

Clasificación de rutas turísticas por medio de deep learning

Classification of tourist routes through deep learning

- ¹ Héctor Fernando Gómez Alvarado  <https://orcid.org/0000-0002-7310-4260>
Universidad Técnica de Ambato, Carrera de Psicopedagogía, Tungurahua,
hf.gomez@uta.edu.ec
- ² María José Mayorga Ases <https://orcid.org/0000-0003-1897-739X>
Universidad Técnica de Ambato, Carrera de Psicopedagogía, Ambato, Tungurahua,
Ecuador.
mariajmayorga@uta.edu.ec
- ³ Leticia Abigail Mayorga Ases  <https://orcid.org/0000-0003-0586-2390>
Universidad Técnica de Ambato, Facultad Ingeniería Civil y Mecánica. Ingeniería
Mecánica,
la.mayorga@uta.edu.ec
- ⁴ Silvia Elena Malo Martínez  <https://orcid.org/0000-0002-9110-3915>
Universidad Técnica de Particular de Loja, Departamento de Filosofía, Artes y
Humanidades, Tungurahua
semalo@utpl.edu.ec



Artículo de Investigación Científica y Tecnológica

Enviado: 24/12/2021

Revisado: 29/12/2021

Aceptado: 03/01/2022

Publicado: 08/03/2023

DOI: <https://doi.org/10.33262/concienciadigital.v6i1.4.2038>

Cítese: Gómez Alvarado, H. F., Mayorga Ases, M. J., Mayorga Ases, L. A., & Malo Martínez, S. E. (2023). Clasificación de rutas turísticas por medio de deep learning. *Conciencia Digital*, 6(1.4), 880-897. <https://doi.org/10.33262/concienciadigital.v6i1.4.2038>



CONCIENCIA DIGITAL, es una Revista Multidisciplinar, Trimestral, que se publicará en soporte electrónico tiene como misión contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://concienciadigital.org>
La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) www.celibro.org.ec



Esta revista está protegida bajo una licencia Creative Commons Attribution Non Commercial No Derivatives 4.0 International. Copia de la licencia: <http://creativecommons.org/licenses/by-nc-nd/4.0/>

**Palabras
claves:**

aprendizaje
profundo, rutas
turísticas,
clústeres,
kmeans, clima

Keywords:

deep learning,
tourist routes,
clusters,
kmeans,
weather

Resumen

Introducción. Actualmente el *deep learning* o aprendizaje profundo tiene aplicaciones de todo tipo, el turismo no es la excepción, la minería de datos ha permitido optimizar procesos dentro de la industria del turismo como la demanda turística, conocer la preferencia de rutas turísticas de las personas permite optimizar recursos y plantear mejoras dentro de este sector. **Objetivo.** Determinar si se pueden clasificar rutas turísticas por medio de herramientas del *deep learning* o aprendizaje profundo. **Metodología.** El diseño de investigación fue cualitativo, se empleó técnicas como la entrevista, para ello se plantean dos hipótesis, la primera tiene que ver con la relación entre el tipo de clima del destino turístico y la preferencia de los turistas, la segunda hipótesis es la verificación de la conformación de *clusters* turísticos en base a la preferencia de las personas. Como herramientas de verificación se empleó la comprobación directa y el programa Weka con la opción de *clusters* SimpleKMeans que permite la identificación de las preferencias de los turistas en base a la minería de datos de 31 personas. **Resultados.** Los resultados indican que la mayor cantidad de personas entrevistadas prefieren destinos turísticos en climas calurosos, sin embargo, este no fue un parámetro determinante en la conformación de *clusters*. **Conclusión.** En el estudio se determinó que sí se puede formar *clusters* de clasificación de rutas turísticas en base a las preferencias de las personas.

Abstract

Introduction. Currently deep learning or deep learning has applications of all kinds, tourism is not the exception, data mining has allowed optimizing processes within the tourism industry such as tourist demand, knowing the preference of people's tourist routes allows optimizing resources and propose improvements within this sector. **Target.** Determine if tourist routes can be classified by means of deep learning or deep learning tools. **Methodology.** The research design was qualitative, techniques such as the interview were used, for these two hypotheses are proposed, the first has to do with the relationship between the type of climate of the tourist destination and the preference of tourists, the second hypothesis is the verification of the conformation of tourist clusters based on the preference of the people. As verification tools, direct verification

and the Weka program were used with the SimpleKMeans clusters option that allows the identification of tourists' preferences based on the data mining of 31 people. **Results.** The results indicate that the largest number of people interviewed prefer tourist destinations in hot climates, however, this was not a determining parameter in the formation of clusters. **Conclusion.** The study determined that it is possible to form clusters for the classification of tourist routes based on people's preferences.

