información disponible, y que pueda generar automáticamente informes, vistas o resumen de datos para mejorar la toma de decisiones.

Dentro de este estudio, se utiliza distintas técnicas de minería de texto y procesamiento de lenguaje natural, con las cuales, se encontrarán nuevos temas de interés a partir del texto de un video y sus respectivas fuentes. Se orquestará información de varias fuentes, y se las unirá dentro de un mismo proceso, para permitir al usuario realizar este proceso de manera directa y automática. Para la evaluación del proceso metodológico, se utilizan dos temáticas diferentes para analizar los resultados obtenidos, la primera se relaciona a videos de aprendizaje del área de informática, y la segunda será acerca de videos de aprendizaje de matemáticas. Estas temáticas, se escogieron en base a que son temas comunes y a la importancia en el ámbito de aprendizaje en la plataforma de YouTube. A continuación, se detalla las diferentes etapas que se utilizan para realizar la ejecución de los objetivos.

La metodología se representa se representa a través del Meta-Modelo 2.0 de Ingeniería de Procesos de Software y Sistemas (SPEM 2.0). El método, se dividió en cinco tareas principales: i) extracción de transcripción, ii) aplicar técnicas de minería de texto, iii) extraer artículos de Wikipedia, iv) clasificar la relación de los temas de interés y v) generación del Mashup.

Figura 1*Metodología SPEM**Figura 1. Metodología SPEM***4.1. Extraer Transcripción**

Como primera tarea, se selecciona los requerimientos y componentes para extraer la información necesaria y dar inicio al proceso. Estos componentes incluyen el enlace del video seleccionado de YouTube y las Plataformas API que permitan obtener el contenido y los metadatos del video.

El primer paso consiste en la transcripción de los videos, enfocándose en extraer el texto del video a través de una API de la plataforma correspondiente, como la API de YouTube. Los datos que se obtienen deben ser transformados en un documento para facilitar el procesamiento de la información. Una vez completado, se utilizan los datos disponibles para continuar con los siguientes pasos.

La API de la plataforma es utilizada para obtener toda la información necesaria que ayudará en las etapas posteriores del proceso. Este proceso se implementa utilizando el lenguaje de programación Python, y se requiere la instalación del módulo "youtube-

transcript-api". A continuación, se muestra un ejemplo de cómo obtener la transcripción del video seleccionado:

```
$pip install youtube_transcript_api
from youtube_transcript_api import YouTubeTranscriptApi as yta
YoutubeTranscriptApi.get_transcript(video_id)
```

El parámetro *video_id*, se refiere al link del video seleccionado de YouTube, cómo se mencionaba anteriormente, se utiliza cómo ejemplo, dos temáticas a ser evaluadas. Para la primera temática relacionada a la informática, se toma el video de “What is Programming?” del canal *Khan Academy*, que contiene 3.4 millones de visitas con el siguiente link: https://www.youtube.com/watch?v=FCMxA3m_Imc, La segunda temática, se toma el video de “*Factorising Algebraic Expressions*” del canal *Maths Explained*, que cuenta con 1.4 millones de visitas con el siguiente link: <https://www.youtube.com/watch?v=ctqviXu-mTE>.

Una vez que se obtiene la transcripción de los videos, se procede a almacenarla dentro de una variable, la cual, contiene la transcripción completa. A través de la extracción de la primera temática, se obtiene como primera frase de la transcripción: “*Hi, welcome to programming! If you’ve never learned to program before, you might be wondering what programming actually is...*”. En el caso de la segunda temática, se obtiene como primera frase de la transcripción lo siguiente: “*Hey guys in this video I’m going to talk about factorizing algebraic expressions so what is factorizing well that’s to break something into its factors...*”

Una vez que se juntan estos componentes, se obtiene la transcripción del video seleccionado, la cual es la base principal de todo el proceso. Ya que, a partir de esta transcripción se obtienen los temas relacionados al tema que se trata dentro del video.

4.2. Aplicar Técnicas de Minería de texto

Figura 2

Metodología SPEM técnicas de minería de texto

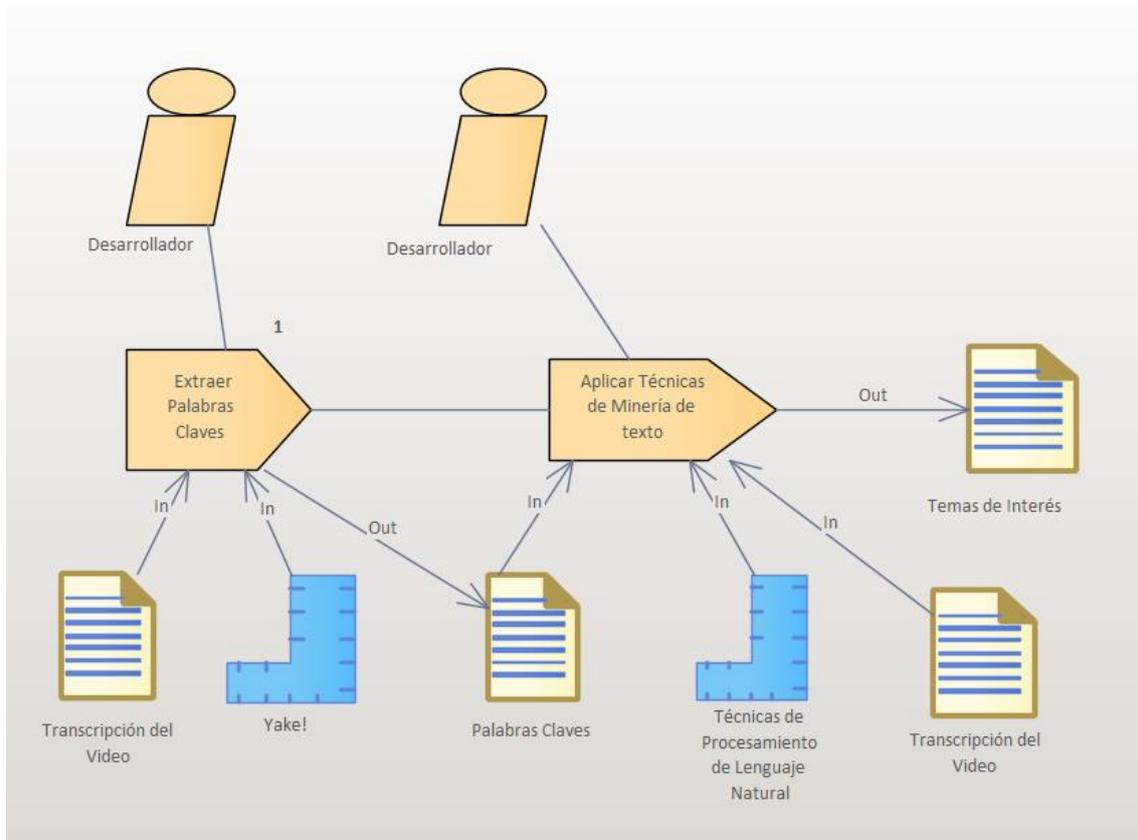


Figura 2. Metodología SPEM técnicas de minería de texto

4.2.1. Extraer palabras claves

En esta tarea, la entrada es la transcripción obtenida del video de la plataforma YouTube, que está habilitado en varias fuentes y recogerá el texto a analizar.

La extracción de palabras clave, es una técnica de análisis de texto que extrae automáticamente las palabras y expresiones más utilizadas e importantes de un texto. Ayuda a resumir el contenido, y reconocer los principales temas tratados dentro de un texto.

La extracción de palabras clave utiliza inteligencia artificial (IA) de aprendizaje automático, para desglosar el lenguaje humano para que las máquinas puedan entenderlo y analizarlo. Se utiliza para encontrar palabras clave de todo tipo de texto.

El texto transcrito, se utiliza para aplicar técnicas de minería de texto, tal es el caso de YAKE; el cual, busca conocimiento en varios temas que pueden ser de interés para los usuarios finales. Es decir, se extrae el texto transcrito del video seleccionado por el usuario, en donde se aplican las distintas técnicas de minería de texto descritas a continuación para obtener las palabras claves.

