



Resumiendo Opiniones Negativas con *Deep Learning* y Reglas Descriptivas

Ana Valdivia, Eugenio Martínez-Cámara, M. Victoria Luzón, Francisco Herrera
Instituto Andaluz de Investigación en Ciencia de Datos e Inteligencia Computacional
Universidad de Granada, 18014 Granada, España
Email: avaldivia@ugr.es, emcamara@decsai.ugr.es, luzon@ugr.es, herrera@decsai.ugr.es

Resumen—La tarea del Análisis de Opiniones a Nivel de Aspecto se basa en realizar un análisis sobre las opiniones con el mayor detalle posible, pues detecta aspectos específicos que aparecen en el texto de la opinión. No obstante, debido a que la información que se extrae de estos algoritmos es muy precisa, aspecto por aspecto, ésta no contribuye a obtener un conocimiento general de todo el corpus. Por ello, en este trabajo se propone una metodología que, a partir de la extracción de aspectos, se resume todo el contenido de una manera descriptiva, visualizando las conexiones más relevantes entre aspectos y una cierta polaridad, que en nuestro caso es la negativa. En este estudio, demostramos que este nuevo método puede emplearse para obtener una descripción global de un corpus entero a partir de las relaciones más significativas entre un aspecto y su polaridad.

I. INTRODUCCIÓN

El Análisis de Opiniones (AO), que tiene como objetivo extraer sentimientos de textos escritos [1], ha alcanzado un alto interés en la sociedad debido a la gran cantidad de textos generados por usuarios que existen en blogs, foros, redes sociales, etc. Dentro de este campo, existen diferentes niveles de análisis dependiendo de su granularidad. El Análisis de Opiniones a Nivel de Aspecto (AONA)¹ es considerado el nivel más profundo de análisis [2]. Todos los métodos basados en AONA tienen como objetivo detectar polaridades en entidades y aspectos mencionados en el texto. Esta subtarea del AO se ha viralizado en los últimos años debido a su capacidad de extraer información muy fina y detallada.

No obstante, los métodos de AONA trabajan a nivel de entidad, lo que implica que la información que extraen es específica de cada opinión que analiza. Permiten obtener un análisis muy preciso de cada opinión, por lo que la información que se extrae a partir de estas técnicas es muy local.

Debido a ello, en este trabajo se propone una nueva metodología que extrae información general de las opiniones a través de algoritmos basados en AONA. La idea es mejorar la capacidad de generalización mediante Reglas Descriptivas (RD) que muestran las relaciones más relevantes entre los aspectos y polaridades. El proceso se basa en tres fases: (1) Extracción de aspectos de las opiniones, (2) Agrupación de aspectos que se refieren a conceptos similares y (3) Extracción de reglas descriptivas de aspectos y polaridades.

Los experimentos están centrados en las opiniones en inglés de TripAdvisor de tres monumentos culturales: la Alhambra,

la Sagrada Familia y la Mezquita de Córdoba. El propósito es el de caracterizar el conjunto de todas las opiniones negativas de estos monumentos, encontrando los aspectos más relevantes de esta clase, pues son los que ayudan a entender qué entidades se podrían mejorar de la visita. Los resultados muestran claramente que la metodología es eficaz para abordar la falta de generalización de los algoritmos AONA, y más específicamente, podría ser utilizado por el personal gerente de monumentos culturales para mejorar la experiencia de la visita cultural.

La estructura de este trabajo sigue así: la Sección II presenta una breve introducción de los conceptos básicos para una mejor comprensión de este estudio. La Sección III presenta la metodología propuesta para abordar el problema identificado. La Sección IV muestra los experimentos realizados. Finalmente, la Sección V resume las conclusiones del trabajo y propone futuras líneas de investigación.

II. CONTEXTO

En esta sección se describen los conceptos generales en los que se basa esta metodología. Primero, se define AONA (Sección II-A), luego, se describen los algoritmos que existen basados en *Deep Learning* (DL) para AONA. Finalmente, se presentan las reglas descriptivas (Sección II-C).