Introducción

Aprendizaje profundo

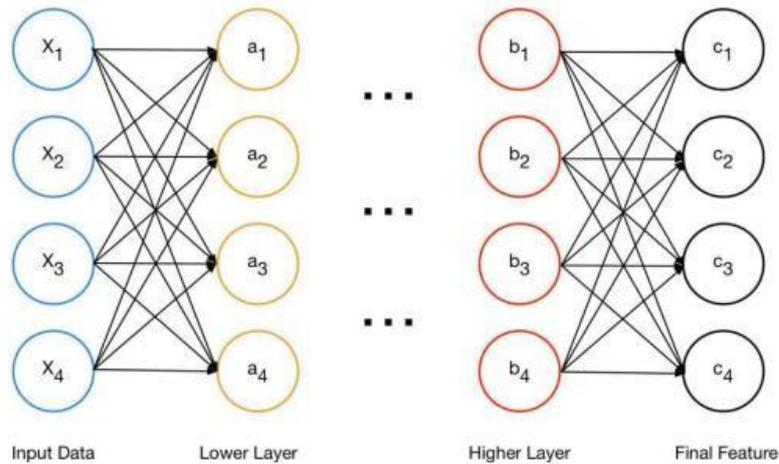
El aprendizaje profundo o *deep learning* se basa en el que la máquina pueda aprender y resolver problemas de forma intuitiva, imitando al cerebro humano (Law et al., 2019), es decir, se requiere un aprendizaje automático, diseñar, analizar algoritmos y extraer patrones de los datos para que la máquina pueda hacer predicciones. Esta tecnología que aún es nueva, modela datos a gran escala empleando estructuras complejas con diferentes arquitecturas; un ejemplo de esto, es el uso de redes neuronales para el procesamiento de la información (Hao et al., 2016).

En el aprendizaje profundo se emplean redes neuronales que operan entre capas, esto permite alcanzar un nivel profundo que puede ser utilizado para trabajos como reconocimiento de voz, reconocimiento de imágenes y predicción de eventos futuros en base a la información histórica (LeCun et al., 2015). El nivel de error en estas tareas gira alrededor del 30% sin embargo, este nivel continúa mejorando día a día con los avances tecnológicos (Hao et al., 2016).

Dentro de las redes neuronales profundas existen múltiples niveles de abstracción que se compone de un aprendizaje de características básicas en las capas iniciales, mientras que, los conceptos de nivel superior se ubican en las capas más profundas. Los avances más recientes permiten el aprendizaje automático de características con diferentes jerarquías empleando datos etiquetados y no etiquetados mediante capacidades mejoradas de procesamiento gráfico (Ahmad et al., 2019). En la figura 1 se muestra un esquema de la interacción de los datos de entrada entre capas inferiores y superiores hasta definir los datos de salida, sin embargo, esta interacción no es únicamente de correspondencia, más bien, los datos de entrada pueden subdividirse en varias capas y relacionarse con otras.

Figura 1

Ejemplo de interacción entre múltiples capas



Nota: Los datos de entrada interactúan con las demás capas de datos hasta obtener información de salida. **Fuente:** Ma et al. (2018)

Tipos de redes en el aprendizaje profundo

Los diferentes tipos de arquitecturas de redes neuronales permiten resolver problemas de una manera jerárquica con enfoques distintos.

- *Redes de aprendizaje profundo supervisado*

Redes empleadas para aprender a diferenciar elementos de datos de diversas clases, la tarea que desempeña la red tiene que ver con la asignación de etiquetas, clasificación y regresión de patrones. Las arquitecturas útiles en estas tareas son: redes neuronales profundas o *Deep Neural Networks* (DNN, por sus siglas en inglés), red neuronal convolucional o *Convolutional Neural Network* (CNN, por sus siglas en inglés) y red neuronal recurrente o *Recurrent Neural Network* (RNN, por sus siglas en inglés) (Ahmad et al., 2019).

Las DNN forman jerarquías en cada capa, esto permite que las redes aprendan patrones desde los niveles más básicos, hasta características muy abstractas en cuanto a los datos de entrada. El flujo de la información se complementa entre sí, puesto que los datos de salida de una capa se convierten en datos de entrada de la capa subsiguiente hasta llegar a las capas profundas. En el caso de texto, imágenes y videos, se emplean las estructuras CNN en donde la información atraviesa tres capas, capas convolucionales en donde se aprenden características importantes y se emplean filtros, capas de agrupación en donde se reduce el tamaño de los mapas característicos, cuando trabajan conjuntamente estas dos capas se

puede extraer rasgos locales de la entrada y combinarlas para obtener datos globales; finalmente, se encuentran las capas de conexión (Ahmad et al., 2019).

Cuando se desea detectar patrones de datos en series de tiempo se emplea la arquitectura RNN que mantiene recurrentes conexiones de red en intervalos de tiempo secuenciales, estas redes se aplican para fuentes de datos de voz, videos y texto; actualmente existe una forma más avanzada de RNN que mantiene memoria a corto plazo, se conoce como larga red de memoria a corto plazo o *Long Short-Term Memory* (LSTM, por sus siglas en inglés) (Ahmad et al., 2019).