Pre-procesamiento

Para aplicar el modelo computacional, es necesario llevar a cabo varias tareas de pre-procesamiento con el fin de preparar los datos. Estas son fundamentales para preparar los datos de texto y maximizar la efectividad de la metodología y del modelo. Estas tareas incluyen:

Stopwords: Esta técnica reduce la dimensionalidad de los textos al eliminar palabras que no son útiles para el estudio. Por ejemplo, se usa para eliminar palabras de uso común (como “el”, “que”, “un”, “en”) a través de un motor de búsqueda que ha sido programado para ignorarlas, tanto al indexar entradas para la búsqueda como al recuperarlas como resultado. (Shukla, H et al., 2016)

Tokenización: Esta técnica consiste en construir una lista de tokens que no incluyen palabras prevalentes y poco informativas desde el punto de vista lingüístico, como conjunciones (y, o, ni, eso), preposiciones (a, en, para, entre otras) y verbos muy comunes. (Campos, R et al., 2020)

Palabras clave YAKE!: Es un método de extracción de palabras clave automático ligero y no supervisado, que se basa en las características estadísticas del texto extraído de documentos individuales, para seleccionar las palabras clave más importantes de un lector (Campos, R et al., 2019). Este sistema, no necesita ser entrenado con un conjunto particular de documentos, ni depende de diccionarios, corpus externo, tamaño de texto, idioma o dominio. Esta es la principal técnica, que se utiliza para extraer las palabras claves del texto de la transcripción.

Este proceso, se implementa a través de una librería de Python, la cual se instala y se implementa cómo se explica a continuación, en donde se utiliza la transcripción del video seleccionado.

```
$pip install git+https://github.com/LIAAD/yake
import yake
custom_kw_extractor = yake.KeywordExtractor(lan="en", n=2,
dedupLim=0.9, dedupFunc='seqm', windowsSize=1, top=10,
features=None)
keywords = custom_kw_extractor.extract_keywords(transcripcion)
```

Tabla 1

Componentes funcionales de Yake!

lan	Idioma del texto que se ingresa
n	Tamaño máximo de los N-gramas
dedupLim	Límite de duplicación de los datos
dedupFunc	Función de duplicación de los datos
windowsSize	Longitud de un recorte de una secuencia temporal de datos
top	Cantidad máxima de palabras a extraer.

Features	Características
-----------------	-----------------

Tabla 1. Componentes funcionales de Yake!

Tras realizar estos pasos, se obtienen las 10 palabras claves más relevantes de la transcripción del video, las cuales, se almacenan dentro de una variable para su uso en los siguientes pasos del proceso. Dentro de esta fase, se genera un conjunto de palabras clave y n-gramas principales. Estas palabras claves, son un indicio de toda la información que puede contener este corpus de texto, pero, se orientan sobre los aspectos en los que se tiene que profundizar o realizar procesos adicionales. Yake! ofrece una estadística numérica, que, pretende reflejar la importancia de una palabra en un documento. El valor de un término, aumenta proporcionalmente al número de veces que la palabra aparece dentro del documento, esto, ayuda a ajustar el hecho de que algunas palabras aparecen con más frecuencia en general. El resultado final, es una lista de palabras clasificadas según su importancia en la transcripción del video.

Siguiendo con las temáticas a evaluar, a través de la transcripción de la temática del video seleccionado de informática se obtienen las siguientes palabras claves en forma de un vector: [*'programming', 'program', 'programs', 'computer', 'Code', 'process', 'learn', 'languages', 'animations'*] y de la temática de matemáticas se obtienen las siguientes: [*'common factor', 'highest common', 'common divisor', 'algebraic expressions', 'factor analysis', 'lowest common factor', 'expression (mathematics)', 'factor solet', 'closed-form expression'*]. Estos vectores, contienen las palabras claves que se extraen de las transcripciones, y se almacenan dentro de una variable.

A través de la aplicación de las técnicas mencionadas, se identifica las palabras claves de la transcripción del video, las mismas que, son el resultado de esta tarea, y a la vez servirá como entrada para el proceso de extracción de artículos de Wikipedia.

4.3 Extraer artículos de Wikipedia

Una vez obtenidos los temas de interés, que tienen relación con el video, el siguiente paso, es asociarlos a los artículos de Wikipedia a través de la API que brinda esta enciclopedia virtual, la cual, se utiliza para obtener artículos asociados a los temas

de interés que fueron extraídos en los pasos anteriores, a través de su motor de búsqueda. A continuación, se muestra el procedimiento para realizar esta tarea:

```
$pip install wikipedia
import Wikipedia
for k in palabras_claves:
    x = wikipedia.search(str(k), results=4)
```

Utilizando las palabras claves obtenidas del video de la primera temática, se utiliza cada palabra, para buscar temas similares al tema ingresado en el buscador de Wikipedia a través de la API, con lo que se obtiene lo siguiente:

Temática informática:

```
Palabra Clave 1 programming: ['Computer programming', 'Program',
'Programming language', 'Code']
```

Temática matemáticas:

```
Palabra Clave 1 common factor: ['Greatest common divisor', 'Common
factors theory', 'Lowest common factor', 'Factor analysis']
```

Cómo se menciona anteriormente, las palabras claves, se encuentran almacenadas dentro de una variable, la cual, se utiliza dentro de la iteración que se muestra en el proceso previo para utilizarla junto a la API de Wikipedia, con el objetivo de buscar artículos de cada tema a través del motor de búsqueda de la enciclopedia y almacenar dentro de una variable, para su uso en los pasos posteriores.

4.4. Clasificar la relación de los temas de interés

La clasificación de textos, es una tarea de NLP donde el modelo necesita predecir las clases de los documentos de texto. Dentro del proceso tradicional, se requiere una gran cantidad de datos etiquetados, para entrenar el modelo, y tampoco pueden predecir usando los datos no vistos. El objetivo principal de cualquier modelo relacionado con la técnica de clasificación de texto de *Zero-shot*, es clasificar los documentos de texto, sin usar ningún dato etiquetado único, o sin haber visto ningún texto etiquetado. A continuación, se discute cómo se puede realizar una clasificación de texto de tipo *Zero-shot* utilizando Transformers cómo método para analizar los resultados.

A menudo, la clasificación de texto, se modela en un entorno supervisado, en donde se ha etiquetado datos de texto específico, y su etiqueta de la clase asociada. Por lo tanto, la clasificación de texto de *Zero-shot*, categoriza un fragmento de texto

determinado, en algún grupo predefinido, o etiqueta de clase sin entrenar explícitamente en un modelo de *Machine Learning* dedicado, en un conjunto de datos que contiene mapeo de etiquetas y texto.

El proyecto *Hugging Face*, proporciona el concepto de canalizaciones que facilitan la inferencia a partir de modelos ya entrenados, al abstraer la mayor parte del código complejo. Para esto, se utiliza el modelo subyacente (*facebook/bart-large-mnli*), que fue entrenado, a través de un modelo de Inferencia de Lenguaje Natural (NLI). “*facebook/bart-large-mnli*” ajusta el modelo BART en el corpus de inferencia de lenguaje natural multigénero (MNLI). El corpus, tiene cerca de 500k pares de oraciones anotadas con información de vinculación textual. NLI, es la tarea de determinar si dos secuencias, “premisa” e “hipótesis”, se implican, se contradicen, son indeterminadas (neutras), o no están relacionadas entre sí. Esto, se implementa con el objetivo de identificar, si los diferentes temas asociados que se obtienen como resultado se relacionan con la transcripción del video a través de una clasificación.

Yin et al. (2019), propuso un método para usar modelos NLI pre-entrenados como clasificadores de secuencia de *Zero-shot*. El método funciona planteando los temas relacionados a clasificar como premisa, y construyendo, una hipótesis a partir de cada etiqueta candidata (en este caso la transcripción). Por ejemplo, si se quiere evaluar si una secuencia pertenece a la temática “Matemáticas”, se construye una hipótesis de “Este texto es sobre matemáticas”. Las probabilidades de implicación y contradicción, se convierten luego en probabilidades de etiquetas de los temas relacionados. A continuación, se muestra la canalización, y la definición de tareas para obtener los resultados de la clasificación, un modelo que facilita la tarea.

```
from transformers import pipeline
classifier = pipeline (
    task="zero-shot-classification",
    model="facebook/bart-large-mnli",
    language="en"
)
```

Luego de encontrar y obtener las palabras claves de la transcripción del video, se utiliza la técnica de clasificación *zero-shot*, basada en el mecanismo de atención (Vaswani, A et al., 2017), la cual determina la efectividad de los resultados extraídos. De esta forma, se identifica la relación de los temas extraídos, a través de las palabras clave y de la API de Wikipedia con los temas que se tratan en el video principal que ingresa el usuario. Para la ejecución, se realiza el siguiente procedimiento:

```
from transformers import pipeline
classifier = pipeline("zero-shot-classification",
model="facebook/bart-large-mnli", language="en")
sequence1 = 20úsqueda20ción
candidate_labels = 20úsqueda_Wikipedia
hypothesis_template = 'This text is about {}.'
Confi = classifier (sequence1, candidate_labels,
hypothesis_template=hypothesis_template, multi_label=True)
```

El resultado de este proceso es una calificación que evalúa la relación de los artículos sugeridos de Wikipedia con la transcripción del video seleccionado. Esta calificación puede indicar la relevancia y la correspondencia entre el contenido del video y los artículos proporcionados como sugerencias de Wikipedia.

