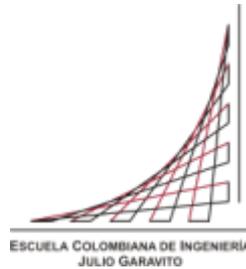


Minería de texto histórica - colaboración al proyecto 'Revealing Cooperation and Conflict Project'

Diana María del Pilar Socha Díaz
Juan Sebastián Martínez Serna
Cristian Camilo Medina Mosquera



Proyecto de grado
Facultad Ingeniería de Sistemas
Escuela Colombiana de Ingeniería Julio Garavito

Director: PhD. Ignacio Pérez Vélez
Co-Director: PhD. Roger Louis Martínez-Dávila

31 de enero de 2017

Índice general

1	Revealing Cooperation and Conflict Project	6
1.1.	Descripción	6
1.2.	Contexto Histórico	7
1.2.1.	Las familias más importantes de Plasencia	9
1.2.2.	Actas capitulares de la Catedral de Plasencia	10
1.3.	El MOOC	11
1.3.1.	Objetivo del MOOC	13
1.3.2.	Datos generados por el MOOC	14
2	Justificación	16
2.1.	Aporte al proyecto Revealing Cooperation and Conflict Project . . .	18
2.2.	Aporte desde la Ingeniería	19
3	Objetivos	22
3.1.	Objetivo general	22
3.2.	Objetivos específicos	22
4	Minería de texto	24
4.1.	¿Qué es?	24
4.2.	Ciclo de trabajo	25
4.2.1.	Corpus	26
4.2.2.	Stop - Words	27
4.2.3.	Lematización	28
5	Antecedentes de minería de texto histórica	30
5.1.	Expressing complex associations in medieval historical documents: the Henry III Fine Rolls Project	30

5.2. Visualization of relationships among historical persons from Japanese historical documents	36
5.3. Information Access to Historical Documents from the Early New High German Period	41
5.4. Information Retrieval from Historical Corpora	49
5.5. Topic Modeling on Historical Newspapers	52
6 Herramientas para minería de texto	57
6.1. KNIME Analytics Platform	57
6.2. RapidMiner	58
6.3. R-Programming y R-Studio	59
6.4. Weka	60
7 Proceso del trabajo	63
7.1. Metodología de trabajo	63
7.2. El contexto de los datos	66
7.2.1. Estructura de los datos	66
7.2.2. Limpieza de datos	69
7.2.3. Flujos de trabajo	72
7.3. Correlaciones	72
8 Conclusiones	75
A Diccionarios	77
A.1. Diccionario de Nombres	77
A.2. Diccionario de Lugares	92
A.3. Diccionario de Roles	100
A.4. Diccionario de Roles - general de la época	104
B Código Python de limpieza de las transcripciones	107
C Código Python para las correlaciones	121
Siglas	124
Glosario	126
Bibliografía	129

Índice de cuadros

4.1. Relación entre los temas y las diferentes áreas de la minería de texto . . .	26
4.2. Ejemplo stop-words	27
4.3. Ejemplo 1 lematización	28
4.4. Ejemplo 2 lematización	29

Índice de figuras

1.1. Imagen del proyecto RCCP	6
1.2. Confederación de la catedral	10
1.3. Fragmento Actas Capitulares de la Catedral de Plasencia	11
4.1. Las siete áreas prácticas del análisis de textos	25
4.2. Diagrama del ciclo de trabajo	27
5.1. Ejemplo de asociaciones a partir de documento estructurado	32
5.2. Proceso para construir la Ontología	33
5.3. Ejemplo de anidaciones entre conceptos, TEI XML	35
5.4. Gráfica de relaciones entre personas y factores históricos	39
5.5. Tabla de relaciones entre personas y factores históricos	40
5.6. Gráfica del resultado del agrupamiento utilizando información por locación	41