- *Redes de aprendizaje profundo no supervisado*

En este tipo de redes, el aprendizaje profundo no es supervisado, es decir, que la información como etiquetas y clasificaciones, no se encuentra dentro de este proceso de aprendizaje; por el contrario, en esta metodología se emplea un codificador automático. El codificador obtiene una representación compacta que contiene los datos de entrada que, al ser relativamente corta, permite la reconstrucción de los datos originales. Durante este proceso surge el aprendizaje de características de los datos de forma no supervisada, para este proceso se usa una arquitectura simple que consta de modelos generativos probabilísticos con múltiples capas (Ahmad et al., 2019).

Se pueden combinar los dos tipos de redes de aprendizaje profundo cuando existe un gran caudal de datos que no pueden ser etiquetados, sin embargo, con el uso de redes de aprendizaje no supervisado se puede obtener los parámetros iniciales, a través de este primer proceso, se puede emplear redes de aprendizaje supervisado para la clasificación de la información.

Aplicaciones del aprendizaje profundo

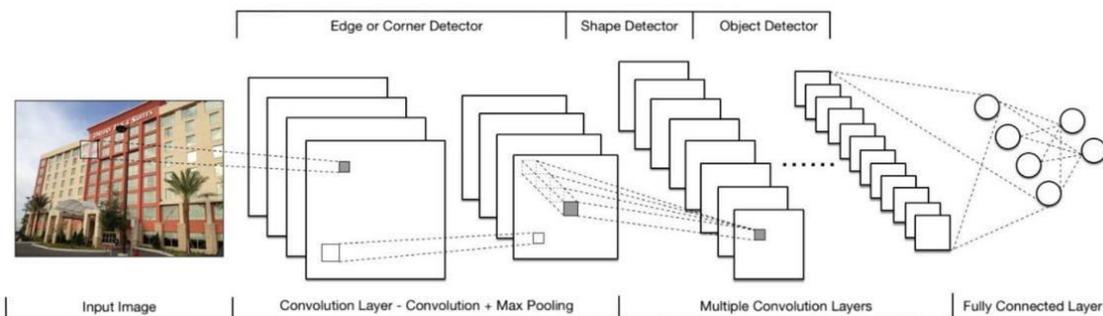
Con el aprendizaje profundo se pueden ejecutar diferentes tipos de actividades, para el caso de los seres humanos, son sencillas de procesar, sin embargo, para una máquina son más complejas. Eventualmente se ha empleado esta tecnología en el reconocimiento y clasificación de imágenes, reconocimiento facial, reconocimiento automático de voz, reconocimiento de características de imágenes en videos, procesamiento de lenguaje (generación y traducción de textos) (Hao et al., 2016).

Los avances recientes del empleo del aprendizaje profundo en la visión por computadora brindan aplicaciones en todos los campos; por ejemplo, sistemas de reconocimiento en vehículos autónomos, diagnóstico y detección de enfermedades, procesamiento, producción y mejoramiento de imágenes, etc. Por otro lado, en el ámbito de la búsqueda de información, esta tecnología brinda la posibilidad de navegar en la red para encontrar datos relacionados con los requerimientos de los usuarios que pueden efectuarse a través de imágenes, audio, video y texto; el mecanismo de operación de la búsqueda de

información se basa en la extracción de características de la entrada de la información mediante algoritmos de transformación (Ahmad et al., 2019).

Figura 2

Arquitectura CNN



Nota: La imagen se presenta como datos de entrada de donde se detectan parámetros como bordes, formas y objetos para conectarlos entre capas y obtener los datos finales. **Fuente:** Ma et al. (2018)

En la figura 2 se muestra el empleo de la arquitectura CNN en imágenes, de la imagen de entrada se puede aplicar capas en forma jerárquica desde la información más simple como bordes o esquinas de las imágenes hasta información más compleja capa por capa (Ma et al., 2018).

En el procesamiento del lenguaje, el aprendizaje profundo puede comprender expresiones lingüísticas complejas que son de uso cotidiano, los recursos de donde se interpreta este lenguaje provienen de datos textuales como formularios, análisis de sentimientos y emociones, opiniones, textos, traducción de idiomas, búsquedas web, correos electrónicos, informes y reconocimiento de documentos (Ahmad et al., 2019).

Aprendizaje profundo en el turismo

El aprendizaje profundo es una tecnología versátil, hoy en día su aplicación está introduciéndose en todo tipo de áreas del conocimiento; el turismo, no es la excepción. Las últimas innovaciones dentro de esta área tienen que ver con la simplificación de varias actividades que el turista lleva a cabo, como es el caso de la organización, planificación, selección de destinos turísticos, alojamiento, transacciones económicas, transporte, etc. Sin embargo, el empleo del aprendizaje profundo dentro del turismo es reciente, y no ha sido explorado en su totalidad.

