

# Propuesta y desarrollo de una aproximación de generación de resúmenes abstractivos multigénero

## *Definition and development of a multi-genre abstractive text summarisation approach*

Alberto Esteban, Elena Lloret

Departamento de Lenguajes y Sistemas Informáticos  
Universidad de Alicante  
Apdo. de Correos 99  
E-03080, Alicante, Spain  
{aesteban,elloret}@dlsi.ua.es

**Resumen:** En este trabajo se propone el análisis de técnicas adecuadas para el diseño y desarrollo de un enfoque de generación de resúmenes multigénero, tomando como partida distintas fuentes de datos pertenecientes a distintos géneros textuales. El objetivo principal es combinar todos estos géneros y producir un resumen abstractivo, es decir un nuevo texto coherente que capte las ideas fundamentales sobre un tema recogidas en las fuentes de datos originales. Concretamente, para este trabajo hemos utilizado información de reseñas mediante TripAdvisor y de microblogs, mediante Twitter, debido a que los resúmenes generados se han aplicado en un contexto turístico, para proporcionar a los usuarios los aspectos más y/o menos favorables sobre hoteles y restaurantes. La evaluación del método propuesto a través de usuarios reales indica que los resúmenes generados tienen una calidad suficiente y aceptable para ser utilizados en aplicaciones reales.

**Palabras clave:** Procesamiento de lenguaje natural, generación de resúmenes, multigénero, resúmenes abstractivos, turismo

**Abstract:** In this paper, the design and development of a multi-genre abstractive summarisation approach is proposed, taking into account information sources belonging to different textual genres. The main objective is to combine the information in all of these genres and produce an abstractive summary, that is, a new coherent text that captures the main ideas about a topic. Specifically, in this research work, information from reviews extracted from TripAdvisor and microblogs gathered via Twitter was used, since the generated summaries were applied to the tourism sector, to provide users with the most and/or less favourable aspects concerning hotels and restaurants. The evaluation carried out with real users shows that the quality of generated summaries meets the standards and therefore, the summaries can be used in real applications.

**Keywords:** Natural language processing, text summarisation, multi-genre, abstractive summarisation, tourism

## 1 *Introducción*

El gran volumen de datos con el que contamos hoy en día, es evidente en cualquiera de nuestras acciones en Internet. Tanto si buscamos información sobre el último dispositivo móvil puesto a la venta, como si la búsqueda es para encontrar una receta de cocina nos encontraremos con miles de resultados donde elegir. Concretamente, en el dominio turístico, el auge de Internet y las Tecnologías de la Información han hecho que

la forma de buscar un hotel o un restaurante cambie de manera drástica. El método tradicional era consultar en una agencia de viajes o a nuestros familiares si conocían un buen hotel o restaurante en el destino de nuestras próximas vacaciones. En la actualidad esa tarea se ha simplificado mucho, podemos visitar varias páginas especializadas para tener toda la información a nuestro alcance. Sin embargo, nos enfrentamos a un problema diferente al de antaño, y es que si bien es

cierto que antes teníamos menos información de la deseada, ahora es justo lo contrario; existe una ingente cantidad de información la cual necesita de mucho tiempo para ser analizada. Por ejemplo, si se consulta una página especializada para conocer qué hotel podríamos escoger para hospedarnos en Alicante, tendríamos más de 2500 reseñas solamente para el *Hotel Meliá Alicante* y considerando únicamente una fuente de información.

En la planificación de unas vacaciones o una estancia fuera de casa siempre queremos tomar una buena decisión en la elección del hotel donde nos hospedaremos y/o del restaurante que visitaremos. En la práctica, esto conlleva la lectura de las opiniones de los antiguos clientes y como podemos apreciar, el volumen de opiniones hace que no podamos leerlas todas, dado que es inviable en términos de tiempo y coste la lectura de todas y cada una de las opiniones, siendo difícil recordar cada uno de los aspectos citados en cada opinión. Además, en muchas ocasiones cuando visitamos un portal de reservas de hoteles o restaurantes se muestra un breve resumen o gráfica de las características del establecimiento, pero este resumen o gráfica puede presentar un alto nivel de subjetividad para enfatizar las mejores características, lo que impediría a los usuarios obtener información objetiva sobre el mismo.