Se realiza este procedimiento con los artículos de Wikipedia extraídos de la primera temática, los cuales son: [*'Computer programming', 'Program', 'Programming language', 'Code'*] y de la segunda: [*'Greatest common divisor', 'Common factors theory', 'Lowest common factor', 'Factor analysis'*]. Con estos temas, a través de *Zero-shot*, se puede analizar mediante una calificación, y un puntaje qué tanto se relacionan los temas sugeridos con la temática del video.

Con las técnicas y procesos mencionados anteriormente, se obtienen los enlaces de los artículos relacionados con el video, estos, se asociarán con otras fuentes de información en la web a través de enlaces directos, y de esta manera se muestran los nuevos temas de interés.

4.5. Generar Mashup

Con los pasos anteriores, se realizó un proceso a través de varias tareas para extraer temas asociados con un video de YouTube que eligió el usuario. La transcripción

del texto del video, se insertó como primer parámetro, con el cuál, a través de las distintas técnicas de minería de texto y NLP explicadas previamente, se crea un flujo que, se implementará a través de un Mashup. El mismo, tiene como objetivo, mostrar al usuario todos los temas nuevos y sugeridos que puedan ser de su interés según el video que ingrese, direccionándolo a enlaces hacia artículos en la web; allí, se encontrará más información sobre estos temas recomendados.

Para la implementación de este proceso, se utiliza *Django*, el cuál es un *Framework* de alto nivel, que permite el desarrollo rápido de sitios web. A través de esta herramienta, se implementó una interfaz gráfica, en donde, se puede introducir el URL del video de YouTube seleccionado, para obtener los diferentes artículos con temas relacionados al mismo. A continuación, se muestra la interfaz gráfica del Mashup, donde se puede apreciar el cuadro donde se inserta el link del video de YouTube.

Figura 3

Página de inicio y campo de texto del enlace de YouTube.



Figura 3. Página de inicio y campo de texto del enlace de YouTube.

A continuación, se muestra el resultado que se obtiene luego de ingresar el URL del video, con uno de los temas relacionados, y los distintos subtemas con enlaces directos hacia artículos de Wikipedia para complementar los temas de estudio.

Video temática informática:

```
Programming: 'Computer programming', 'Program', 'Programming language', 'Code'
```

Video temática matemáticas:

```
Common Factor: 'Greatest common divisor', 'Common factors theory',
'Lowest common factor', 'Factor analysis'
```

Finalmente, se dirige automáticamente al artículo de Wikipedia seleccionado y de esta manera el proceso finaliza, entregando distintos artículos que se relacionan al video principal.

5. Resultados

Una vez que se aplica el proceso metodológico, se obtienen diferentes enlaces hacia artículos de Wikipedia que se relacionan con la temática del video seleccionado. Basándose en los resultados obtenidos a través de la experimentación de este proceso, se analizan los mismos, para clasificarlos según qué tan significativos y relacionados son con el video principal, para ello, se utilizar la técnica de clasificación *Zero-shot*.

Cuando el clasificador está listo, se envía la transcripción, y los temas relacionados que se obtienen para la variable de la premisa, las etiquetas candidatas y la elección de predicción multiclase o no. De esta manera, se obtiene una clasificación con un puntaje sobre el 100% de la precisión cada tema, lo que quiere decir que si el puntaje se acerca más al 100%, el tema clasificado tendrá más relación al video seleccionado.

```
transcripcion = transcripcion_video
labels = temas_relacionados[]
predictions = classifier(transcripcion, labels, multi_class=True)
print(predictions)
```

Video temática informática:

```
['Computer programming': 0.9941139221191406, 'Program':
0.9747389554977417, 'Programming language': 0.9262308478355408, 'Code':
0.7655550241470337]
```

Figura 4

Gráfico de Resultados Temática Informática

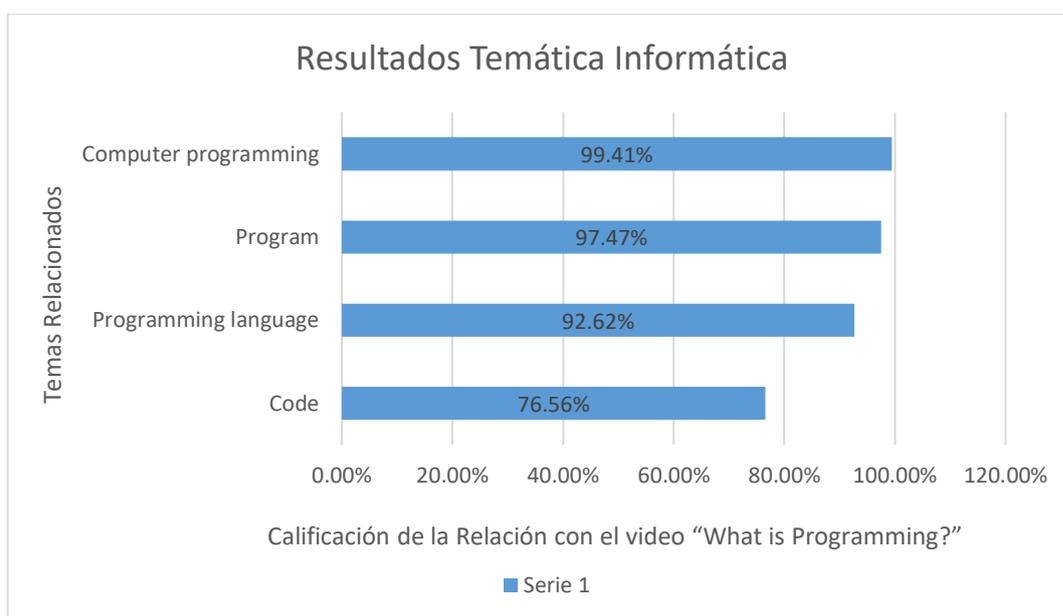


Figura 4. Gráfico de Resultados Temática Informática

Como se observa en la Figura 4, se analizan cuatro temáticas diferentes: *Computer Programming*, *Program*, *Programming Language* y *Code*. Se clasifican por orden de mayor relación al video analizado de "What is Programming". El tema con mayor puntuación es *Computer Programming*, el cual, obtuvo una calificación de 99.41% de relación, lo que implica que tiene un vínculo muy fuerte con la temática del video principal, le siguen las dos temáticas *Program* y *Programming Language*, que tienen 97.47% y 92.62% de relación respectivamente, esto da a lugar que también son temáticas que se relacionan directamente a lo explicado en el video. Por último, está el tema *Code*, que obtuvo una calificación de 76.56%. La misma que indica que este tema no comparte una relación tan relevante con el video, cómo los anteriores. A través de estos resultados, se puede determinar, que artículos son los más relevantes y asociados para el video seleccionado. De esta manera, con estos resultados, se puede trasladar hacia el *Mashup*

los temas con más relación al video, y en forma de un enlace directo hacia cada artículo de Wikipedia como se presenta a continuación:

Figura 5

Resultado Temática Informática dentro del Mashup

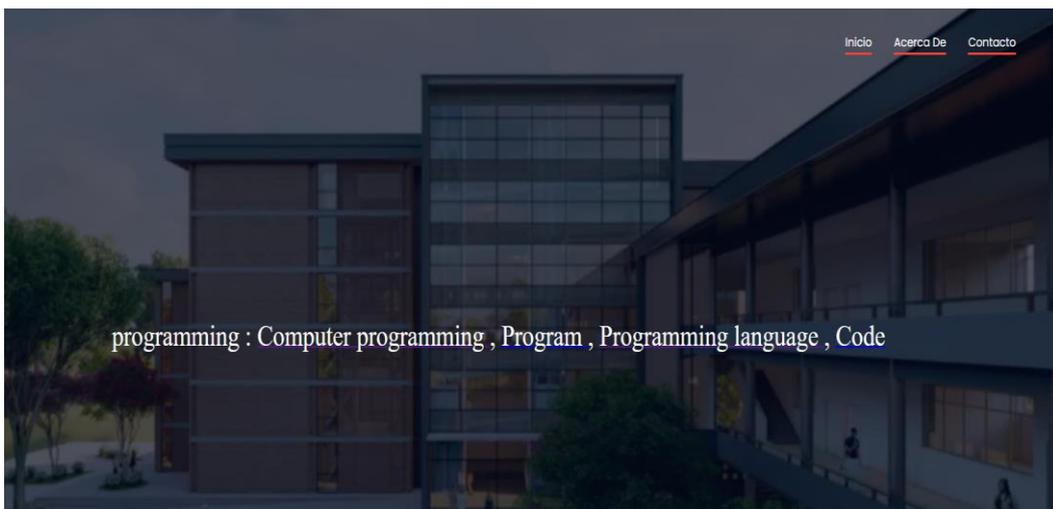


Figura 5. Resultado Temática Informática dentro del Mashup

Video temática matemáticas:

[‘Common factors theory’: 0.9795864820480347, ‘Greatest common divisor’: 0.9723048210144043, ‘Lowest common factor’: 0.9449946284294128, ‘Factor analysis’: 0.9107250571250916]

Figura 6

Gráfico de Resultados de la temática de matemáticas

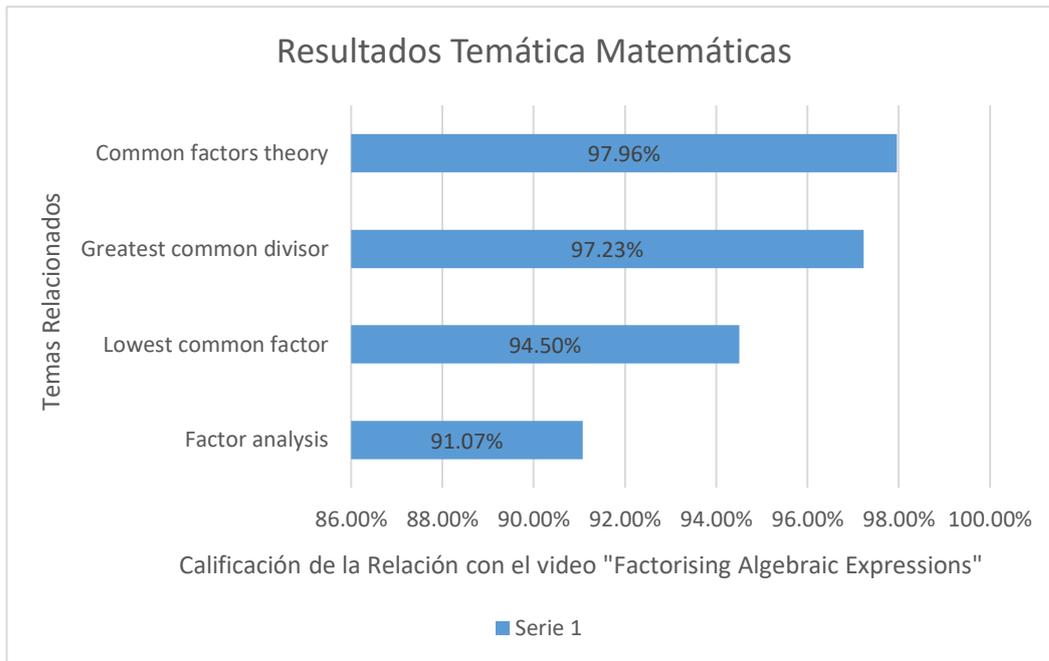


Figura 6. Gráfico de Resultados de la temática de matemáticas

En la Figura 6, se analizan cuatro temáticas diferentes: *Common Factors Theory*, *Greatest Common Divisor*, *Lowest Common Factor* y *Factor Analysis*. De igual manera, se clasifican por orden de mayor relación al video analizado de “*Factorising Algebraic Expressions*”. El tema con mayor puntuación es *Common Factors Theory*, obteniéndose una calificación de 97.96% de relación, lo que quiere decir que, este tema tiene un vínculo muy fuerte con la temática del video principal, le siguen las dos temáticas *Greatest Common Divisor* y *Lowest Common Factor*, las cuales tienen 97.23% y 94.50% de relación respectivamente, lo que significa que también son temáticas que se relacionan directamente a lo explicado en el video. Por último, está el tema *Factor Analysis*, este recibió una calificación de 91.70% de relación, esta calificación da a lugar que este tema comparte relación con el video de igual forma que los anteriores temas, sin embargo, es el de menor relación de los temas analizados. A través de estos resultados, se determina que los artículos son los más relevantes y asociados para el video seleccionado, los cuales se visualizan como parte del *Mashup*, como indica la Figura 7.

Figura 7

Resultados de temática de matemáticas dentro del Mashup

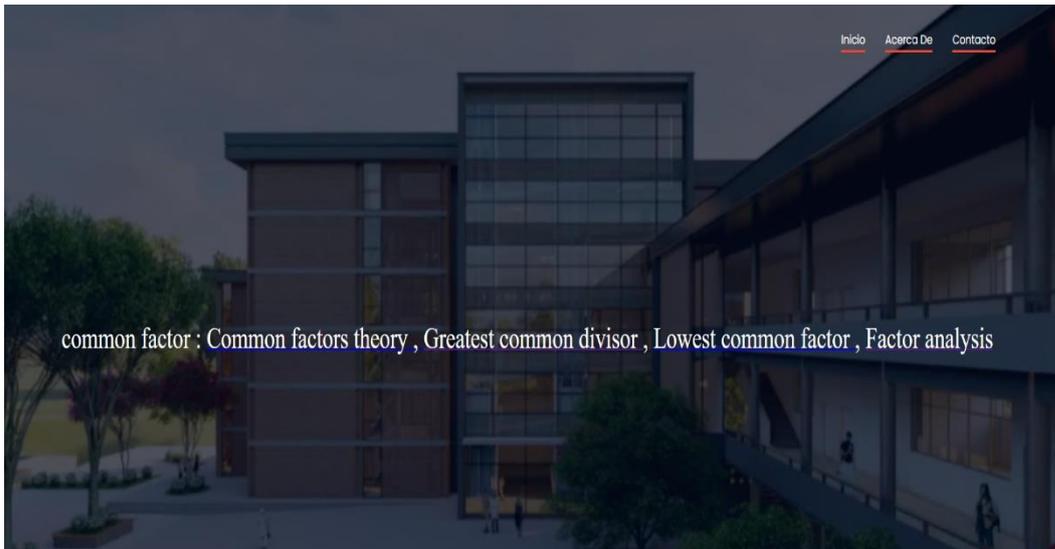


Figura 7. Resultados de temática de matemáticas dentro del Mashup

Como se observa en las figuras anteriores, el modelo da a conocer los diferentes temas relacionados en torno al tema central del que se transcribe en los videos. La formulación de esta clasificación se adapta a la técnica de texto de *Zero-shot* al tratar la transcripción del video y las etiquetas candidatas de los temas relacionados como premisa e hipótesis, respectivamente. A través del modelo utilizado, se comprende las relaciones de dos piezas de texto (transcripción y temas relacionados). Este conocimiento, se utiliza para determinar, si alguna etiqueta del conjunto de candidatos de los temas relacionados se implica o se relaciona al tema principal del video. Si es así, se etiqueta a los temas y artículos relacionados, como las etiquetas de relación verdaderas.

La técnica de *Zero-shot Classification*, ofrece un enfoque adecuado cuando los datos de entrenamiento son limitados (o incluso inexistentes), o como punto de referencia fácil de implementar para métodos más sofisticados. Así como se realiza en diferentes estudios analizados en el estado del arte. Aunque los enfoques y métodos para datos explícitos, como el ajuste de grandes modelos preentrenados, siguen superando a los enfoques implícitos, como en este caso, pero el aprendizaje de *Zero-shot Classification* y su aplicabilidad universal hace muy atractivo utilizar esta opción para modelos no entrenados.