Los investigadores Law et al. (2019), emplearon el aprendizaje profundo para el pronóstico del volumen mensual de turistas en Macao, la arquitectura que emplearon tiene el soporte necesario para la construcción e identificación de características y factores de previsión relevantes en esta tarea. La importancia de la predicción de la demanda turística no surge de la casualidad, puesto que el turismo también forma parte de las principales

actividades económicas en muchos países, conocer el flujo de turistas en ciertas épocas del año y en eventos específicos, puede definir con un menor riesgo de pérdidas económicas el número de entradas, alimentos, disponibilidad en alojamientos, presupuesto de promociones turísticas y todo tipo de estrategias que involucran un alto costo y esfuerzo de recursos humanos.

Las plataformas de búsqueda permiten obtener datos como la planificación de los viajes, selección de atracciones turísticas, planificación de transporte, entre otros, sin embargo, se debe tener en cuenta el buscador que tiene mayor cantidad de usuarios en función de la región de estudio. Otro dato muy importante para determinar un modelo de demanda turística corresponde al volumen de turistas mensuales. De este análisis se obtienen palabras clave que, a través del análisis de tendencias se obtienen resultados diarios y mensuales de los intereses de los turistas, este ejercicio se puede hacer en diferentes idiomas, con lo cual posibilita obtener información de otras regiones (Law et al., 2019; Labzioui, 2020). Para el tipo de redes de aprendizaje profundo que se requiere emplear en este caso LSTM, se emplea una demanda histórica de turismo en series de tiempo, los factores multivalentes del análisis son los datos previamente correlacionados de las palabras clave (Labzioui, 2020). El mecanismo LSTM identifica automáticamente un conjunto de características influyentes en cada paso de tiempo en el caso de Macao, algunas de estas características corresponden al transporte, clima y gastronomía; sin embargo, diferentes mercados pueden presentar otro tipo de conjuntos de características que son usuales entre los turistas que acuden en estas zonas (Law et al., 2019).

La visualización de imágenes de las reseñas turísticas también puede ser relevante en la elección del turista. Ma et al. (2018), proponen el empleo de las fotos subidas por los usuarios en las reseñas para hacer un análisis de su efecto en la utilidad de sus comentarios; mediante la visión por computadora se procesó la información de hoteles que tienen detalles de su servicio en línea junto con los comentarios y reseñas con fotografías; además de la información proveniente de redes sociales. Con los avances tecnológicos, las fotografías proporcionadas por los usuarios cumplen un papel fundamental en la evaluación de productos, este tipo de retroalimentación causa un mayor impacto en la percepción de los consumidores y en la toma de decisiones.

Las variables de entrada empleadas en el análisis de Ma et al. (2018), fueron de reseñas de texto, fotos y la combinación de texto y fotografías, clase de hotel, respuestas de los usuarios (la información fue útil) y la calificación de la reseña. Para el procesamiento del contenido textual emplearon procesamiento del lenguaje cotidiano o *Natural Language Processing* (NLP, por sus siglas en inglés), en el procesamiento de las imágenes aplicaron directamente CNN con la finalidad de extraer características de la imagen y se combinaron las metodologías en un módulo LSTM para elaborar funciones de secuencia. Los resultados reflejaron que la combinación de reseñas textuales con fotografías fue más

eficiente y arrojaron un mayor rendimiento.

El aprendizaje profundo también permite el reconocimiento masivo de datos de imagen y contenido visual, por ese motivo este recurso es útil para la determinación de la preferencia y comportamiento de los turistas en sus destinos turísticos.

Zhang et al. (2019), plantearon este tipo de análisis en el caso de las fotos de Beijing subidas en redes sociales. La visión por computadora permite obtener datos acerca de los destinos turísticos y la experiencia del viaje. Previo a esto, se hizo un análisis de correlación ente las cualidades afectivas de los lugares y los adjetivos que describen las imágenes, gran cantidad de esta información también puede obtenerse de las plataformas de redes sociales (Jeong et al., 2020).

Para el análisis por visión por computador emplearon arquitectura de aprendizaje profundo ResNet que mejora el desempeño de las redes convolucionales y ejecuta tareas de reconocimiento de escenas y clasificación de imágenes, en este caso, los datos de entrada son las fotografías de los turistas. Los resultados del análisis sugieren que los lugares escénicos tradicionales son los de mayor preferencia de los turistas, específicamente los edificios tradicionales. La información es de relevancia puesto que un estudio preliminar de las preferencias puede ser una pauta para la promoción de marketing (Zhang et al., 2019).