5.7. Tabla del resultado del agrupamiento utilizando información por locación	41
5.8. Ejemplo Variantes en grafemas vocálicos	45
5.9. Resultados del sistema al encontrar relaciones	48
5.10. Variantes y sinónimos encontrados en documentos históricos y en documentos modernos	50
5.11. Resultados de la evaluación de desempeño	52
6.1. Pipelining modular de datos	57
6.2. KNIME Analytics Platform	58
6.3. RapidMiner Studio	60
6.4. RStudio	61
6.5. Weka Knowledge Flow	62
7.1. Diagrama CRIPS-DM	64
7.2. Carpetas con todas las actividades del curso	67
7.3. Carpetas de los estudiantes de cada actividad	67
7.4. La actividad del estudiante con los calificadores de la misma	68
7.5. Transcripciones digitalizadas “sucias”	68
7.6. Documento obtenido del proceso de la limpieza	72
7.7. Flujo en KNIME de Tag Cloud para limpieza y extracción	73
7.8. Tag Cloud para limpieza y extracción	74

Capítulo 1

Revealing Cooperation and Conflict Project



The Revealing Cooperation and Conflict project seeks to invigorate the humanities and public's imagination by creating a visually-compelling, data-robust, and historically-lush digital world known as Virtual Plasencia.

Figura 1.1: Imagen del proyecto RCCP

1.1. Descripción

Revealing Cooperation and Conflict Project (RCCP) es un proyecto de investigación histórica, el cual va desde **principios del siglo XIV hasta finales del siglo XVI**. El objetivo principal es “reconstruir tanto los procesos de cooperación como de disputas que surgieron durante un período que alternaba tanto la integración intercultural como la violencia en España y en Europa”[1], conociendo las relaciones de coexistencia entre judíos, cristianos y musulmanes; debido a que durante esta época, en España se vivían fuertes episodios de violencia y además surgía una integración intercultural que alteraba aún más la situación, y fue por esto mismo que jugó un papel clave en la violencia que vivió Europa, por tal motivo, los estudios

para la investigación del proyecto RCCP se centrarán en la ciudad de Plasencia, España, más específicamente en la Catedral de Plasencia, porque esta era la máxima autoridad en la ciudad y se encargaba del manejo de todos los documentos oficiales, “*sabemos que la Catedral de Plasencia transfería dinero regularmente a los banqueros del norte de Europa a principios del siglo XVI, lo que sugiere que la región estaba fuertemente ligada a los mercados y a los asuntos políticos europeos*” [1]

Vale aclarar que “*el proyecto se centra en asuntos interreligiosos porque la evidencia archivística apunta a que las relaciones entre judíos, católicos y musulmanes eran mucho más fluidas, tanto positiva como negativamente, de lo que los estudiosos contemporáneos sugieren y de lo que percibe la opinión pública.*” [1]. Para el análisis y descubrimiento de aquellos acontecimientos relevantes para la investigación, que pueden dar luces acerca de lo que ocurría entonces y puntos en los cuáles se aleja de lo planteado en dichas otras investigaciones contemporáneas, se utiliza como principal fuente de información documentos denominados Actas Capitulares de la Catedral de Plasencia [1].

El proyecto RCCP es dirigido por el **Dr. Roger Louis Martínez-Dávila**, y además es un proyecto sin fines lucrativos, abierto para que todos participen al avance del mismo. “*El proyecto reúne expertos de geovisualización, historiadores, geógrafos, lingüistas e informáticos de EE.UU., Suiza y España, así como académicos y ciudadanos de todo el mundo*” [2]. Además se considera que presenta una innovación en la forma de realizar proyectos de alta complejidad, pues este proyecto “*se aprovecha también el conocimiento de ciudadanos expertos al permitir la colaboración abierta en la transcripción y la indexación de los documentos históricos. Se implementa un formato de base de datos más flexible para captar mejor las relaciones no lineales entre los protagonistas históricos y las distintas circunstancias que rodeaban sus entornos.*” [1]