En base a este contexto, el objetivo principal de este trabajo es el análisis, propuesta y desarrollo de un método para la generación automática de resúmenes abstractivos multigénero. Mediante el enfoque propuesto, los usuarios podrán conocer de manera concisa lo mejor y lo peor de cada establecimiento en base a los comentarios realizados por los propios clientes en distintas fuentes de información (concretamente en reseñas – TripAdvisor y en microblogs – Twitter), evitando así la falta de objetividad que podría tener leer un resumen realizado por el propio establecimiento para así tomar la mejor decisión de donde alojarse o que restaurante visitar.

## 2 Trabajo relacionado

Generar un resumen de forma automática no es una tarea trivial y la mayoría de métodos existentes se centran en generar resúmenes extractivos, en los que el sistema simplemente determina la información relevante y

la extrae (Lloret, 2012). De ahí que uno de los principales retos sea la generación de resúmenes abstractivos donde se genera un nuevo texto coherente a partir de la información relevante, pero también combinando esta información o añadiendo otra nueva no explícitamente presente en la fuente de origen (Saggion, 2011; Carenini, Cheung, y Pauls, 2013; Li, 2015; Khan, 2015). Si a esto le sumamos la heterogeneidad de géneros textuales (sobre todo los que han aparecido en la Web 2.0) y la diversidad de información, nos encontramos ante otro reto mayor y necesario, que es el de abordar la generación de resúmenes multigénero, hasta ahora apenas tratado por la comunidad científica (Lloret y Boldrini, 2015).

De manera similar a los métodos de resúmenes que trabajan con textos de la Web 2.0, nuestro enfoque utiliza un motor de análisis de opiniones para poder distinguir información con polaridad positiva, negativa y neutral, así como técnicas de clasificación para agrupar la información y heurísticas para determinar la relevancia de la misma. Sin embargo, la principal diferencia de nuestro enfoque radica en la generación del resumen a partir de varias fuentes de información heterogénea, puesto que cada género textual tiene sus propias peculiaridades. Por tanto, se requiere de un proceso de tratamiento y comprensión de la información que permita maximizar la coherencia del resumen final, siendo esencial la generación de resúmenes abstractivos en este contexto.

## 3 Fases para la generación de resúmenes abstractivos multigénero

A continuación, se van a detallar cada una de las fases involucradas en el proceso de generación de resúmenes. Como entrada, se dispone de un conjunto de documentos procedentes de varias fuentes de información heterogéneas sobre hoteles y restaurantes (en nuestro caso reseñas generadas por usuarios y tuits) sobre el mismo tema. Como salida, se obtiene un breve resumen abstractivo.

### 3.1 Preparación de los textos

Para esta investigación inicial, hemos optado por considerar la oración como la unidad básica de información para el proceso de generación de resúmenes. Para ello, se ha ll-

evado a cabo la segmentación de oraciones de forma automática usando la herramienta Stanford CoreNLP propuesta por Manning et al. (2014). En el caso de las reseñas, la tarea de la división automática de sentencias es muy complicada dado que las reseñas han sido escritas por todo tipo de usuarios por lo que la informalidad o las faltas de ortografía son muy comunes, lo que puede influir en el rendimiento de la herramienta automática seleccionada. Como el tamaño de un tweet no puede superar los 140 caracteres, y en su mayoría el tweet suele ser una única sentencia, no se ha llevado a cabo ningún proceso de división del texto para este género textual.

Por otro lado, nos interesa saber cuáles son los términos más comentados de cada establecimiento y fuente de información con el objetivo de poder conocer qué tema/s predominan (por ejemplo, habitaciones, servicio, limpieza, etc.). Para obtener dichos términos, llevamos a cabo un proceso de tokenización, eliminación de palabras auxiliares, lematización de las palabras y la identificación de la categoría léxica. Como resultado de este proceso, consideramos los 100 lemas más frecuentes con categoría sustantivo de cada establecimiento y cada fuente de información. Esta información nos ayudará en etapas posteriores para determinar la información relevante y componer el resumen final.

### 3.2 Análisis y clasificación de polaridad

En esta fase, vamos a determinar la polaridad asociada a cada frase/tuit. Debemos conocer si una frase es positiva, negativa o neutra para conocer si el usuario está opinando o no, y si lo hace, saber si es para dar información sobre aspectos buenos o malos. Por ejemplo, la frase “*fantástica habitación*” tendrá una polaridad positiva, mientras que la frase “*la ubicación del hotel era muy mala*” se clasificará como negativa. Para lograr este objetivo se ha utilizado la herramienta propuesta por Fernández et al. (2015). Además, esta herramienta nos dará también la intensidad de opinión, por lo que nos guardaremos ese valor para etapas posteriores.