Dentro del ámbito de la planificación de rutas, viajes compartidos, transporte y monitoreo del tráfico, el uso del aprendizaje profundo también posibilita la estimación de tiempos de movilización. En estos análisis de tiempos, se emplean redes convolucionales con datos geográficos para la captura de correlaciones espaciales incluyendo aspectos como las maniobras de conducción; por otro lado, se emplean redes neuronales recurrentes LSTM para dependencias temporales de características obtenidas de mapas y factores externos como las condiciones climáticas, hábitos del conductor, día de la semana (Wang et al., 2018). En el reconocimiento de recursos turísticos se han desarrollado diferentes avances tecnológicos empleando dispositivos móviles, por ejemplo, el desarrollo de aplicaciones con guías turísticas interactivas empleando reconocimiento de imágenes y texto (M. Wang, 2020). En establecimientos turísticos como hoteles y restaurantes se emplean aplicaciones para la gestión y organización de reservas, ocupación e ingresos, la recopilación de estos datos permite hacer investigaciones de demanda y tendencias turísticas. Otros recursos importantes para el turismo es la predicción de precios en los viajes, chatbots en donde se brinda atención al cliente durante todo el día (Renteria, 2021).

Rutas turísticas

Para la elaboración de rutas turísticas se deben tener en cuenta diferentes aspectos, por

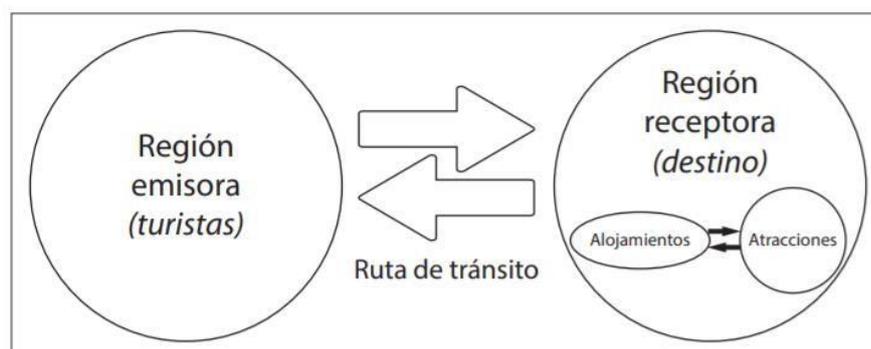
ejemplo, la modalidad de turismo, las actividades que se pueden llevar a cabo en los diferentes puntos, los lugares que se visitan, gastronomía y atractivos turísticos (Vinces et al., 2021). Sin embargo, el éxito de un destino turístico está relacionado con la buena estructuración de los productos turísticos y la elaboración de un itinerario adecuado. Una ruta turística posee una agrupación de características que la hacen viable como, por ejemplo, una adecuada infraestructura, tipo de rutas, duración, costo y recursos complementarios que requieren tener en cuenta los turistas para llevar a cabo las actividades de la ruta y el análisis de la cadena de valor del producto o servicio turístico (Rodríguez & Abeal, 2016).

Clasificación de rutas turísticas

Un factor muy importante para la clasificación de rutas turísticas son los atractivos turísticos, el flujo de los turistas se presenta a través de la región emisora de donde parten los turistas, la ruta de destino y la región receptora o destino, dentro de los diferentes destinos existen dos variables de gran importancia, son los alojamientos y los atractivos turísticos, como se presenta en la figura 3. La importancia de este factor radica en que es lo que motiva a las personas a movilizarse hacia la región de destino y dentro de esta variable existe un sinnúmero de tipologías que definen la intención turística (Enseñat, 2020).

Figura 3

Sistema turístico – espacial



Nota: Esquema de los componentes de las rutas turísticas. **Fuente:** Enseñat (2020)

Dentro de los destinos turísticos existe una gran variación de atractivos turísticos que están dentro de una misma zona, los destinos pueden definirse como los países, ciudades o puntos territoriales en donde se agrupan otros sitios de interés para los turistas o visitantes, mientras que los atractivos turísticos son zonas naturales o sitios implementados por el ser humano que están abiertos al público para diferentes fines. Debido a que los atractivos turísticos la clave en la elección de la ruta turística se debe conocer el nivel de interés que tienen en las personas, con este fin, los atributos que influyen en este parámetro están ligados al tipo de sitio turístico (Enseñat, 2020).

Los destinos turísticos cuentan con una cultura propia, operadores turísticos y una comunidad que en conjunto brindan una experiencia satisfactoria y atractiva a quienes visitan las zonas. Otros aspectos que hacen atractivos a los destinos turísticos pueden ser la naturaleza, el hospedaje y la imagen que en general se tiene del destino, y toda esta información es la que se puede recopilar a través de medios sociales, páginas web, blogs y el *big data*; uno de los principales canales de flujo de información son las redes sociales en donde se almacenan datos de tipo UGC o contenidos generados por el usuario como, por ejemplo: sentimientos, imágenes, videos y la interacción que se produce en estas plataformas. Analizar los sentimientos, opiniones y expresiones de las personas permite evaluar cada sitio y conocer el nivel de impacto que tienen entre los turistas (Molinar et al., 2017).