1.2. Contexto Histórico

En la época medieval la comunidad Judía se hallaba muy repartida, la ciudad donde más se encontraban judíos era en Toledo, en la comunidad de Andalucía se destacaba las ciudades de Sevilla y Córdoba y en Extremadura Cáceres y Plasencia. Las relaciones entre Cristianos y Judíos entre los siglos XI a XIII fueron mayormente pacíficas, pero durante el siguiente siglo las dificultades económicas contribuyeron a hacer de los Judíos un chivo expiatorio de todos los males, a eso se suma la propagan-

da demagógica de Enrique de Trastámara quien atacando a los judíos, quiso ganarse el favor de la población castellana en su guerra contra Pedro I. En consecuencia, durante el siglo XIV se produjeron disturbios antijudíos en ciudades como Barcelona y Valencia, pero el punto más crítico de ese proceso, fueron los violentos ataques en la ciudad de Sevilla, que se fueron propagando por varias ciudades como Córdoba y Andújar, la onda de violencia se extendió rápidamente por el norte de España produciendo asesinatos en Madrid, Toledo, Segovia, Sepúlveda y en la corona de Aragón sufrieron matanzas de judíos en Barcelona, Valencia y Palma. El clima de persecución hizo que muchos judíos abandonaron la península, dirigiéndose al norte de África, cuando en 1492 se confirmó su expulsión definitiva [3].

La expulsión de los Judíos fue ordenada por los Reyes Católicos mediante el Edicto de Granada, la finalidad de éste, era impedir que siguieran influyendo a los cristianos nuevos para que éstos judaizaran. La decisión de expulsar a los judíos está relacionada con la instauración de la Inquisición catorce años antes en la Corona de Castilla y nueve en la Corona de Aragón, porque precisamente fue creada para perseguir a los judeoconversos que seguían practicando su antigua fe[4]. Durante el siglo XV en Plasencia, España, se creó una relación de coexistencia entre las diferentes religiones que había. Judíos, musulmanes y cristianos lograron convivir en comunidades lo que les permitió coexistir mientras en el resto del país la situación era marcada por la violencia. Plasencia tiene una participación importante en la historia de Europa, ya que existía una estrecha relación con los banqueros del norte de Europa, lo que sugiere que estaba estrechamente relacionada a los mercados y los temas políticos en Europa. Allí, se dieron relaciones inusuales que se iniciaron en la frontera de Plasencia, como por ejemplo, se destaca el hecho de que la cooperación y el conflicto hacían parte del día a día; la comunidad a pesar de estar formada por personas de múltiples religiones como judíos o musulmanes o en algunos casos familias convertidas a otras religiones por intereses comunes, formaron alianzas religiosas, políticas y económicas lo cual no sucedía en otros lugares de España. Otro comportamiento poco común era que debido a la gran variedad de recursos con los que contaba Plasencia y los pueblos más cercanos, se buscaba tener un control sobre los recursos como el arrendamiento de tierras y el intercambio de ganado, poniendo en contradicción la situación que se vivía en el resto de España, entre las diferentes religiones.[5]

1.2.1. Las familias más importantes de Plasencia

De acuerdo con los registros de impuestos archivísticos de la Diócesis de Plasencia, en el año 1400 sólo había 119 hombres adultos y sus familias, 40 cristianos (34 %), 50 judíos (42 %) y 29 musulmanes (24 %). Los historiadores especulan que la población total de la ciudad era de aproximadamente de 800 a 1000 habitantes, aunque la población de la ciudad no llegó a 1,000 personas hasta la década de 1570. Así, los judíos y los musulmanes eran un componente clave de la base de la población a lo largo del siglo XV y fueron increíblemente importantes para la economía local. [4]

El Dr. Martínez-Dávila considera de vital importancia el estudiar de cerca no solo relaciones económicas y políticas que se presentaron en la época sino también las relaciones familiares y ciertas familias que ha descubierto que tenían suficiente poder sobre la sociedad de aquel entonces en Plasencia. *“Estamos identificando situaciones en las que las familias rabínicas judías, como la de Loya, trabajaron estrechamente con los conversos (convertidos del judaísmo al cristianismo) y antiguas familias de caballeros cristianos, como la de Santa María y Carvajal, para contrarrestar y equilibrar el poder de los señores, como los Estúñiga, Condes de Béjar y Plasencia. De esta manera, estamos en presencia de alianzas de “extraños compañeros de cama”* [5]. Como ya se dieron luces anteriormente, durante éste periodo existieron tres familias que resaltan debido al poder que éstas ejercían sobre Plasencia, dichas familias, además de lo ya mencionado tenían roles "profesionales" diferentes y religiones, pero mantenían contacto cercano con la Catedral de Plasencia; éstas familias fueron:

- **La Familia Carvajal** eran una familia cuyo rol de “profesional” principal era de caballeros nobles, sus integrantes eran católicos.
- **La Familia Santa María** eran antiguos judíos Ha-levis y arrendaban propiedades de la iglesia a otras familias judías
- **La Familia Estúñiga** eran una familia perteneciente a la elite de la ciudad, eran Condes de Plasencia y Béjar

La familia Carvajal considerada principalmente una familia de caballeros nobles, a finales de 1300 y comienzos de 1500, empezaron a tener una importante participación en los puestos de mayor actividad económica y política de Plasencia junto a la familia Santa María, quienes se convirtieron al cristianismo y desarrollaron una especial conexión con la familia Carvajal. La familia Santa María durante su paso

por Plasencia adquieren varios apellidos como Gutierrez de la Calleja y Fernandez de Cabrero lo que indica que tuvieron que convertirse para continuar con el poder que adquirieron en la catedral, algunos cargos de mayor importancia fueron archidiácono de Plasencia, Bejar, Trujillo, Medellín y Coria, tesorero, cantor, vicario general, obispo, caballero, burócrata real, líder eclesiástico, concejal de la región y concejal de la ciudad. En la siguiente imagen se puede ver que hasta 1420 aparece Gonzalo Gutierrez de la Calleja como tesorero de la catedral, luego el puesto es cedido en 1436 a Gonzalo Garcia de Carvajal y luego a varios integrantes de la familia Santa Maria, lo que sugiere que mantenían una relación cercana las dos familias y lo que buscaban era construir una confederación duradera en la catedral.

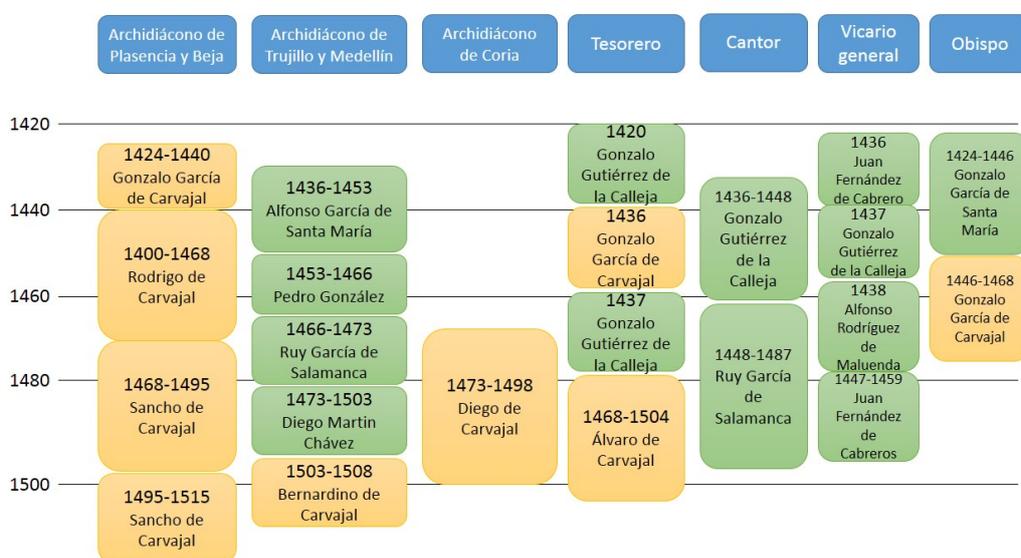


Figura 1.2: Confederación de la catedral

1.2.2. Actas capitulares de la Catedral de Plasencia

Las Actas Capitulares de la Catedral de Plasencia “*son los documentos más representativos de la gestión y administración de los concejos medievales castellanos*”[6] que son pertenecientes a los siglos desde el **siglo XIV hasta el siglo XVI** [7], en estos documentos se recogían todas las decisiones y actuaciones de quienes se encontraban a cargo de la política (principalmente concejiles), en estas se trataban mayormente temas que contienen información sobre la economía y gestión de la ciudad.