II-A. Análisis de Opiniones a Nivel de Aspecto (AONA)

AONA es una subtarea de AO que se basa en extraer aspectos y polaridades de entidades que son nombradas en opiniones. Es una tarea que aporta información granular del propósito de la opinión [3], y por lo tanto también es más precisa, ya que los usuarios no suelen mostrar el mismo sentimiento en todo un mismo texto. Por ejemplo, si analizamos el siguiente enunciado:

“Los jardines de la Alhambra son espectaculares, pero las colas que se forman antes de entrar son horribles (deberían mejorar el sistema de entradas).”

En el ejemplo se observa que la usuaria primero expresa un sentimiento positivo hacia los jardines, pero luego critica el sistema de entradas por las colas que se forman para acceder al monumento. Por lo tanto, la opinión global de la oración no está clara, pero si se realiza el análisis a nivel de entidad, se identifica un aspecto positivo (la Alhambra) y otro negativo (sistema de entradas).

¹En inglés: *Aspect Based Sentiment Analysis* (ABSA).

Existen diferentes métodos basados en la extracción de aspectos. Los primeros que se desarrollaron, conocidos como Métodos Basados en Frecuencias, están basados en detectar los nombres simples y compuestos más frecuentes. Por ejemplo, Hu et al. identificaron características de productos a través de algoritmos con reglas de asociación [2]. Este método fue también aplicado al dominio del turismo, donde Marrese et al. extrajeron aspectos de restaurantes y hoteles en [4]. No obstante, estos métodos no detectan aspectos con una frecuencia muy baja en el texto, los cuáles también pueden ser útiles para comprender la opinión. Por otro lado, los Métodos Basados en Sintaxis se centran en analizar las relaciones sintácticas en el texto y así extraer los aspectos [5]. Para que estos métodos tengan un alto rendimiento, se necesitan definir previamente reglas sintácticas, tantas como sean posibles, lo cuál complica considerablemente el desarrollo de estos algoritmos. Por último, durante los últimos años se ha experimentado una explosión de técnicas basadas en *deep learning*. Este tipo de métodos han conseguido mejorar el rendimiento de muchos problemas dentro de las Ciencias de la Computación, consiguiendo resultados que baten a la mayoría de metodologías pasadas. AONA es un ejemplo de cómo estos algoritmos han mejorado los resultados de ciertas tareas, el cual explicaremos en la siguiente sección.

II-B. Deep Learning (DL)

Durante los últimos años, el DL ha revolucionado gran parte de la comunidad científica. Este tipo de estructuras algorítmicas proporciona la versatilidad del aprendizaje supervisado y sin necesitar una selección previa de características para optimizar el rendimiento final. Los modelos de *deep learning* son clasificadores no lineales que pueden ajustarse a los datos de una manera más precisa. Durante la última década, este tipo de métodos han mejorado la mayoría de *baselines* de problemas del Procesamiento del Lenguaje Natural (PLN). Por ejemplo, Collobert et al. presentaron el primer estudio que introdujo el uso de Redes Neuronales Convolucionales (CNN) en tareas de PLN [6]. Poria et al. presentaron un enfoque de AONA basado en el aprendizaje profundo, que se basa en dos capas de CNN combinadas con un conjunto de patrones lingüísticos [7]. En este trabajo, se utilizará este sistema para extraer los aspectos debido al buen rendimiento que presenta en el estudio.

II-C. Reglas Descriptivas (RD)

El aprendizaje supervisado comprende todos aquellos métodos que aprenden una función que asigna instancias a una clase previamente etiquetada. Se utilizan cuando el objetivo es predecir la clase de nuevas instancias. En cambio, el aprendizaje no supervisado son todos aquellos métodos que infieren estructuras ocultas a partir de datos no etiquetados. En este caso, se conciben como técnicas de descriptivas de datos y analizan su estructura inherente.

Una de las técnicas más populares de aprendizaje no supervisado son las RD. Se definen como el conjunto de técnicas que apuntan a descubrir un conocimiento descriptivo guiado

por una variable de clase supervisada. El objetivo principal de las RD es entender los patrones que se transmiten en los datos, en lugar de clasificar las instancias con respecto a una variable de clase mediante reglas. Recordamos que una regla es una expresión que relaciona un cierto atributo (consecuente) con un conjunto de características (antecedente). Una de las técnicas más conocidas de RD es el *Subgroup Discover* (SD). SD es una técnica de minería de datos no supervisada que describe una conjunción de características que son propia de una clase, dónde el antecedente es el conjunto característico de valores propios de la clase.

$$R: \{\text{Subgroup Conditions}\} \longrightarrow \{\text{Class}\},$$

Esta tarea no se centra en encontrar relaciones complejas en los datos, sino que intenta cubrir las instancias a partir de los datos de una manera exhaustiva.