### 3.3 Agrupación de las frases/tuits

El objetivo de esta fase es agrupar las frases/tuits con el fin de conocer las semejanzas que hay entre ellas. Para ello en primer

lugar agrupamos las frases/tuits según su polaridad mediante la herramienta propuesta por Fernández et al. (2015). Una vez hechos los grupos por polaridad, se ha calculado la similitud entre frases usando el método del coseno a través de la librería *Simmetrics*<sup>1</sup>, determinando empíricamente el umbral de similitud, de tal manera que frases con una similitud de al menos un 30% serán agrupadas en el mismo conjunto. La razón por la que este umbral es más permisivo se debe a que más que buscar frases idénticas o muy similares, lo que queremos es identificar frases que puedan estar hablando de lo mismo. Además, cabe indicar que los grupos de frases son conjuntos disjuntos, es decir, una frase no puede pertenecer a dos conjuntos de frases. Esta decisión se tomó para disminuir la complejidad computacional del proceso de generación de resúmenes.

### 3.4 Determinación de la relevancia de cada frase

El objetivo de esta fase es calcular la relevancia de cada frase para establecer un ranking entre las frases de cada grupo obtenido de la fase anterior. Para ello se puntúa cada frase teniendo en cuenta las siguientes heurísticas:

- **Relevancia de la frase según el tipo de fuente de información a la que pertenece.** Para esta heurística, diferenciamos entre la fuente de información de reseñas y de microblogs, considerando más importante las reseñas en una proporción 70/30, dado que se trata de un tipo de género textual más especializado en opiniones.
- **Relevancia de la frase respecto a su propia fuente de información.** En este caso comparamos los lemas de cada frase perteneciente a una reseña o tuit con el listado de los 100 lemas más utilizados del establecimiento en todas las reseñas o tuits recopilados, respectivamente; si existe el lema en el listado, la puntuación aumentará en base a la frecuencia del lema, del tal manera que se irán sumando las frecuencias de los lemas de esa frase para calcular la relevancia de esa frase. Si el lema no está entre los 100 lemas más frecuentes el valor para ese lema será 0.

<sup>1</sup><https://github.com/Simmetrics/simmetrics>

“La gran mayoría de las opiniones destacan su excelente servicio” ( <i>establecimiento: hotel - aspecto: servicio - puntuación: 9 - sentimiento: positivo</i> )
“Las opiniones indican que el servicio es correcto” ( <i>establecimiento: hotel - aspecto: servicio - puntuación: 8 - sentimiento: negativo</i> )
“Los clientes lo utilizan para hospedarse en viaje de negocios” ( <i>establecimiento: hotel - aspecto: null - puntuación: null - perfil del cliente: de negocios</i> )
“Los clientes recomiendan este restaurante por su magnífica gastronomía” ( <i>establecimiento: restaurante - aspecto: comida - puntuación: 9.5 - sentimiento: positivo</i> )
“Según la valoración de los clientes es uno de los mejores de la ciudad” ( <i>establecimiento: restaurante - aspecto: valoración general - puntuación: 10 - sentimiento: positivo</i> )

Tabla 1: Ejemplo de frases de enlace generadas

- **Intensidad de la frase.** Este valor se obtiene del análisis de polaridad realizado en etapas anteriores y lo consideraremos para dar preferencia a las frases que expresen opiniones de una forma más intensa.
- **Complementos del sustantivo.** La puntuación de los complementos del sustantivo se realiza mediante un análisis morfológico donde intentamos puntuar la aparición de adjetivos seguidos por sustantivos o viceversa con el objetivo de seleccionar las frases que sean más descriptivas. Mediante esta heurística, se valorará positivamente que las frases contengan adjetivos calificando a los sustantivos con el fin de aportar mayor expresividad al resumen.