La periodicidad que presentaban las Actas Capitulares de la Catedral de Plasencia era semanal [6], aunque en caso de ser necesario de escribir una antes debido a algún evento extraordinario se hacia, también se llegaban a escribir varias actas en un mismo día. Adicionalmente estas presentaban *“una estructura uniforme con un encabezamiento que contiene, entre otros componentes, la data crónica y a veces la data tópica del lugar concreto donde se celebraba la sesión del concejo productora del acta. Seguidamente, se desplegaba el cuerpo del acta”* [6]

Estos documentos tienen el aspecto más crítico del proyecto dirigido por el Dr. Martínez-Dávila puesto que *“son una fuente inestimable para la reconstrucción de los diversos aspectos de la vida de la ciudad de Plasencia”*[6]. En la imagen de la figura 1.3 se evidencia que contiene un pequeño fragmento de un documento de éste tipo, pertenece a la **Unidad documental simple /004 - Acta capitular de 30 de mayo de 1522**, ha sido tomada del archivo municipal de Plasencia consignado digitalmente en la página oficial <http://archivo.plasencia.es/index.php>

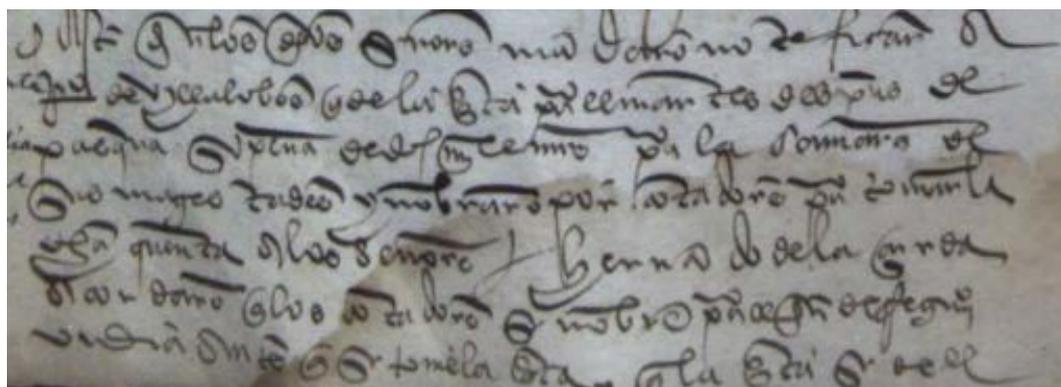


Figura 1.3: Fragmento Actas Capitulares de la Catedral de Plasencia

1.3. EI MOOC

Deciphering Secrets: Cursos Abiertos Masivos en Línea, es un proyecto que involucra una serie de cursos tipo MOOC, que quiere decir que son abiertos y masivos, presentados en línea. Todos aquellos cursos presentados dentro del proyecto son dirigidos por el Dr. Roger Louis Martínez-Dávila con el apoyo tanto de la Universidad de Carlos III de Madrid como de University of Colorado-Colorado Springs. Todos los MOOCs se centran en entender las relaciones y coexistencia de personas en una sociedad marcada por interrelaciones religiosas delicadas, durante la Edad

Media en España. Todos los MOOCS que hacen parte del proyecto *Deciphering Secrets* hacen parte de una iniciativa global de educación, investigación e ingeniería denominada “*Global Citizen Scholars (GCS)*” que tiene como objetivo recuperar la curiosidad cultural sobre la humanidad, fomentar el uso de la tecnología para incrementar la participación y contribución de los estudiantes colaboradores y por último contribuir en la investigación académica que tiene que ver con la cooperación y el conflicto judío, cristiano y musulmán medieval generando así una nueva forma de investigación para el siglo XXI.

Deciphering Secrets comienza en el año 2014, como un curso en línea, masivo y abierto (MOOC), impartido por el Dr. Martínez-Dávila en la plataforma course-ra.org (denominado *Deciphering Secrets: Unlocking the Manuscripts of Medieval Spain*). Tanto en su momento como en el tiempo que estuvo disponible al público, el curso fue todo un éxito atrayendo a más de 10,000 estudiantes de 140 naciones y más de 2,500 estudiantes lo completaron con éxito. A destacar de éste curso que de aquellos estudiantes, más de 1,000 de ellos deciden continuar como lo que se denomina “**ciudadanos académicos**”, colaborando al desarrollo del proyecto Revealing Cooperation and Conflict Project (RCCP). [8]

Para este MOOC los estudiantes debían estudiar la historia antigua de los judíos, cristianos y los musulmanes de la España medieval, comprendiendo dicho periodo y parte del siglo XV. A grandes rasgos, el estudiante aprendería sobre aspectos tanto positivos como negativos de las relaciones entre las personas de aquella época, teniendo en cuenta la coexistencia tanto religiosa como cultural y social que había en Plasencia.