Existen diferentes métricas que tratan de medir la calidad y relevancia de las reglas extraídas. Las más populares son [8] y [2]:

- **Cobertura:** Número de instancias cubiertas por la regla.

$$Cov(R) = \frac{|\text{Subgroup Conditions}|}{N},$$

donde N es el total de instancias del dataset.

- **Soporte:** Número de instancias en el dataset que cumplen las condiciones del antecedente (*Subgroup Conditions*) y el valor de la clase (*Class*).

$$Sup(R) = \frac{|\text{Subgroup Conditions} \cap \text{Class}|}{N}.$$

- **Confianza:** Mide el grado de cobertura de una regla en relación al conjunto de ejemplos que satisfacen el antecedente.

$$Conf(R) = \frac{|\text{Subgroup Conditions} \cap \text{Class}|}{|\text{Subgroup Conditions}|}.$$

III. UNA NUEVA METODOLOGÍA PARA DESCRIBIR OPINIONES

El objetivo de las tareas basadas en AONA es el de obtener información detallada sobre la opinión. Estas tareas relacionan los aspectos mencionados en un texto con una polaridad específica. Sin embargo, en este trabajo detectamos la falta de generalización de estas técnicas, pues no sirven para tener una idea global del contenido de las opiniones. Por ello, proponemos una nueva metodología que combina la extracción de aspectos con técnicas de RD para obtener una descripción global de las relaciones más relevantes entre aspectos y polaridades dentro de un corpus. En este sentido, se combinan dos poderosas herramientas: una red neuronal basada en el uso de varias capas convolucionales CNN para la extracción de aspectos y un método de SD para la agregación de información, es decir, reglas que asocien un conjunto de aspectos con una cierta polaridad, en este caso, la negativa:

$$R: \{\text{aspect}_a = 1, \text{aspect}_b = 1\}$$




Figura 1. Flujo de la metodología propuesta.

→ {sentiment = negative}.

La metodología propuesta está basada en tres fases (ver Figura 1). La primera es extraer aspectos usando una arquitectura neuronal (Section III-A). Luego, se agrupan aspectos similares para representar el mismo concepto en una sola entidad (Sección III-B). Finalmente, se utiliza un algoritmo basado en SD para extraer la información agregada y así describir el conjunto de opiniones mediante reglas entre aspectos y polaridades (Sección III-C).

III-A. Deep Learning para extraer aspectos

Los modelos de DL son clasificadores no lineales, lo cuáles se han convertido en el estado del arte de la gran mayoría de las tareas de PLN, debido al buen rendimiento que se ha observado. Por esta razón, en este trabajo se propone utilizar el método DL presentado en [7] para la extracción de aspectos. Este método se basa en una arquitectura convolucional, la cual utiliza como entrada las palabras que rodean a un aspecto. La arquitectura de esta red está formada por una capa de entrada, dos capas de convolución, dos capas de *pool* máximo y una capa totalmente conectada con una salida *softmax*. La salida de cada capa de convolución está calculada usando *tanh* como función de activación. Por último, se utiliza un conjunto de patrones lingüísticos que se ejecutan en la salida, lo cuales mejoran el rendimiento del método de extracción de aspectos.

III-B. *k-nn* para agrupar aspectos

Debido a la riqueza del lenguaje natural que utilizan los humanos, cuando una persona escribe no suele utilizar la misma palabra o expresión para transmitir una misma idea. Por lo tanto, la variedad de aspectos extraídos por cualquier método de extracción de aspectos es muy amplio, y muchos de ellos pueden referirse a una misma entidad. Por ejemplo, cuando se escribe sobre la experiencia de una visita a un monumento cultural, existen muchas maneras de expresar lo mismo:

ticket → {onsite ticket office, senior ticket, ticket area, ticket check points, ticket office, entry ticket, service ticket, machine ticket, ticket staff, ticket price, ticket process, ...}.