Sin embargo, cabe esperar que *Zero-shot Classification*, en general, adquiera mayor uso y utilidad por la existencia de datos limitantes de entrenamiento en varios campos para el NLP. Esto se debe, a que la forma en que se utilizan los modelos para

resolver tareas evolucionará con la creciente importancia de los grandes modelos preentrenados existentes. Por lo tanto, la técnica de *Zero-shot* dentro de este estudio fue fundamental para llegar a los objetivos y obtener los resultados deseados.

6. Evaluación

En este capítulo, se presenta la evaluación de los resultados de la metodología propuesta a través de un modelo de aceptación tecnológica (TAM, por sus siglas en inglés). El TAM, es una teoría que se utiliza para explicar cómo los usuarios adoptan y utilizan tecnologías en sus vidas diarias (Davis, 1989). En este estudio, se utiliza el modelo descrito para evaluar la aceptación de los resultados de la metodología propuesta. El modelo TAM, que se utiliza se basa en tres constructos principales: la percepción de utilidad, la percepción de facilidad de uso y la actitud hacia el uso. La percepción de utilidad se refiere a la creencia del usuario de que el uso de los resultados mejorará su desempeño en sus actividades, la percepción de facilidad de uso, se refiere a la creencia del usuario de que el uso de los resultados de la metodología es fácil de comprender y sin esfuerzo, y la actitud del uso, para saber cuál es la predisposición de la adopción y uso de los resultados de la metodología.

El objetivo de este capítulo, es evaluar la aceptación de los resultados de la metodología propuesta para identificar temas relacionados de un video de YouTube a través de la implementación y experimentación de varias técnicas, métodos de minería de texto y NLP.

Para lograr este objetivo, se utiliza el TAM, y se miden las percepciones de utilidad, de facilidad de uso y de la actitud hacia el uso de los resultados de la metodología, mediante un cuestionario basado en la escala de Likert de cinco puntos.

6.1 Goal Question Metric

A través del Goal Question Metric (Basili & Weiss, 1984), se comprueba la eficacia, y la aceptación de los resultados de la metodología propuesta en la identificación de temas relacionados a un video de YouTube, el mismo que incluye la implementación y experimentación de varias técnicas y métodos de minería de texto y NLP.

Para lograr este objetivo, se realiza un estudio de caso en el que se aplica la metodología propuesta. Se selecciona un video de YouTube del área de aprendizaje de matemáticas, y se utiliza la metodología para extraer los temas relacionados. La evaluación de la eficacia, y la aceptación de la metodología, se realiza mediante la

Escala de Likert: La escala de Likert es un método de medición que utiliza una serie de afirmaciones y una escala de opciones para evaluar el grado de acuerdo o desacuerdo de las personas en relación con esas afirmaciones. Se utiliza para obtener datos cuantitativos sobre actitudes u opiniones.

revisión manual de los resultados, y una encuesta a un grupo de personas con experticia en diferentes áreas.

Se utiliza la plantilla de Goal Question Metric, para definir los objetivos del caso de estudio a través de la siguiente tabla.

Evaluar	¿Qué es lo que se estudia?
Con el propósito de	¿Qué intención tiene el estudio?
Con respecto	¿Qué efecto se estudia?
Desde el punto de vista de	¿Quién se ve afectado?, se refiere al grupo de estudio
En el contexto de	¿Dónde, cómo y por quién se lleva a cabo el estudio?

Para este estudio, se evalúan las distintas variables para los resultados de aplicar la metodología, para identificar temas relacionados de un video de YouTube a través de la implementación y experimentación de varias técnicas, métodos de minería de texto y NLP.

Evaluar	El resultado de aplicar la metodología para identificar temas relacionados de un video del área de matemáticas en YouTube a través de la implementación y experimentación de varias técnicas y métodos de minería de texto y NLP.
Con el propósito de	Evaluar la validez de los resultados obtenidos del método
Con respecto	Temas relacionados que se obtienen sobre un video del área de matemáticas
Desde el punto de vista de	Ingeniero de Sistemas y Ciencia de Datos
En el contexto de	Investigadores del laboratorio LIDI de la Universidad del Azuay

6.2 Modelo de aceptación tecnológica (TAM):

Para evaluar la aceptación de los resultados de la metodología propuesta, se utiliza el modelo de aceptación tecnológica (TAM) descrito anteriormente. Se definen las variables de percepción de utilidad, percepción de facilidad de uso y actitud hacia el uso, y se establecen las hipótesis correspondientes (Verma et al., 2018). Para evaluar estas variables, se utilizan encuestas a un grupo de personas con experiencia en el área de ciencia de datos. La encuesta, incluye preguntas sobre la eficacia de los resultados de la metodología, la precisión de los resultados, la facilidad de implementación, y la simplicidad de la interfaz de usuario, en donde, se utiliza una escala de Likert de cinco puntos, la misma que en el indicador uno, se refiere a "Totalmente en desacuerdo", y cinco "Totalmente de acuerdo".

6.2.1. Definición de variables

Para evaluar la percepción de utilidad, se pueden definir dos variables: la eficacia de los resultados, metodología para encontrar temas relacionados, y la precisión de los resultados obtenidos. Para evaluar la percepción de facilidad de uso, se definen de igual forma dos variables: la facilidad de uso de los resultados, y la simplicidad del uso los resultados. Por último, para evaluar la actitud hacia el uso se integran dos variables adicionales:

- Percepción de utilidad:
 - Eficacia de los resultados de la metodología para encontrar temas relacionados de un video de YouTube.
 - Impacto en la productividad, o eficiencia con los resultados de la metodología.
- Percepción de facilidad de uso:
 - Los resultados de la metodología son fáciles de entender y utilizar.
 - Simplicidad en llegar a los resultados de la metodología.
- Actitud hacia el uso:
 - Aceptación de los resultados de la metodología.

- Intención de uso continuo.

6.2.2. Hipótesis

- **H₁**: La percepción de utilidad de los resultados de la metodología es adecuada en la productividad o eficiencia a la hora de encontrar temas relacionados a partir de un video de YouTube.
- **H₂**: Los resultados de la metodología son fáciles de entender y utilizar, lo que permite adaptarse a su funcionamiento y aprovechar sus funcionalidades sin dificultad.
- **H₃**: Los resultados de la metodología denotan un valor significativo para usuario al momento de utilizarlos, lo que genera confianza en su funcionamiento.

A continuación, en la Tabla 2, se observan los ítems con las respectivas declaraciones y preguntas que se plantearon para medir las variables de percepción de utilidad, percepción de facilidad de uso, y de la actitud hacia el uso de los resultados de la metodología.

Tabla 2

Cuestionario para la medición de variables con TAM

Constructo	Ítem	Declaración Positiva
Utilidad percibida de los resultados de la metodología (PU)	PU1	Los resultados de la metodología logran una eficacia cuando se buscan temas relacionados a un video de YouTube.
	PU2	Encuentra que los resultados obtenidos a través de la metodología son útiles y relevantes a la necesidad del caso de estudio.
	PU3	Se optimiza su tiempo productivo y se mejora la eficiencia (menos tiempo) al

		utilizar los resultados de la metodología.
Facilidad de uso percibida de los resultados de la metodología (PEU)	PEU1	Los resultados de la metodología son fáciles de entender y utilizar, lo que permite adaptarse rápidamente a su funcionamiento y aprovechar sus funcionalidades sin dificultad.
	PEU2	Se percibe que se alcanzan los resultados deseados fácilmente, es decir, no se requieren pasos complejos o procesos largos.
Actitud hacia el uso de los resultados de la metodología (ATT)	ATT1	La actitud hacia el uso de resultados es favorable, se reconocen los beneficios en su trabajo o en sus actividades diarias.
	ATT2	La actitud hacia el problema es entusiasta, es decir, se confía en los resultados obtenidos, y se tienen la intención de utilizarlo de forma continua en el futuro.

Tabla 2. Cuestionario para la medición de variables con TAM

6.2.3 Ejecución

Para que la evaluación se lleve con éxito, como primer paso, a los expertos se presenta una introducción de la metodología usada, y la forma de uso del *Mashup* para generar los resultados. A continuación, se realiza la demostración e interacción con cada uno de los expertos, los cuales, en base a los resultados obtenidos realizan la encuesta proporcionada.

6.3 Análisis e interpretación de los datos recolectados

A continuación, se presentan los resultados obtenidos a través de la encuesta aplicada a los expertos (Anexo 1). Se analizan los valores mínimos, máximos y medias de las variables de la encuesta, así como la confiabilidad de la escala mediante el coeficiente Alpha de Cronbach y finalmente se evalúa la validación de las hipótesis planteadas.