En el presente análisis se verificará la influencia del clima en la selección de las preferencias del destino turístico de las personas, así como también la factibilidad de creación de *clusters* empleando la tecnología del aprendizaje profundo con herramientas como *Simple KMeans de Weka*.

Metodología

Para el estudio se entrevistó a una población de 31 estudiantes de la carrera de turismo de la facultad de ciencias humanas y de la educación, quienes eligieron el destino turístico de su preferencia colocando 1 en la casilla cuando existe preferencia por el destino turístico y 0 cuando no existe preferencia. Se plantearon diversos destinos turísticos que cuentan con diferentes condiciones climáticas.

Para poder procesar los datos, se conformaron tablas en función de las preferencias turísticas y del clima que caracteriza a cada destino turístico, para ello se normalizaron los datos entre 0 y 1.

En la etapa de verificación de conformación de *clusters* en función de las preferencias de los turistas se empleó la herramienta Weka desarrollada por la Universidad de Waikato, que emplea diferentes opciones de procesamiento de minería de datos, para la formación de *clusters* se seleccionó *Simple Kmeans* para la verificación de las distancias entre los centroides de los *clusters* o el valor de *k*.

En base a los resultados de Weka se verificó si existen características similares entre los *clusters* y el clima que rige en los destinos turísticos para conocer si existe una influencia entre ellos.

Resultados

Se entrevistó a 31 estudiantes, en la tabla 1 se muestran los resultados de sus preferencias turísticas de los destinos o sitios turísticos del Ecuador.

Tabla 1

Resultados de preferencias turísticas – estudiantes facultad de ciencias humanas y de la educación

No Estudiante	Papallacta	Cotacachi	Mindo	Santo Domingo de los Tsáchilas	Esmeraldas	Cayambe	Volcán	Chimborazo	Montañita	Baños	Salinas	Salinas de Guaranda	Volcán	Tungurahua	Tisaleo	Pinillo	Tena	Quito
1	0	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0
2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
3	1	0	0	0	0	1	1	1	1	0	0	0	0	0	0	0	1	1
4	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1
5	1	1	1	1	1	1	1	1	1	1	1	0	1	0	1	0	0	1
6	0	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1
7	0	0	0	0	1	1	1	1	1	1	1	0	1	0	0	0	1	1
8	0	0	0	1	1	0	0	1	1	1	1	0	1	1	1	1	1	1
9	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	0	1	1
10	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
11	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
12	1	1	1	0	1	1	1	0	1	1	1	0	1	0	0	0	1	0
13	0	1	1	1	0	0	0	1	1	0	1	0	0	0	0	1	0	1
14	1	0	0	0	1	1	1	0	1	0	0	0	1	0	1	0	0	1
15	1	0	1	1	1	0	0	0	1	1	0	0	0	0	0	1	1	1
16	1	1	1	1	1	0	0	0	1	1	0	0	1	0	1	1	1	0
17	0	1	0	1	1	1	1	0	0	0	1	0	0	0	0	0	1	0
18	1	0	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	1
19	1	1	1	0	1	0	1	1	1	1	1	1	1	0	0	0	1	1
20	1	1	1	1	1	0	1	0	1	1	0	0	1	0	1	1	1	1
21	1	1	1	0	0	0	0	1	1	1	1	1	0	0	0	0	1	
22	1	1	1	0	1	0	1	0	1	1	0	0	1	1	1	1	0	1
23	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
24	1	1	0	1	1	1	1	1	1	1	1	0	1	1	1	1	1	0

Tabla 1

Resultados de preferencias turísticas – Estudiantes Facultad de Ciencias Humanas y de la Educación (continuación)

No Estudiante	Papallacta	Cotacachi	Mindo	Santo Domingo de los Tsáchilas	Esmeraldas	Cayambe	Volcán	Chimborazo	Montañita	Baños	Salinas	Salinas de Guaranda	Volcán Tungurahua	Tisaleo	Pinlo	Tena	Quito
25	1	0	1	0	1	1	1	1	1	1	1	1	1	0	0	1	1
26	1	1	1	1	1	0	0	0	0	1	1	1	0	0	1	1	0
27	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
28	0	0	1	1	1	1	0	1	0	1	0	0	1	1	1	1	1
29	1	0	1	1	0	0	0	1	1	1	1	1	1	1	1	1	
30	0	0	1	1	1	0	1	0	1	0	0	1	0	1	0	1	0
31	1	1	1	1	1	0	1	1	0	1	0	0	1	1	1	0	1
Totales	23	20	23	23	26	19	23	22	28	26	18	22	15	21	24	22	

Fuente: Estudio de preferencias turísticas estudiantes Universidad Técnica de Ambato

De la tabla 1 se puede resaltar que tres destinos turísticos obtuvieron mayor frecuencia en cuanto a las preferencias de las personas, en este caso, 28 personas prefieren Baños (Baños de Agua Santa) y, 26 personas prefieren Esmeraldas y Salinas.