La riqueza del lenguaje implica que: (1) se debe lidiar con la alta dimensionalidad de los aspectos, porque una misma entidad puede estar representada con una gran variedad de palabras idea; (2) aspectos similares semánticamente tienen representaciones diferentes. Para abordar estos problemas, en este trabajo proponemos agrupar estos aspectos en un mismo grupo o clúster, y así disminuir la dimensionalidad de aspectos extraídos.

III-B1. De palabras a vectores: Los *word embeddings* son representaciones de palabras en forma de vector numérico. Mikolov et al. presentaron en [9] el primer *word embedding* del estado del arte del PLN, conocido como *word2vec*. Levy et al. generalizaron este modelo teniendo en cuenta el contexto de las palabras que se representan [10]. Demostraron que los contextos sintácticos capturan otro tipo de información, por lo que su modelo recoge más similitud funcional entre las palabras representadas como vectores. Por esa razón, en este trabajo se han usado este tipo de *embeddings*². Para esos aspectos que están compuestos por más de una palabra, su representación en *embeddings* es la media de todos los *embeddings* de las palabras que componen dicho aspecto.

III-B2. De vectores a clústers: El *clustering* es la tarea de agrupar un conjunto de objetos de tal manera que los que pertenecen a un mismo grupo o clúster son más similares entre ellos que entre los que pertenecen a otro clúster. En toda la literatura, existe una gran variedad de algoritmos de *clustering*. La principal diferencia entre ellos es la noción que tienen de similitud entre los objetos a la hora de formar los grupos y cómo de eficiente es la agrupación. Uno de los más populares es el *k-means*. Este es un algoritmo iterativo tiene como objetivo minimizar la varianza entre las instancias que forman un mismo grupo. Más formalmente se puede expresar como:

Dado un conjunto de elementos $\{w_1, \dots, w_n\}$, *k-means* agrupa las *n* observaciones en *k* clusters ($\{C_1, \dots, C_k\}$), minimizando la función:

$$\arg \min_C \sum_{i=1}^k \sum_{w \in C_i} \|w - \mu_i\|^2, \quad (1)$$

donde μ_i es la media de los puntos en C_i .

Una vez se han agrupado los aspectos similares en un mismo clúster, construimos la matriz *review-aspect* (ver Figura 1), la cuál tiene la misma estructura que una matriz *término-documento*: el elemento a_{ij} es igual a 1 si la opinión *i* contiene algún aspecto del cluster *j*, si no, es igual a 0. Por último, añadimos a esta matriz la columna de la polaridad de TripAdvisor, es decir, la puntuación que el usuario asigna a su experiencia. Como esta puntuación se basa en una escala del 1 al 5, configuramos las puntuaciones de 1 a 3 como opiniones negativas y de 4 a 5 como opiniones positivas.

²<https://levyomer.wordpress.com/2014/04/25/dependency-based-word-embeddings/>

III-C. SD para describir reglas

Los algoritmos de reglas de asociación tienen como objetivo obtener relaciones entre las variables del conjunto de datos. En este caso, las variables pueden aparecer tanto en el antecedente como en el consecuente. En los algoritmos SD, en el consecuente se asigna la variable clase, que en nuestro caso es la polaridad. Esto significa que los algoritmos de reglas de asociación se pueden adaptar perfectamente a las tareas SD.

El algoritmo Apriori [11] fue diseñado para operar en un conjunto de datos transaccional, en la que cada transacción es vista como un conjunto de ítems o características. Dado un valor de un umbral C de confianza, el algoritmo Apriori identifica todos los conjuntos de ítems que son subconjuntos de al menos C transacciones. Este algoritmo utiliza un enfoque *bottom up*, donde subconjuntos frecuentes son ampliados por un ítem a la vez (este paso se conoce como generación de candidatos). El algoritmo finaliza cuando no encuentra más ampliaciones exitosas de los conjuntos previos de ítems. Apriori-SD es la versión de este algoritmo para SD. Fue desarrollado añadiendo varias modificaciones del algoritmo Apriori C [12].