6.3.1 Resultados de la Encuesta

La encuesta tiene siete preguntas que evalúan: la percepción de uso, la percepción de utilidad y la actitud hacia el uso de los participantes con respecto a los resultados de la metodología propuesta. Las respuestas se estructuraron mediante en una escala de Likert de uno a cinco, donde uno representa "Totalmente en desacuerdo" y cinco representa "Totalmente de acuerdo" (Anexo 2). A continuación, se presentan los valores mínimos, máximos y medias de las respuestas a cada una de las preguntas en la Tabla 3.

Tabla 3

Estadística descriptiva de los resultados obtenidos para cada variable

Variab les	Min	Max	Media
PU	3	5	4.16
PEU	4	5	4.5
ATT	2	5	4.13

Tabla 3. Estadística descriptiva de los resultados obtenidos para cada variable

A través de los resultados obtenidos en la encuesta, se utiliza el coeficiente de alfa de Cronbach, para evaluar la confiabilidad interna del cuestionario y sus resultados. Se indica la consistencia y la correlación entre los ítems que miden cada variable para evaluar su validez (Cronbach, 1951).

El coeficiente de alfa de Cronbach varía de cero a uno. Cuanto mayor sea el valor, mayor será la confiabilidad interna de los ítems.

- 0.90 o superior: Excelente confiabilidad. Los ítems están altamente correlacionados y miden de manera consistente la variable.

- 0.80 a 0.89: Buena confiabilidad. Los ítems están correlacionados moderadamente y miden la variable de manera consistente.
- 0.70 a 0.79: Aceptable confiabilidad. Los ítems están correlacionados de manera moderada y miden la variable de manera aceptable.
- 0.60 a 0.69: Confiable en ciertas circunstancias. Los ítems están correlacionados débilmente y miden la variable de manera moderada.
- Inferior a 0.60: Baja confiabilidad. Los ítems están débilmente correlacionados y no miden la variable de manera consistente.

En este estudio, el coeficiente Alpha de Cronbach para las respuestas de la encuesta es de 0.85. Este valor indica una consistencia interna sólida de las variables y las respuestas, lo que sugiere que, la escala utilizada es confiable para medir las percepciones, y actitud hacia el uso de los resultados de la metodología.

6.4 Validación de las Hipótesis

A continuación, se evalúa la validación de las hipótesis planteadas en el estudio a través de los resultados obtenidos.

H1: La percepción de utilidad de los resultados de la metodología es adecuada en la productividad o eficiencia a la hora de encontrar temas relacionados a partir de un video de YouTube.

Para validar esta hipótesis, se puede examinar el valor promedio obtenido para la variable relacionada con la percepción de utilidad de los resultados (PU), la cual es de 4.16. Esto indica que, los participantes consideran que los resultados son útiles en términos de productividad o eficiencia. Por lo tanto, se puede concluir que, esta hipótesis se valida, ya que los resultados indican una percepción adecuada de utilidad en la productividad o eficiencia, respaldada por una escala confiable.

H2: Los resultados de la metodología son fáciles de entender y utilizar, lo que permite adaptarse a su funcionamiento y aprovechar sus funcionalidades sin dificultad.

Para aceptar esta hipótesis, se observa el valor promedio obtenido para la variable relacionada con la percepción de facilidad de uso de los resultados (PEU), que es de 4.5. Esto corresponde a que los participantes consideran que, los resultados son fáciles de comprender y utilizar. En consecuencia, se concluye que esta hipótesis se valida, ya que

los resultados indican una percepción favorable de facilidad en la comprensión y uso de los resultados.

H3: Los resultados de la metodología denotan un valor significativo para el usuario al momento de utilizarlos, lo que genera confianza en su funcionamiento.

Para validar esta hipótesis, se observa el valor promedio de la variable relacionada con la actitud hacia el uso (ATT), y su influencia en la generación de confianza. El valor promedio es de 4.13. Lo que indica que los participantes perciben un valor significativo en los resultados, y que esto otorga confianza en el funcionamiento de la metodología.

En resumen, los resultados promedio de las preguntas de la encuesta respaldan las hipótesis planteadas, indicando que los participantes perciben utilidad, facilidad y valor significativo en los resultados de la metodología propuesta. Además, el coeficiente Alpha de Cronbach de 0.85, confirma la confiabilidad de la escala utilizada en la encuesta. Estos hallazgos, respaldan la validez de las hipótesis planteadas y sugieren que los resultados de la metodología propuesta son percibidos positivamente por los participantes.

6.5 Amenazas a la validez

6.5.1 Validez de conclusión

Durante la realización de este estudio, se identifica que la validez de los resultados podía verse amenazada por diversos factores, siendo el tamaño y la selección de la muestra los principales. Para evitar que esto ocurra, se llevó a cabo un proceso de revisión y análisis interno por parte de investigadores expertos en el tema, quienes han examinado y validado los resultados y conclusiones obtenidos. Este proceso de revisión por pares contribuye a asegurar la precisión y validez de las conclusiones al contar con una evaluación crítica y objetiva de los resultados.

6.5.2 Validez interna

En lo que respecta a la validez interna de este estudio, se identificó que una de las principales amenazas para llevarlo a cabo de manera efectiva, es la posibilidad de que el evaluado cuente con conocimientos previos sobre la temática que se estudia. Los conocimientos previos pueden influir en la forma en que la persona aborda y responde a las preguntas, lo que puede comprometer la validez de los resultados.

Para atenuar la amenaza, se toma la decisión de seleccionar investigadores altamente capacitados en ciencias de datos y que se desenvuelven profesionalmente en esta misma área. De esta manera, se aseguró que los evaluadores tuvieran una amplia experiencia y conocimientos especializados en el tema que se iba a investigar, lo que les permite realizar una evaluación objetiva y rigurosa, sin la influencia de prejuicios o conocimientos previos.

6.5.3 Validez de constructo

En cuanto a la validez del constructo, se identifica que una de las amenazas que podrían afectar la misma, está relacionada con la validez de la encuesta utilizada en el estudio. Es común que las encuestas presenten limitaciones en cuanto a su capacidad, para medir de manera precisa y objetiva los constructos que se están investigando, lo que puede comprometer la validez de los resultados. Por lo que adopta una estrategia que, consiste en realizar una validación de la encuesta con un profesional experto en temas de ciencia de los datos. De esta manera, se aseguró que la encuesta utilizada tuviera la validez correspondiente y evalué de manera precisa, y objetiva los constructos que se están investigando.

De igual manera, en este estudio el coeficiente Alpha de Cronbach obtenido de 0.85, indica una consistencia interna y validez sólida en la escala utilizada en la encuesta. Esto indica que las preguntas de la encuesta miden de manera consistente el constructo teórico que se pretende evaluar, es decir, la percepción de los participantes hacia los resultados de la metodología propuesta.

En definitiva, la validación de la encuesta fue una medida crucial para asegurar la validez del constructo en este estudio, y garantizar la calidad de los resultados obtenidos. De esta manera, se espera que los resultados obtenidos sean confiables y representen de manera fiel la realidad que se está investigando.

6.5.2 Validez externa

En cuanto a la validez externa, se identificó que una de las posibles amenazas en este estudio estaba relacionada con la selección de los participantes, ya que estos fueron seleccionados a conveniencia, y no de manera aleatoria. Este tipo de selección puede

limitar la generalización de los resultados obtenidos, ya que los participantes pueden no representar de manera adecuada la población objetivo del estudio.

Sin embargo, se debe destacar que la selección de los participantes en este estudio se realizó de manera cuidadosa y estratégica. Se seleccionaron participantes, con un amplio entendimiento en el área de ciencia de datos. De esta manera, se buscó garantizar que los participantes tuvieran la experiencia y conocimientos necesarios para realizar una evaluación rigurosa y objetiva de los datos, lo que permite obtener resultados confiables y representativos de la realidad que se está investigando.

7. Conclusiones

Dentro de este estudio, se llevó a cabo un proceso para identificar temas relacionados de un video de YouTube a través de la implementación y experimentación de varias técnicas y métodos de minería de texto y NLP, en este caso, principalmente YAKE! Y *Zero-Shot Classification*. Estas técnicas, se aplicaron dentro de dos temáticas diferentes para analizar los resultados obtenidos, la primera acerca de videos de aprendizaje del área de informática, y la segunda acerca de videos de aprendizaje de matemáticas, en donde se evaluó el proceso en ambos casos.