Además de lo anterior y, “*lo que es más importante, los estudiantes contribuyen a un esfuerzo académico internacional ayudando a transcribir manuscritos*”. [8]

Según manifiestan los diseñadores del curso y profesores, como lo son el Dr. Roger L. Martínez-Dávila y Dr. Kathryn Andrus “*Muchos de nosotros creemos que nuestro mundo existe a lo largo de una trayectoria del progreso humano. Este curso trata sobre la duda, el cuestionamiento y las complicaciones. Se abre con la proposición de que nuestro mundo actual no es ni excepcional ni especial, sino que es el beneficiario y el esclavo de la historia.*” [9].

1.3.1. Objetivo del MOOC

En el curso, los estudiantes podrían aprender sobre aspectos tanto negativos como positivos de la coexistencia que se vivía en Plasencia, España, al mismo tiempo que colaboraban en una investigación académica internacional Revealing Cooperation and Conflict Project (RCCP). Por medio del MOOC era posible que se aprendiera también sobre los desafíos que tuvo que pasar la comunidad en una sociedad en donde debían convivir personas de diferentes religiones y culturas. Otro punto importante del que se hacía énfasis en el curso online era en las familias tanto judías nobles, comerciantes, clanes de caballeros y caballeros medievales.

Los inscritos al curso contribuirían al trabajo que se está llevando a cabo con respecto a la reconstrucción de cómo era la interacción, tanto cooperativa como conflictiva, en Plasencia. Todo se realizó por medio del estudio de la España medieval y el entendimiento de algunas temáticas nombradas en las Actas Capitulares de la Catedral de Plasencia (documentos base para el trabajo de transcripción).

Las nombradas Actas Capitulares de la Catedral de Plasencia son los documentos que se utilizaron para que los estudiantes transcribieran su contenido y así mismo se conociera mucho más sobre las personas históricas de aquel entonces, este punto es importante recalcarlo porque gracias a dicha información es posible reconstruir las relaciones interpersonales y entender parte de la importancia que tenía la familia Carvajal dentro la sociedad y así revelar condiciones políticas y religiosas que se crearon, logrando entonces alianzas o conflictos que es importante entender para el fin último del MOOC.

Se resaltan entonces aspectos importantes como, el estudio y evaluación a la vida de judíos, cristianos y musulmanes; las relaciones interpersonales entre dichas comunidades bajo ciertas creencias religiosas y bajo la presión social y cultural que implicó; la transcripción de las Actas Capitulares de la Catedral de Plasencia; el descubrimiento y estudio de personajes históricos.

La primera parte del curso se centró en el estudio de la historia de la Europa medieval general, para pasar a centrarse en el estudio específico de la España medieval y finalmente en la historia de Plasencia. La segunda parte del curso tuvo que ver con la transcripción de las Actas Capitulares de la Catedral de Plasencia por lo que el Dr. Martínez-Dávila incursiona en temas como la paleografía, da a conocer sus estudios y avances en el tema para pasar a permitir que los estudiantes hagan sus

propias transcripciones de fragmentos de los documentos a partir de lo aprendido.

Los objetivos específicos del curso, descritos por los profesores son [9]:

- *Los estudiantes estudian y entienden la historia de la España medieval y la comunidad de Plasencia.*
- *Los estudiantes exploran el mundo de los manuscritos y los textos medievales.*
- *Los estudiantes aprenden a leer documentos históricos.*
- *Los estudiantes transcriben y evalúan documentos.*

1.3.2. Datos generados por el MOOC

“La fuente principal que los estudiantes transcribirán en este curso es el Libro Cinco (1499-1513) de las Actas Capitulares de la Catedral de Plasencia, que es un documento censal de tipo contabilidad que detalla las actividades y transacciones comerciales de la catedral. La mayoría de los estudiantes trabajarán con la transcripción del siglo XIX del texto original del siglo XV. Los estudiantes que deseen desafiar a sí mismos tendrán la oportunidad de trabajar con el texto original de finales del siglo XIV/XV.” [9]