En nuestra metodología, se aplica el algoritmo Apriori-SD teniendo en cuenta:

- *items* son los aspectos,
- la *transacción* es la matriz review-aspects,
- el *antecedente* es el conjunto de aspectos que aparecen siempre juntos,
- el *consecuente* es la polaridad prefijada, negativa o positiva.

Por lo tanto, el objetivo es el de encontrar los aspectos más relevantes dentro de todas las opiniones negativas de TripAdvisor. Como medidas de evaluación de las reglas extraídas, proponemos emplear el Soporte y la Confianza.

IV. EXPERIMENTOS

En esta sección se evalúa la eficacia de nuestra propuesta en diferentes bases de datos de opiniones. En esta sección, primero se describen los datasets empleados (Sección IV-A), luego se analizan cómo se han agrupado los aspectos (Sección IV-B), y los resultados de las reglas descriptivas (Sección IV-C).

IV-A. El conjunto de datos

TripAdvisor es una compañía estadounidense basada en una página web de viajes que ofrece reseñas de experiencias de viajeros sobre hoteles, restaurantes y monumentos. Este sitio web ha formado la mayor comunidad de viajeros, alcanzando un total de 630 millones de visitantes únicos mensuales, y 350 millones de comentarios y opiniones que cubren más de 7.5 millones de alojamientos, restaurantes y atracciones en 49 mercados en todo el mundo³. Una de las características más relevantes de TripAdvisor es la gran cantidad de opiniones de millones de turistas cotidianos que contiene. De hecho,

³Fuente: <https://tripadvisor.mediaroom.com/uk-about-us>

Monumento	Opiniones	Opiniones con Aspectos	Aspectos
Alhambra	7.217	6.186	9.284
Mezquita	3.526	2.802	3.688
Sagrada Familia	34.558	26.386	18.553

Tabla I

NÚMERO DE OPINIONES, OPINIONES CON ASPECTOS Y ASPECTOS ÚNICOS.

Monumento	Positivo	Negativo
Alhambra	6.781 (93,96 %)	436 (6,04 %)
Mezquita	3.454 (97,96 %)	72 (2,04 %)
Sagrada Familia	32.664 (94,52 %)	1.894 (5,48 %)

Tabla II

DISTRIBUCIÓN DE LAS POLARIDAD POSITIVAS Y NEGATIVAS POR MONUMENTO.

sus opiniones han sido utilizadas como fuente de datos para muchos estudios de AO [4], [13]–[15].

Para evaluar nuestra propuesta, se propone aplicar la metodología en tres de los principales monumentos culturales a nivel nacional: la Alhambra (Granada), la Sagrada Familia (Barcelona) y la Mezquita de Córdoba (Córdoba). Para ello, se han recopilado 45,301 opiniones escritas en inglés, desde Julio de 2012 hasta Junio de 2016. La Tabla I muestra el número de revisiones por monumento, el número de revisiones con aspectos detectados, y el número de aspectos extraídos por el método descrito en la Sección III-A.

Antes de empezar con el análisis de los resultados, se propone analizar la distribución de los sentimientos en cada conjunto de datos. Se establecen las valoraciones de los usuarios de 1 a 3 como negativas, y de 4 a 5 como positivas. Como muestra en la Tabla II, las polaridades están altamente desbalanceadas. Las opiniones positivas son mucho más numerosas que las negativas, lo que significa que los usuarios de TripAdvisor tienden a evaluar positivamente su visita en estos monumentos.

IV-B. Una idea, cien palabras

En esta sección se describen los resultados del agrupamiento de aspectos similares. Un aspecto puede estar formado por una palabra o más de una. En el segundo caso, la representación en *word embeddings* consiste en la media de todas las palabras que forman el aspecto. Además, también existen aspectos que no tienen representación en *word embeddings*, debido a faltas de ortografía, falta de espacios entre dos palabras, etc. En estos casos, no serán considerados para el agrupamiento, y formarán un clúster único. La Tabla III muestra la distribución de los aspectos con y sin representación en *word embeddings*.