### 3.5 Preparación de frases para el resumen

En esta fase llevamos a cabo un proceso de conversión de las frases a un modo más impersonal. Al tratar con información procedente de la Web 2.0 existe mucha variabilidad en la manera de escribir, y por tanto es necesaria una forma de homogeneizar la escritura para aportar mayor legibilidad al texto y que no sea un compendio de frases sueltas. Para ello, diseñamos un proceso basado en reglas para convertir la frase a tercera persona del plural a partir de la extracción de información morfológica presente en la propia frase. Por ejemplo, “*Nos alojamos en la planta superior, desde la cual podíamos ver la la inmensidad del mar*” pasaría a “*Se alojaron en la planta superior, desde la cual podían ver la inmensidad del mar*”.

### 3.6 Creación de frases de enlace

En este trabajo, la propuesta de resúmenes abstractivos es una propuesta mixta que combina frases extraídas de las fuentes de información con la creación de un conjunto de frases predefinidas que permiten aportar mayor naturalidad a los resúmenes generados de forma automática, basándonos en la idea sugerida por Gerani et al. (2014). Esta opción sería la más adecuada teniendo en cuenta que trabajamos a nivel de oraciones, dado el tipo de textos tratados. Para conseguir un mayor nivel de abstracción y generar un resumen puramente abstractivo, se necesitaría trabajar con una granularidad más fina, como por ejemplo, cláusulas, o tripletas, tal y como se realiza en (Li, 2015; Khan, 2015) pero en primer lugar sería necesario verificar que las herramientas existentes para este propósito se comportan de la misma manera para textos informales de cara a minimizar la introducción de errores en el proceso.

Se generaron un total de 176 frases predefinidas para los hoteles y 160 para los restaurantes. Dichas frases se clasificaron dependiendo del aspecto al que hicieran referencia, puntuación otorgada sobre el aspecto, perfil de usuario, tipo de opinión, etc. teniendo en cuenta los metadatos que podíamos extraer de las fuentes de información utilizadas. La tabla 1 muestra algunos ejemplos de frases predefinidas. Además se crearon algunas oraciones con el objetivo de introducir las frases elegidas que formarán parte del resumen, tales como “*De lo más comentado por los clientes es que*” o “*Las opiniones de los clientes enfatizan que*”.

### 3.7 Composición del resumen

Debido a la gran cantidad de información y opiniones existentes para cada tipo de establecimiento, como muestra la tabla 2, decidimos generar tres resúmenes por cada establecimiento: i) resumen mixto, que mostrará los aspectos más importantes para bien y para mal del establecimiento; ii) resumen positivo, que mostrará únicamente las características más relevantes que han gustado más a los clientes; y iii) resumen negativo que sólo mostrará los aspectos más importantes que no han gustado a los clientes. El proceso de composición para cada tipo de los resúmenes se detalla a continuación.

Para generar un **resumen mixto**, se llevan a cabo los siguientes pasos:

- Introducir frase predefinida respecto a la valoración general del establecimiento con sentimiento positivo.
- Introducir dos frases predefinidas sobre distintos aspectos del establecimiento y/o perfil de usuario (por ejemplo, limpieza, servicio) con sentimiento positivo.
- Introducir frase predefinida para introducir las opiniones de los clientes.
- Añadir las frases más relevantes del conjunto de frases neutras, positivas y negativas (1 frase por cada grupo, controlando que la similitud de la frase con mayor puntuación no supera un umbral predefinido para evitar así redundancia y contradicciones (caso por ejemplo, de que a un usuario le haya gustado un aspecto del hotel y lo haya valorado positivamente, y a otro el mismo aspecto no le haya gustado y por tanto lo haya valorado negativamente).

La generación del **resumen positivo** y del **resumen negativo**, se realiza de forma análoga a la del resumen mixto pero escogiendo las frases del conjunto de frases clasificadas con polaridad positiva y negativa, respectivamente.

## 4 Experimentación

Para la generación de resúmenes, elegimos como fuentes de información: la página especializada de reseñas TripAdvisor<sup>2</sup> y la red social Twitter<sup>3</sup>, debido por una parte al gran

<sup>2</sup><https://www.tripadvisor.es/>

<sup>3</sup><https://twitter.com/>

Número de hoteles	180
Número de hoteles por ciudad	30
Número de restaurantes	180
Número de restaurantes por ciudad	30
Número de comentarios TripAdvisor	91505
Número de comentarios de TripAdvisor por hotel	235
Número de comentarios de TripAdvisor por restaurante	275
Número de tuits	78713
Número de tuits por hotel	200
Número de tuits por restaurante	240