De acuerdo con los resultados obtenidos, usando la técnica YAKE! a través de los datos extraídos, se obtuvieron los diferentes temas principales de las transcripciones analizadas. Así mismo, el NLP es fundamental a la hora de determinar los temas que se obtienen como resultado final del estudio y en que medida los mismos se relacionan con el video. Se utiliza la técnica de *Zero-shot Classification*, a través de un puntaje para calificar los distintos temas relacionados, e identificar si son acordes al video principal. Una vez que se determinan los temas relacionados, estos pueden ser visualizados a través de la generación de un *Mashup*, el cuál, presenta las temáticas en forma de enlaces directos hacia artículos de Wikipedia. Finalmente, en base a los resultados obtenidos, se concluye que, a través de la aplicación de técnicas y métodos de minería de texto, NLP, y la generación de un *Mashup* para combinar lo mencionado anteriormente, se puede llegar a los objetivos planteados en este estudio, que consistió en la generación de temas relacionados de un video de YouTube, con sus enlaces directos hacia otras fuentes de información acerca de los distintos temas obtenidos.

8. REFERENCIAS

- Belleau, F., Nolin, M. A., Tourigny, N., Rigault, P., & Morissette, J. (2008). Bio2RDF: Towards a mashup to build bioinformatics knowledge systems. *Journal of Biomedical Informatics*, 41(5), 706–716. <https://doi.org/10.1016/j.jbi.2008.03.004>
- Burstein, J. (2009). Opportunities for natural language processing research in education. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 5449 LNCS, 6–27. https://doi.org/10.1007/978-3-642-00382-0_2
- Campos, R., Mangaravite, V., Pasquali, A., Jorge, A., Nunes, C., & Jatowt, A. (2020). YAKE! Keyword extraction from single documents using multiple local features. *Information Sciences*, 509, 257–289. <https://doi.org/10.1016/j.ins.2019.09.013>
- Chalkidis, I., Fergadiotis, M., Kotitsas, S., Malakasiotis, P., Aletras, N., & Androutsopoulos, I. (2020). An empirical study on large-scale multi-label text classification including few and zero-shot labels. *EMNLP 2020 - 2020 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, 7503–7515. <https://doi.org/10.18653/v1/2020.emnlp-main.607>
- Chary, M., Parikh, S., Manini, A. F., Boyer, E. W., & Radeos, M. (2019). A review of natural language processing in medical education. *Western Journal of Emergency Medicine*, 20(1), 78–86. <https://doi.org/10.5811/westjem.2018.11.39725>
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL HLT 2019 - 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies - Proceedings of the Conference*, 1(Mlm), 4171–4186.
- Ennals, R., & Gay, D. (2007). User-friendly functional programming for web mashups. *ACM SIGPLAN Notices*, 42(9), 223–233. <https://doi.org/10.1145/1291220.1291187>
- Ferreira-Mello, R., André, M., Pinheiro, A., Costa, E., & Romero, C. (2019). Text mining in education. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(6). <https://doi.org/10.1002/widm.1332>
- Ghiani, G., Paternò, F., Spano, L. D., & Pintori, G. (2016). An environment for End-User Development of Web mashups. *International Journal of Human Computer Studies*, 87, 38–64. <https://doi.org/10.1016/j.ijhcs.2015.10.008>
- Grammel, L., & Storey, M. A. (2010). A survey of mashup development environments. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 6400, 137–151. https://doi.org/10.1007/978-3-642-16599-3_10
- Grobelnik, M., Mladenic, D., & Jermol, M. (2002). Exploiting text mining in publishing and education. *ICML-2002 Workshop on Data Mining Lessons Learned*, 34–39. <http://www.gzs.si/eng/index.htm%0Ahttps://www.researchgate.net/publication/237590193>

- Karami, A., White, C. N., Ford, K., Swan, S., & Yildiz Spinel, M. (2020). Unwanted advances in higher education: Uncovering sexual harassment experiences in academia with text mining. *Information Processing and Management*, 57(2), 102167. <https://doi.org/10.1016/j.ipm.2019.102167>
- Litman, D. (2016). Natural language processing for enhancing teaching and learning. *30th AAAI Conference on Artificial Intelligence, AAAI 2016*, 4170–4176.
- Marujo, L., Ling, W., Trancoso, I., Dyer, C., Black, A. W., Gershman, A., De Matos, D. M., Neto, J. P., & Carbonell, J. (2015). Automatic keyword extraction on twitter. *ACL-IJCNLP 2015 - 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing of the Asian Federation of Natural Language Processing, Proceedings of the Conference*, 2, 637–643. <https://doi.org/10.3115/v1/p15-2105>
- Ngu, A. H. H., Carlson, M. P., Sheng, Q. Z., & Paik, H. Y. (2010). Semantic-Based Mashup of Composite Applications. *IEEE Transactions on Services Computing*, 3(1), 2–15. <https://doi.org/10.1109/TSC.2010.8>
- Odden, T. O. B., Marin, A., & Caballero, M. D. (2020). Thematic analysis of 18 years of physics education research conference proceedings using natural language processing THEMATIC ANALYSIS of 18 YEARS ... ODDEN, MARIN, and CABALLERO. *Physical Review Physics Education Research*, 16(1), 10142. <https://doi.org/10.1103/PHYSREVPHYSEDUCRES.16.010142>
- Petersen, S. (2007). *Natural Language Processing Tools for Reading Level Assessment and Text Simplification for Bilingual Education*. 145.
- Romero, C., & Ventura, S. (2013). Data mining in education. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 3(1), 12–27. <https://doi.org/10.1002/widm.1075>
- Shukla, H., & Kakkar, M. (2016). Keyword extraction from Educational Video transcripts using NLP techniques. *Proceedings of the 2016 6th International Conference - Cloud System and Big Data Engineering, Confluence 2016*, 105–108. <https://doi.org/10.1109/CONFLUENCE.2016.7508096>
- Simeone, O. (2018). A Very Brief Introduction to Machine Learning with Applications to Communication Systems. *IEEE Transactions on Cognitive Communications and Networking*, 4(4), 648–664. <https://doi.org/10.1109/TCCN.2018.2881442>
- Song, C., Zhang, S., Sadoughi, N., Xie, P., & Xing, E. (2020). Generalized zero-shot text classification for ICD coding. *IJCAI International Joint Conference on Artificial Intelligence, 2021-Janua*, 4018–4024. <https://doi.org/10.24963/ijcai.2020/556>
- Tuchinda, R., Knoblock, C. A., & Szekely, P. (2011). Building mashups by demonstration. *ACM Transactions on the Web*, 5(3). <https://doi.org/10.1145/1993053.1993058>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems, 2017-Decem(Nips)*, 5999–6009.

- Wong, J., & Hong, J. I. (2007). *Making mashups with marmite*. 1435–1444. <https://doi.org/10.1145/1240624.1240842>
- Yunanto, A. A., Herumurti, D., Rochimah, S., & Kuswardayan, I. (2019). English education game using non-player character based on natural language processing. *Procedia Computer Science*, 161, 502–508. <https://doi.org/10.1016/j.procs.2019.11.158>
- Zhang, Y., Yuan, C., Wang, X., Bai, Z., & Liu, Y. (2022). *Learn to Adapt for Generalized Zero-Shot Text Classification*. 1, 517–527. <https://doi.org/10.18653/v1/2022.acl-long.39>
- Likert, R. (1932). *A Technique for the Measurement of Attitudes*. *Archives of Psychology*, 140, 1-55.
- Basili, V. R., & Weiss, D. M. (1984). *A methodology for collecting valid software engineering data*. *IEEE Transactions on Software Engineering*, 10(6), 728-738.