Este análisis muestra la agrupación de los clústers, eligiendo k igual a 5, 20, 50, 100, 200, 500 and 1.000. Se observa que para valores muy pequeños de k , los clústers son formados

Monumento	Aspectos	Aspectos con embeddings	Aspects sin embeddings
Alhambra	9.284	5.430	3.854
Mezquita	3.688	2.291	1.397
Sagrada Familia	18.553	10.247	8.306

Tabla III

NÚMERO TOTAL DE ASPECTOS, CON Y SIN REPRESENTACIÓN EN VECTOR.



por gran número de aspectos, lo que hace que el clúster no sea una representación de una idea en común. En cambio, con $k = 500$, la mayoría de clústers corresponden a un mismo concepto, lo que indica que los resultados son coherentes con los de [16]. La Tabla IV muestra algunos ejemplos de clústers con $k = 500$.

Otra ventaja importante de la agrupación de aspectos es la reducción de la dimensionalidad. Como muestra la Tabla III, se obtienen 9.284, 3.688 y 18.553 aspectos por cada monumento, respectivamente. Después del proceso de agrupación con $k = 500$, estos aspectos se reducen a 4.353, 1.897 y 8.806 aspectos, respectivamente.

IV-C. Caracterizando las opiniones negativas de los monumentos culturales

Antes de aplicar algoritmos SD, se analizan frecuencias de los aspectos agrupados en los tres conjuntos de datos. En este análisis, la gran mayoría de los aspectos ocurren menos de 5 veces. La mayoría de estos aspectos corresponden a aquellas palabras sin representaciones vectoriales (ver Tabla III). Por otro lado, los aspectos agrupados obtienen valores con alta frecuencia, lo que tiene sentido porque representan varios aspectos, por ende se suma la frecuencia de cada aspecto que pertenece a ese clúster.

También se analizan los aspectos agrupados más frecuentes en los tres conjuntos de datos. Como se observa en la Tabla IV, en los tres monumentos las palabras más populares están relacionadas con temas arquitectónicos. Por consiguiente, se concluye que los usuarios tienden a describir el monumento mientras opinan sobre su visita en TripAdvisor.

Finalmente, se utiliza la versión del algoritmo Apriori-SD para identificar aspectos en opiniones negativa. Se fija el consecuente de las reglas con la clase *negativa* y se aplica el algoritmo SD para que descubra los aspectos en el lado del antecedente. Las Tablas V, VI y VII presentan las reglas más relevantes de las opiniones negativas de la Alhambra, Mezquita y Sagrada Familia, respectivamente. Se obtienen valores muy bajos tanto para las medidas de soporte y confianza. Los valores de soporte bajos se deben a la escasez de aspectos en todo el dataset. En cambio, los valores bajos de confianza se deben a la poca frecuencia de los aspectos respecto al conjunto total de opiniones.

Analizando el contenido de las reglas, se detectan algunos patrones interesantes en los datos. En las opiniones de la Alhambra, los clústers relacionados con *staff* (personal), *tickets* (tiquets) y *queue* (cola) son los más relevantes. De hecho, el clúster que representa todo lo relacionado con el personal es el que mayor confianza obtiene (0,3), lo que implica que es una característica muy distintiva de esta clase. En ese caso, se concluye que los usuarios de TripAdvisor que han visitado la Alhambra suelen quejar de ese aspecto. El mismo hecho se observa analizando las opiniones de la Sagrada Familia con el aspecto *queue*, a pesar que su confianza es relativamente más baja (0,06). También se observa que existen otro tipo de reglas descriptivas relacionadas con las características del monumento en sí: {*gardens*, *architecture*,

building, *church*, ...}. Esto es debido a que los usuarios de TripAdvisor suelen escribir información objetiva en sus opiniones, es decir, realizan descripciones arquitectónicas del monumento.

V. CONCLUSIONES

Este trabajo presenta una metodología novedosa y eficaz para describir un conjunto de opiniones sobre alguna entidad según los aspectos nombrados. Los algoritmos de AONA extraen información muy detallada de opiniones a través de aspectos, pero no proporcionan una visión general de lo que contiene el texto. En consecuencia, se propuso combinar métodos de extracción de aspectos con técnicas de reglas, para así representar el contenido de un texto. Esta metodología se ha basado en tres fases: (1) Extracción de Aspectos, (2) Agrupamiento de Aspectos y (3) Reglas Descriptivas. Luego, esta metodología se ha aplicado sobre el conjunto de opiniones negativas de tres monumentos culturales, ya que aportan la información más valiosa para mejorar la experiencia del visitante a estos monumentos.