Tabla 2: Estadísticas de la información extraída

volumen de datos que podíamos obtener y por otra, a que se trataba de fuentes heterogéneas pertenecientes a distintos géneros textuales. A partir de estas fuentes de información, recopilamos un corpus con los comentarios y tuits de restaurantes y hoteles de 6 ciudades nacionales e internacionales (Alicante, Barcelona, Londres, Madrid, Roma y Valencia), utilizando técnicas de crawling y reglas para asegurar de que los comentarios y/o tuits estuvieran en castellano y relacionados con opiniones o comentarios sobre los establecimientos. Además, para el caso particular de los tuits, se eliminaron las menciones (p. ej. @perfil) y los enlaces (p. ej. <http://www.melialicante.com>). La tabla 2 muestra las estadísticas del corpus recopilado.

Para cada hotel y restaurante de cada ciudad, se generaron 3 resúmenes, creando finalmente un total de 1080 resúmenes de forma automática. La tabla 3 muestra, a modo de ejemplo, los tres tipos de resúmenes generados para el hotel *NH Valencia*.

## 5 Evaluación, resultados y análisis

Respecto a la evaluación, se llevó a cabo una evaluación manual con 41 usuarios reales para valorar los resúmenes generados de manera cualitativa. Mediante una pequeña interfaz que contenía todos los resúmenes generados, y para no restringir el resumen que el usuario debía de valorar, se permitió a cada usuario evaluar el tipo de resumen del hotel/restaurante que quisiera sin establecer ningún requisito adicional. Simplemente se les pedía que anotaran el establecimiento elegido y el tipo o tipos de resúmenes consultados. La tarea consistía en puntuar con una nota de 0 a 10, siendo un 0 la peor nota y 10 la mejor cada uno de los siguientes criterios: i) coherencia del resumen: para de-

---



---

**Resumen mixto**


---

El hotel NH Valencia Las Artes según la valoración de los clientes es un buen hotel para hospedarse. La mayoría de las opiniones recomienda el hotel por la buena relación calidad-precio, además los clientes destacan que es excelente para venir en pareja. Entre lo más comentado por los clientes, se encuentra que hotel ubicado en la zona de la ciudad de las artes & ciencias de valencia, lobby pequeño y habitación individual chica pero con un plus inmejorable, una terraza enorme con vista a la ciudad de valencia donde vale la pena apreciar el atardecer y amanecer. Desde la llegada trato e informacion humana muy acogedora las habitaciones modernas, espaciosas y luminosas con hermosas vistas, baños confortables tiene instalaciones para ejercicios, piscina y solarium el bufet para desayuno variado y rico. Por el contrario las habitaciones un poco pequeñas pero cuidadas, pedid mejor las habitaciones que dan a la plaza interior porque sino son algo ruidosas las exteriores.

---



---

**Resumen positivo**


---

El hotel NH Valencia Las Artes según la valoración de los clientes es un buen hotel para hospedarse. El hotel es recomendable para venir en pareja, además el hotel destaca por tener una gran relación calidad-precio. Las opiniones destacan que habitación normal, hotel cerca de la ciudad de las artes y la playa de la malvarrosa La limpieza de la habitación era inexistente, polvo acumulado por toda la habitación, sin embargo el baño estaba limpio. Otro aspecto importante es que hotel muy céntrico y con muy buen servicio, las habitaciones están muy bien y con buenas vistas, el buffet del desayuno muy completo y todo muy bueno, el personal de servicio muy agradable y se puede descansar muy bien en las habitaciones, muy tranquilo para estar en el centro de valencia. Algo a destacar es que a nuestro parecer este hotel fue realmente perfecto, su ubicación es inmejorable, al lado de la ciudad de las ciencias, al lado de un centro comercial grande, al lado de unos restaurantes, se gustó la taberna de maria, tampoco tan alejado del centro.

---



---

**Resumen negativo**


---

El hotel NH Valencia Las Artes según la valoración de los clientes es un hotel correcto para pasar unos días. El hotel cuenta con un servicio del que no debemos preocuparnos según la mayoría de las opiniones, además la limpieza del hotel es aceptable. Las opiniones destacan que la ubicación no puede ser mejor, en la puerta de la ciudad de las artes y las ciencias, cerca del parque, dos centros comerciales y. Adicionalmente las habitaciones y el desayuno muy bien pero es caro la atencion a la hora de *habrir* las habitaciones comunicadas entre si mal. Además algo lejos del centro pero de fácil acceso desde allí, lo peor la limpieza de la habitación, que dejaba algo que desear.