ANEXOS

Anexo 1

Cuestionario para la medición de variables con TAM

Utilidad percibida de los resultados de la metodología (PU)

Descripción (opcional)

Los resultados de la metodología logran una **eficacia** cuando se buscan temas relacionados a un video de YouTube. (La eficacia se refiere a la capacidad de lograr los resultados deseados o alcanzar los objetivos establecidos) *

1 2 3 4 5

Totalmente en desacuerdo Totalmente de acuerdo

Encuentra que los resultados obtenidos a través de la metodología son útiles y relevantes a la necesidad del caso de estudio. *

1 2 3 4 5

Totalmente en desacuerdo Totalmente de acuerdo

Se optimiza su tiempo productivo y se mejora la **eficiencia** (menos tiempo) al utilizar los resultados de la metodología. (La eficiencia se refiere a la capacidad de obtener los resultados utilizando los recursos disponibles de la manera más óptima posible) *

1 2 3 4 5

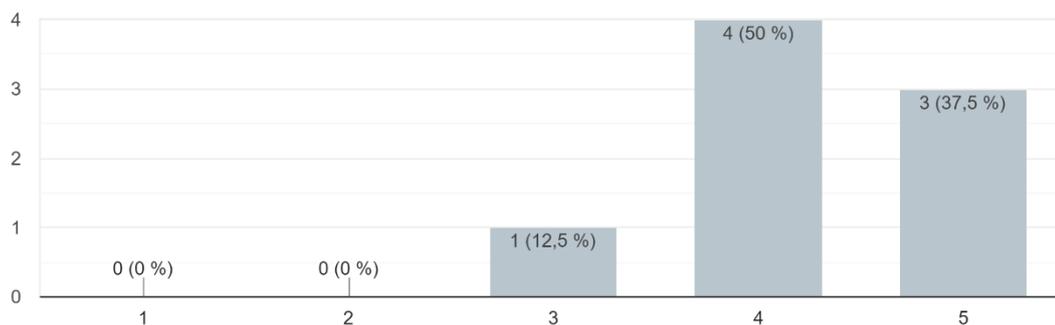
Totalmente en desacuerdo Totalmente de acuerdo

Anexo 2

Resultados del Cuestionario para la medición de variables con TAM

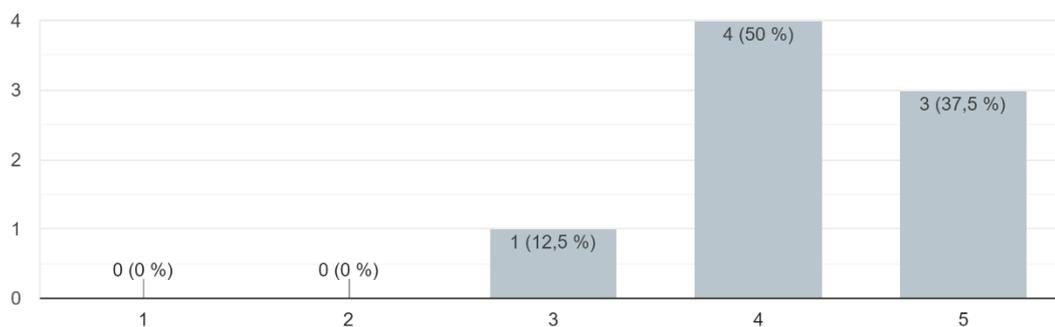
Los resultados de la metodología logran una eficacia cuando se buscan temas relacionados a un video de YouTube. (La eficacia se refiere a la capa...s deseados o alcanzar los objetivos establecidos)

8 respuestas



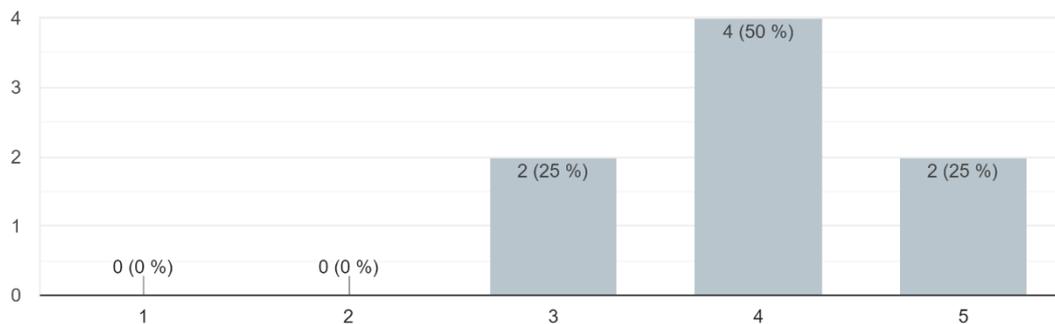
Encuentra que los resultados obtenidos a través de la metodología son útiles y relevantes a la necesidad del caso de estudio.

8 respuestas



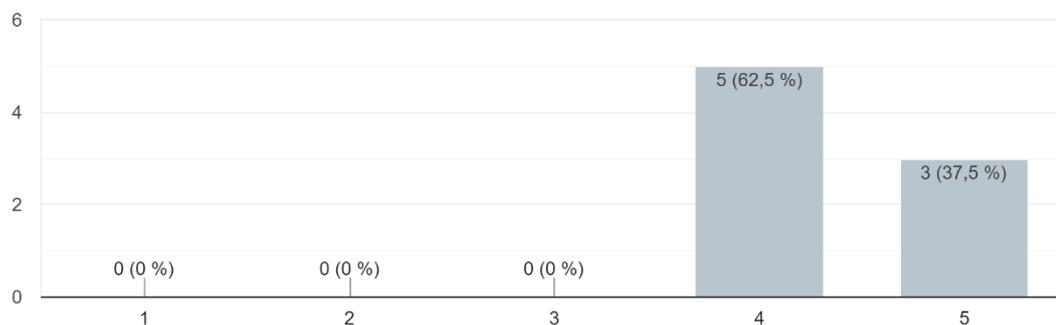
Se optimiza su tiempo productivo y se mejora la eficiencia (menos tiempo) al utilizar los resultados de la metodología. (La eficiencia se refiere a la ...cursos disponibles de la manera más óptima posible)

8 respuestas



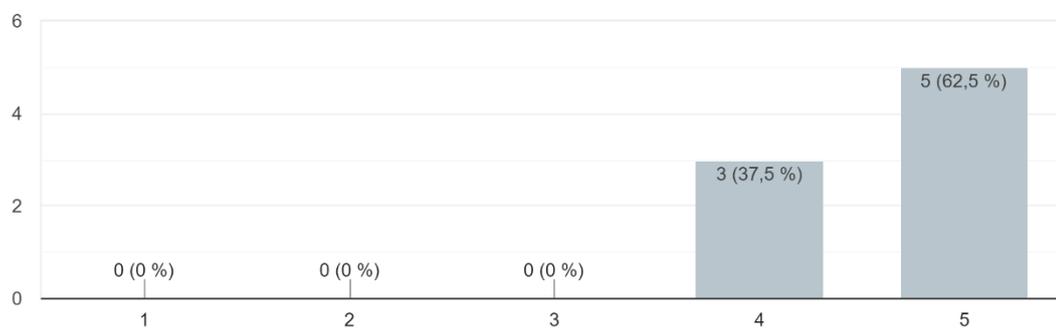
Los resultados de la metodología son fáciles de entender y utilizar, lo que permite adaptarse rápidamente a su funcionamiento y aprovechar sus funcionalidades sin dificultad.

8 respuestas



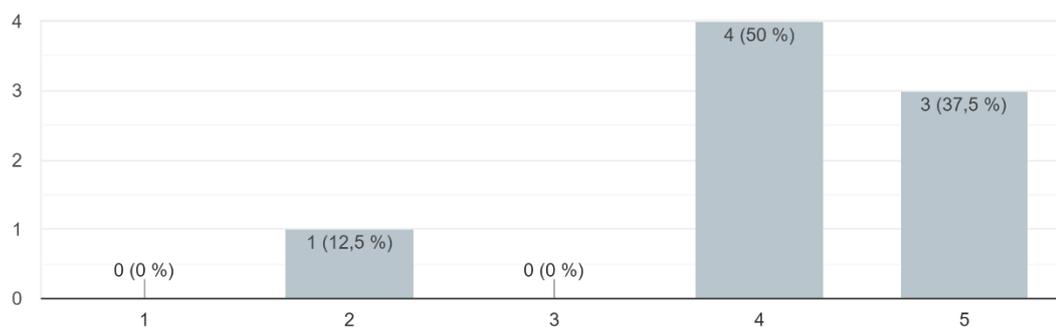
Se percibe que se alcanzan los resultados deseados fácilmente, es decir, no se requieren pasos complejos o procesos largos.

8 respuestas



La actitud hacia el uso de resultados es favorable, se reconocen los beneficios en su trabajo o en sus actividades diarias.

8 respuestas



La actitud hacia el problema es entusiasta, es decir, se confía en los resultados obtenidos, y se tienen la intención de utilizarlo de forma continua en el futuro.

8 respuestas