En la tabla 2 se muestran los datos del tipo de clima que es característico en los 16 destinos turísticos planteados para el estudio.

Tabla 2

Clima característico de los destinos turísticos

Destino Turístico	Clima característico del sitio			
	Frío	Templado	Caluroso	TOTAL
Papallacta	1	0	0	1
Esmeraldas	0	0	1	1

Tabla 2

Clima característico de los destinos turísticos (continuación)

Destino Turístico	Clima característico del sitio			
	Frío	Templado	Caluroso	TOTAL
Cayambe	0	1	0	1
Santo Domingo de los Tsáchilas	0	0	1	1
Quito	1	0	0	1
Mindo	1	0	0	1
Cotacachi	1	0	0	1
Tisaleo	1	0	0	1
Pinlo	1	0	0	1
Tena	0	1	0	1
Volcán de Chimborazo	1	0	0	1
Montañita	0	0	1	1
Baños de Agua Santa	0	1	1	2
Salinas de Guaranda	0	1	0	1
Salinas	0	0	1	1
Volcán Tungurahua	1	0	0	1
TOTAL	8	4	5	17

Fuente: Estudio de preferencias turísticas estudiantes Universidad Técnica de Ambato

Con la información obtenida en la tabla 1 se realizó una comprobación directa para identificación de las preferencias, de los resultados con mayor frecuencia se hizo una verificación con respecto al clima, según el tipo de clima característico del sitio, como se presenta en la tabla 2.

Tabla 3

Resultados de las preferencias con relación al clima

Preferencia de destino turístico	Clima
Esmeraldas	Caluroso
Baños	Templado / Caluroso
Salinas	Caluroso

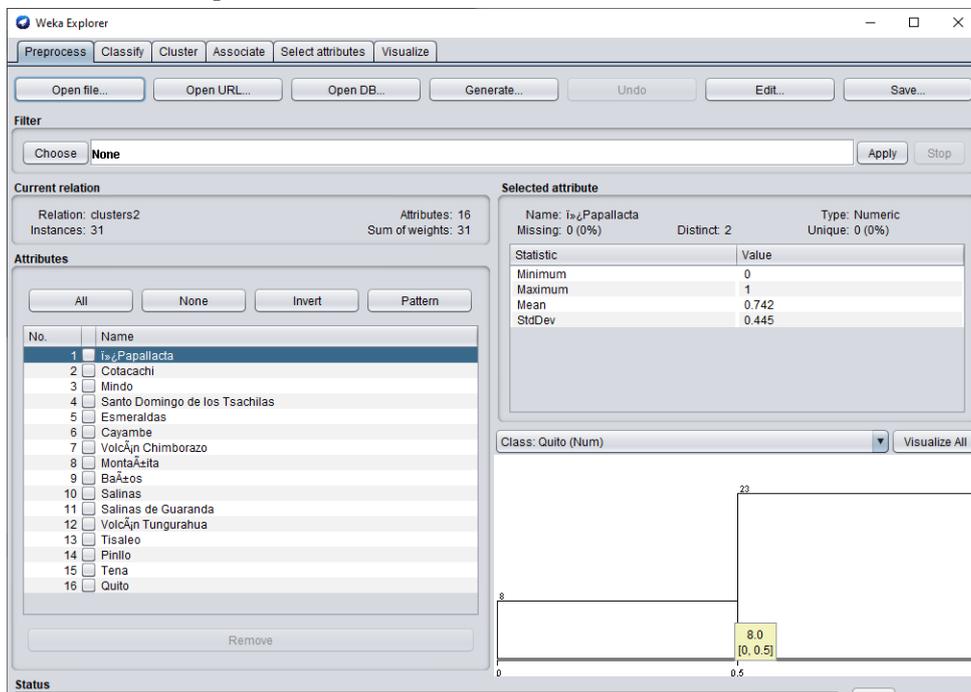
Fuente: Estudio de preferencias turísticas estudiantes Universidad Técnica de Ambato

El resultado de la verificación directa se muestra en la tabla 3 en donde se indica que los sitios que tienen mayor preferencia en la población de 31 estudiantes corresponden a climas calurosos.

Para la elaboración de los *clusters* empleando la herramienta Weka se utilizó la misma base de datos presentada en la tabla 1, en esta tabla se resumen las preferencias de los destinos turísticos con el valor de 1.

En la figura 4 se muestra el preprocesamiento de la información con los 16 atributos que corresponden a los diferentes sitios turísticos del Ecuador, de los cuales se hizo un análisis de preferencias en base a la población de 31 estudiantes, en este caso no se aplicó ningún filtro y se procesó la información directamente en la opción *cluster* del programa.