Los resultados muestran que la metodología propuesta es eficaz para resumir un conjunto de opiniones según sus aspectos. La principal ventaja es que ofrece una representación directa del contenido del texto. Se pudo describir una gran cantidad de reseñas culturales a través de aspectos y reglas descriptivas, lo que refuerza la comprensión de las opiniones. Por ejemplo, los visitantes de la Alhambra suelen quejarse del personal, del sistema de tickets y de las largas colas de espera. También se detectó que los usuarios tienden a describir los elementos del monumento visitado, lo que se considera como información objetiva. Este hecho es muy interesante porque no se observa cuando se analizan opiniones de restaurantes u hoteles. Sin embargo, se detectó que las métricas de las reglas son muy bajas, debido a dos razones: (1) el bajo porcentaje de opiniones negativas y (2) la poca frecuencia de los aspectos. También se detecta que en algunos casos, usar la polaridad de la opinión para todos los aspectos que aparecen en ella puede llevar a una mala interpretación del contenido.

Hay varias direcciones a seguir, guiadas por los resultados obtenidos. La primera está por la baja confianza de las reglas. Se propone aplicar la misma metodología pero extrayendo la polaridad del aspecto en concreto. Otra línea futura sería extender esta metodología a diferentes contextos como: restaurantes, hoteles o crítica de productos.

AGRADECIMIENTOS

Este trabajo ha sido desarrollado gracias al proyecto TIN2017-89517-P del Gobierno de España. Eugenio Martínez-Cámara contó con el apoyo del Programa Juan de la Cierva Formación (FJCI-2016-28353).

REFERENCIAS

- [1] B. Liu, *Sentiment analysis: Mining opinions, sentiments, and emotions*. Cambridge University Press, 2015.
- [2] M. Hu and B. Liu, "Mining and summarizing customer reviews," in *Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining*. ACM, 2004, pp. 168–177.

Monumento	Etiqueta del cluster	Contenido del Cluster
Alhambra	FAA	alhambra staff, member of staff, staff member, local staff, ticket staff, entry staff, palace staff, male staff, staffs
Alhambra	BAG	ticket price, ticket collectors, ticket seller, ticket prices, price child ticket, ticket buying, ticket printer, ticket stock
Alhambra	DBI	garden benches, architecture garden complexes, garden areas, garden tiles, manicured garden, botanical garden, garden mazes
Mezquita	B	ceilings, quoined ceilings, domed ceilings, pews, altars ceilings, mosques ceilings
Mezquita	DIE	guard, security guard, security guard berating
Mezquita	BFH	audio tour, audio, audio program, audio rental, multilingual audio, audio devices
Sagrada Familia	BAH	entrance map, gain entrance, entrance slot, entrance queues
Sagrada Familia	BCI	crowd waiting, waits, waiting costs, lines waiting, waiting queue, waiting times, waiting line
Sagrada Familia	DEB	shop, souvenir shop, merch shop, bookshop, adjoint shop

Tabla IV

EJEMPLO DE ASPECTOS AGRUPADOS EN UN MISMO CLUSTER.

Cluster Content	Rule	Cover.	Support	Conf.
staff	{ BBA = 1 } \rightarrow { sentiment = negative }	0,02	< 0,01	0,30
tickets	{ DJG = 1 } \rightarrow { sentiment = negative }	0,05	< 0,01	0,12
queue	{ BH = 1 } \rightarrow { sentiment = negative }	0,05	< 0,01	0,13
alhambra	{ CAF = 1 } \rightarrow { sentiment = negative }	0,27	0,02	0,07
gardens	{ CFE = 1 } \rightarrow { sentiment = negative }	0,17	< 0,01	0,04

Tabla V

MOST RELEVANT RULES OF THE ALHAMBRA MONUMENT.

Cluster Content	Rule	Cover.	Support	Conf.
mosque	{ EHE = 1 } \rightarrow { sentiment = negative }	0,18	< 0,01	0,02
architecture	{ EHF = 1 } \rightarrow { sentiment = negative }	0,16	< 0,01	0,02
place	{ BDE = 1 } \rightarrow { sentiment = negative }	0,06	< 0,01	0,02
arches	{ DJD = 1 } \rightarrow { sentiment = negative }	0,05	< 0,01	0,02
building	{ DDB = 1 } \rightarrow { sentiment = negative }	0,09	< 0,01	< 0,01

Tabla VI

MOST RELEVANT RULES OF THE MEZQUITA MONUMENT.