---



---

Tabla 3: Resúmenes automáticamente generados para el hotel NH Valencia (como se observa, debido a que las opiniones han sido extraídas de usuarios reales, a veces podemos encontrar faltas de ortografía (como ocurre en el caso de *habrir*))

terminar si el texto generado mediante las técnicas propuestas tenía sentido como un todo y estaba bien estructurado y enlazado; ii) utilidad: para conocer si el resumen leído le podría servir al usuario o no; y iii) errores ortográficos: para conocer la presencia de faltas de ortografía en los resúmenes, derivados del uso de contenido generado por otros usuarios.

En conjunto, los usuarios evaluaron un total de 332 resúmenes (171 procedentes de hoteles y 161 de restaurantes), variando de

1 a 10 usuarios, el número de personas que evaluaron el mismo resumen. Las figuras 1 y 2 muestran los resultados medios globales y lectura de tipo de resúmenes por tipo de establecimiento, respectivamente. A continuación, realizamos un análisis más detallado de los mismos.

En líneas generales, los resultados obtenidos son buenos, teniendo en cuenta los retos que nos planteábamos con el método propuesto: generación de resúmenes abstractivos multigénero y multidocumento, puesto




Figura 1: Resultados globales de los resúmenes generados para los hoteles y restaurantes

que trabajamos con varias reseñas y/o tuits de un mismo establecimiento. Si nos centramos en la figura 1 podemos observar que los resúmenes sobre hoteles han sido mejor valorados en todos los apartados descriptos, aunque debemos decir que las diferencias respecto a los resúmenes de los restaurantes son mínimas. Este resultado es positivo ya que demuestra que el enfoque propuesto funciona bien para dos dominios distintos y esto nos lleva a pensar que se podría aplicar directamente a otros tipos de productos (películas, libros, móviles, ordenadores,...) y/o servicios (eventos, atracciones,...).

Concretamente, el apartado mejor valorado por los usuario fue la utilidad de los resúmenes alcanzando una nota media por encima de 8. Respecto a la coherencia también se obtuvieron buenos resultados, con notas superiores a 7,40. Sin embargo, el apartado más criticado en la generación de los resúmenes fue la existencia de errores ortográficos y gramaticales en los resúmenes (como el que se ha ilustrado en el resumen negativo de la tabla 3). Es por esto que la nota media otorgada por los usuarios para este criterio se queda cercana al 6, no alcanzando así el notable. Esto nos indica que se deberían refinar la fase de recopilación y extracción de información de fuentes heterogéneas, intentando identificar informalidades y faltas de ortografía. Otra propuesta podría ser añadir un factor de errores gramaticales en la ponderación de las frases para evitar que las frases con faltas de ortografía formaran parte de los resúmenes generados.

Fijándonos en los resúmenes que han obtenido peores valoraciones, identificamos una serie de mejoras que se podrían realizar

para mejorar la calidad del método propuesto, algunas de ellas relacionadas con el uso de las herramientas externas utilizadas, como es el caso de la herramienta de clasificación de opiniones. Si la polaridad de la frase se etiqueta de manera errónea, el resumen generado puede no cumplir la finalidad con la que se creó (por ejemplo, se ha observado que muchas veces los resúmenes negativos contienen frases con polaridad positiva y por tanto, el resultado no es un resumen enfatizando los peores aspectos del establecimiento en cuestión). Para mitigar este error, se podría hacer uso de otra herramienta adicional con el mismo cometido y si ante un mismo texto las dos herramientas obtienen el mismo resultado almacenar el sentimiento de la frase, de esta forma evitaríamos el uso exclusivo de una única herramienta. También se ha observado que el paso de algunos verbos a tercera persona ha comportado faltas de ortografía, que se añadirían a las posibles faltas cometidas por los usuarios autores de las reseñas/tuits. Esto sucede especialmente cuando el verbo es irregular, se debería utilizar una lista completa de los verbos irregulares conjugados, para que en el caso de detectarse la existencia de uno de ellos, se haga una sustitución simple, sin comportar ningún tipo de procesamiento que diera lugar a errores.