Figura 4
Preprocesamiento de los destinos turísticos en Weka



Fuente: Estudio de preferencias turísticas estudiantes Universidad Técnica de Ambato, datos procesados en Weka

En la figura 5 se muestran los resultados de k valor aplicando la herramienta Simple KMeans para la conformación de *clusters*. Como resultado se obtuvo 2 *clusters*, uno con 23 datos y otro con 8, en total se analizaron los 36 datos por atributo que se ingresaron de la tabla 1.

0 existen destinos turísticos de clima frío, caluroso y templado, mientras que en el *cluster* 1 no se verifica la preferencia del clima frío.

Referencias bibliográficas

- Ahmad, J., Farman, H., & Jan, Z. (2019). Deep Learning Methods and Applications. *Deep Learning: Convergence to Big Data Analytics* (pp. 31-42). Springer. https://doi.org/10.1007/978-981-13-3459-7_3
- Enseñat, F. (2020). Clasificación de las zonas arqueológicas según su nivel de atracción. *Investigaciones geográficas*, 102. <https://doi.org/10.14350/rig.60146>
- Hao, X., Zhang, G., & Ma, S. (2016). Deep Learning. *International Journal of Semantic Computing*, 10(03), 417-439. <https://doi.org/10.1142/S1793351X16500045>
- Jeong, C. S., Ryu, K. H., Lee, J. Y., & Jung, K. D. (2020). Deep Learning-based Tourism Recommendation System using Social Network Analysis. *International Journal of Internet, Broadcasting and Communication*, 12(2), 113-119. <https://doi.org/10.7236/IJIBC.2020.12.2.113>
- Labzioui, H. (2020). *Aplicación de Deep Learning a la predicción de turismo en la Costa del Sol*. <https://riuma.uma.es/xmlui/handle/10630/20490>
- Law, R., Li, G., Fong, D. K. C., & Han, X. (2019). Tourism demand forecasting: A deep learning approach. *Annals of Tourism Research*, 75, 410-423. <https://doi.org/10.1016/j.annals.2019.01.014>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Ma, Y., Xiang, Z., Du, Q., & Fan, W. (2018). Effects of user-provided photos on hotel review helpfulness: An analytical approach with deep learning. *International Journal of Hospitality Management*, 71, 120-131. <https://doi.org/10.1016/j.ijhm.2017.12.008>
- Molinar, C. M. A., Espinoza, P. M., & Llamas, I. O. (2017). Evaluación de destinos turísticos mediante la tecnología de la ciencia de datos. *Estudios y perspectivas en turismo*, 26(2), 286-305. <https://dialnet.unirioja.es/servlet/articulo?codigo=6327726>
- Rentería Ayquipa, R. A. (2021). Machine learning y realidad aumentada para el reconocimiento de recursos turísticos. *Repositorio Institucional*.

<http://repositorio.unap.edu.pe/handle/UNAP/16669>

- Rodríguez, C. R., & Abeal, J. P. (2016). El itinerario cultural urbano como producto turístico: El caso de Galicia. *International journal of scientific management and tourism*, 2(2), 373-396.
<https://dialnet.unirioja.es/servlet/articulo?codigo=5665888>
- Vinces, O. M., Cabrera, K. R., & Grunauer, M. N. (2021). Diseño de un modelo de aplicación móvil de las rutas turísticas del cantón Pasaje, Ecuador. *593 digital Publisher CEIT*, 6(6), 196-211.
<https://dialnet.unirioja.es/servlet/articulo?codigo=8149604>
- Wang, D., Zhang, J., Cao, W., Li, J., & Zheng, Y. (2018, Abril 26). When Will You Arrive? Estimating Travel Time Based on Deep Neural Networks. *Thirty-Second AAAI Conference on Artificial Intelligence*. Thirty-Second AAAI Conference on Artificial Intelligence.
<https://www.aaai.org/ocs/index.php/AAAI/AAAI18/paper/view/16657>
- Wang, M. (2020). Applying Internet information technology combined with deep learning to tourism collaborative recommendation system. *PLOS ONE*, 15(12), e0240656. <https://doi.org/10.1371/journal.pone.0240656>
- Zhang, K., Chen, Y., & Li, C. (2019). Discovering the tourists' behaviors and perceptions in a tourism destination by analyzing photos' visual content with a computer deep learning model: The case of Beijing. *Tourism Management*, 75, 595-608.
<https://doi.org/10.1016/j.tourman.2019.07.002>

El artículo que se publica es de exclusiva responsabilidad de los autores y no necesariamente reflejan el pensamiento de la **Revista Conciencia Digital**.



El artículo queda en propiedad de la revista y, por tanto, su publicación parcial y/o total en otro medio tiene que ser autorizado por el director de la **Revista Conciencia Digital**.



Indexaciones