Cluster Content	Rule	Cover.	Support	Conf.
queue	{ ECA = 1 } \rightarrow { sentiment = negative }	0,05	< 0,01	0,06
view	{ EJB = 1 } \rightarrow { sentiment = negative }	0,06	< 0,01	0,06
construction	{ BGA = 1 } \rightarrow { sentiment = negative }	0,08	< 0,01	0,05
church	{ CBG = 1 } \rightarrow { sentiment = negative }	0,09	< 0,01	0,05
building	{ GB = 1 } \rightarrow { sentiment = negative }	0,08	< 0,01	0,05

Tabla VII

MOST RELEVANT RULES OF THE SAGRADA FAMILIA MONUMENT.

- [3] K. Schouten and F. Frasincar, "Survey on aspect-level sentiment analysis," *IEEE Transactions on Knowledge and Data Engineering*, vol. 28, no. 3, pp. 813–830, 2016.
- [4] E. Marrese-Taylor, J. D. Velásquez, F. Bravo-Marquez, and Y. Matsuo, "Identifying customer preferences about tourism products using an aspect-based opinion mining approach," *Procedia Computer Science*, vol. 22, pp. 182–191, 2013.
- [5] Y. Zhao, B. Qin, S. Hu, and T. Liu, "Generalizing syntactic structures for product attribute candidate extraction," in *Human Language Technologies: The 2010 Annual Conference of the North American Chapter of the Association for Computational Linguistics*. Association for Computational Linguistics, 2010, pp. 377–380.
- [6] R. Collobert, J. Weston, L. Bottou, M. Karlen, K. Kavukcuoglu, and P. Kuksa, "Natural language processing (almost) from scratch," *Journal of Machine Learning Research*, vol. 12, no. Aug, pp. 2493–2537, 2011.
- [7] S. Poria, E. Cambria, and A. Gelbukh, "Aspect extraction for opinion mining with a deep convolutional neural network," *Knowledge-Based Systems*, vol. 108, pp. 42–49, 2016.
- [8] N. Lavrač, B. Kavšek, P. Flach, and L. Todorovski, "Subgroup discovery with cn2-sd," *Journal of Machine Learning Research*, vol. 5, no. Feb, pp. 153–188, 2004.
- [9] T. Mikolov, K. Chen, G. Corrado, and J. Dean, "Efficient estimation of word representations in vector space," *arXiv preprint arXiv:1301.3781*, 2013.
- [10] O. Levy and Y. Goldberg, "Dependency-based word embeddings," in *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers)*, vol. 2, 2014, pp. 302–308.
- [11] R. Agrawal, H. Mannila, R. Srikant, H. Toivonen, A. I. Verkamo *et al.*, "Fast discovery of association rules," *Advances in knowledge discovery and data mining*, vol. 12, no. 1, pp. 307–328, 1996.
- [12] V. Jovanoski and N. Lavrač, "Classification rule learning with apriori-c," in *Portuguese Conference on Artificial Intelligence*. Springer, 2001, pp. 44–51.
- [13] A. Valdivia, M. V. Luzón, and F. Herrera, "Sentiment analysis in tripadvisor," *IEEE Intelligent Systems*, vol. 32, no. 4, pp. 72–77, 2017.
- [14] B. Lu, M. Ott, C. Cardie, and B. K. Tsou, "Multi-aspect sentiment analysis with topic models," in *Data Mining Workshops (ICDMW), 2011 IEEE 11th International Conference on*. IEEE, 2011, pp. 81–88.
- [15] W. Kasper and M. Vela, "Sentiment analysis for hotel reviews," in *Computational linguistics-applications conference*, vol. 231527, 2011, pp. 45–52.
- [16] X. Zhang and Q. Yu, "Hotel reviews sentiment analysis based on word vector clustering," in *Computational Intelligence and Applications (ICCIA), 2017 2nd IEEE International Conference on*. IEEE, 2017, pp. 260–264.