Por otro lado, analizamos también qué tipo de resúmenes preferían consultar los usuarios. Los resultados obtenidos se muestran en la figura 2, donde se observa que el resumen mixto es el más consultado, seguido del positivo y finalmente, el menos leído es el resumen negativo. Y esto ocurre tanto para los hoteles como los restaurantes, indicando que al parecer los usuarios prefieren disponer de un resumen donde se expongan tanto los aspectos positivos y negativos sobre un establecimiento y no tanto sólo un tipo de ellos.

## 6 Conclusión y trabajo futuro

En este trabajo de investigación se ha presentado un método para la generación automática de resúmenes abstractivos multigénero y multidocumento para el dominio turístico. Las herramientas lingüísticas utilizadas junto con las heurísticas propuestas nos han permitido obtener un método capaz de producir tres tipos de resúmenes abstractivos dependiendo de la perspectiva que queramos ofrecer (sólo lo mejor, sólo lo




Figura 2: Resultados sobre el tipo de resumen más consultado

peor, o ambos).

Los resultados obtenidos a partir de la evaluación mediante usuarios reales han demostrado la viabilidad y utilidad del método para ser integrado o aplicado a escenarios reales, si bien es cierto que primero se deberían mejorar algunos aspectos, como es el de la corrección ortográfica de los resúmenes producidos que sería la primera mejora que abordaríamos de cara a trabajos futuros. Adicionalmente, nos planteamos integrar técnicas de generación de lenguaje para mejorar la fase de creación de frases de enlace y probar el método de resúmenes en otros contextos, puesto que no sólo tendría aplicación en el dominio turístico. Por ejemplo, en multitud de portales Web, los clientes expresan su opinión acerca de los productos adquiridos, lugares visitados, servicios consumidos, etc. Podríamos utilizar esta información junto con información factual provista por el fabricante del producto, lugar, o servicio como fuentes de información y aplicar el método propuesto para elaborar un resumen que se centre en los mejores y peores aspectos. La mayor dificultad radicaría en el pre-procesamiento de las fuentes de información y el grado de informalidad que éstas contuvieran, ya que el núcleo del método se podría utilizar directamente.

### Agradecimientos

Esta investigación ha sido financiada por la Generalitat Valenciana a través del proyecto DIIM2.0: Desarrollo de técnicas Inteligentes e Interactivas de Minería y generación de información sobre la web 2.0 (PROMETEOII/2014/001), y por el Gobierno de España (MINECO) a través de los proyectos TIN2015-65100-R, TIN2015-65136-C2-2-R.

### References

- Carenini, G., J. C. K. Cheung, y A. Pauls. 2013. Multi-document summarization of evaluative text. *Computational Intelligence*, 29(4):545–576.
- Fernández, J., Y. Gutiérrez, J. M. Gómez, y P. Martínez-Barco. 2015. Social rankings: análisis visual de sentimientos en redes sociales. *Procesamiento del Lenguaje Natural*, 55:199–202.
- Gerani, S., Y. Mehdad, G. Carenini, R. T. Ng, y B. Nejat. 2014. Abstractive summarization of product reviews using discourse structure. En *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, páginas 1602–1613, Doha, Qatar, October. Association for Computational Linguistics.
- Khan, Atif y Salim, N. y. J. K. Y. 2015. A framework for multi-document abstractive summarization based on semantic role labelling. *Appl. Soft Comput.*, 30(C):737–747, Mayo.
- Li, W. 2015. Abstractive multi-document summarization with semantic information extraction. En *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, páginas 1908–1913, Lisbon, Portugal, September. Association for Computational Linguistics.
- Lloret, E. y E. Boldrini. 2015. Multi-genre summarization: Approach, potentials and challenges. En *eChallenges e-2015 Conference*, páginas 1–9, Nov.
- Lloret, Elena y Palomar, M. 2012. Text summarisation in progress: A literature review. *Artif. Intell. Rev.*, 37(1):1–41, Enero.
- Manning, C. D., M. Surdeanu, J. Bauer, J. Finkel, S. J. Bethard, y D. McClosky. 2014. The Stanford CoreNLP natural language processing toolkit. En *Association for Computational Linguistics (ACL) System Demonstrations*, páginas 55–60.
- Saggion, H. 2011. Learning predicate insertion rules for document abstracting. En *Computational Linguistics and Intelligent Text Processing - 12th International Conference, CICLing 2011, Tokyo, Japan, February 20-26, 2011. Proceedings, Part II*, páginas 301–312.