Respecto a lo anterior, es válido mencionar que se vuelve tedioso el proceso para transcribir y digitalizar las Actas Capitulares de la Catedral de Plasencia pues no es tan sencillo entender su contenido a simple vista (como se ve en la imagen (1.3)), por lo que los interesados de todo el mundo colaboran en la realización de las transcripciones por medio de ejercicios prácticos los cuales, son básicamente fragmentos de texto de las actas que se le entregan al estudiante y que éste debe transcribir siguiendo parámetros aplicables que como ya se mencionó, son enseñados a partir de documentos sobre paleografía que ya ha realizado el Dr. Roger L. Martínez-Dávila y que se enseñan durante el curso online.

Las respuestas a los ejercicios propuestos durante el MOOC, se almacenan en una base de datos que es gestionada por el Dr. Roger Louis Martínez-Dávila y que es compartida a éste proyecto con fines académicos; existe cierto nivel de confidencialidad de los datos allí almacenados por lo que se tratan y manipulan con discreción. La base de datos se encuentra en formato *.xlsx* y almacena directamente los resultados arrojados y almacenados por la plataforma *coursera.org*. Dichos resultados son pertenecientes a los de los estudiantes que participaron en el curso para el año 2014.

Se tienen entonces datos relevantes a:

- Código de identificación del estudiante relacionado directamente con una transcripción realizada.
- Información de confidencialidad de la información almacenada.
- Transcripciones identificadas por número de imagen, grupo del curso y relacionadas directamente al estudiante que la realizó.
- Identificación y extracción de años mencionados en los fragmentos de las Actas Capitulares de la Catedral de Plasencia.
- Identificación y extracción de lugares mencionados en los fragmentos de las Actas Capitulares de la Catedral de Plasencia.
- Identificación y extracción de personajes históricos y nombres, mencionados en los fragmentos de las Actas Capitulares de la Catedral de Plasencia.
- Ejercicios marcados como bonos dentro del curso.
- Nombre de la persona y nacionalidad de la persona a la que se atribuye la transcripción almacenada.

La información entregada en dicha fuente de datos o base de datos es el motor de arranque para iniciar con la contextualización y preparación de los datos.

Capítulo 2

Justificación

Considerando que desde diferentes ramas de la informática es posible aportar, desde su propio desarrollo, a ámbitos de estudio que no necesariamente se relacionan con la ciencia y además teniendo en cuenta que los resultados demuestran apoyo no solo para la investigación sino también para la academia, es totalmente provechoso poder colaborar desde la perspectiva del desarrollo de algoritmia y metodologías en proyectos humanísticos como es el caso de *RCCP*. Es de suma importancia encontrar más información que no ha sido realmente evidente acerca de Plasencia y la convivencia entre sus habitantes, lugares y los roles que las personas podían llevar a cabo pues, aportar directamente a dicho proceso da como resultado directamente avances para Dr. Martínez-Dávila en su investigación. Lo anterior es posible trabajarlo con ayuda de las tecnologías y metodologías (adaptables) que la ciencia de la computación expone, para éste proyecto lo más conveniente es hacer uso la minería de texto en este caso histórica, como técnica de recuperación y organización de la información.

Desde los avances que ha tenido la investigación, se conoce que existen algunos interrogantes sobre el desarrollo de la vida de las personas pertenecientes a la ciudad e incluso se han podido descubrir nuevos hechos que hacen que sea necesario explorar más profundamente las Actas Capitulares de la Catedral de Plasencia. Un ejemplo de lo anterior es La Familia Carvajal y el interrogante que surge al rededor de la misma es que La Familia Carvajal vivía una especie de *transformación* pues no seguían las formas de vida tradicionales para la era medieval. Lo anterior hace referencia al hecho de que en aquella época el linaje de un integrante de la familia junto con su rol o actividad a desempeñar estaba prácticamente establecida, entonces, si un padre era sastre, con toda seguridad, sus hijos también lo serían, lo más seguro es que así continuaría generación tras generación.

Por medio de éste desarrollo y la creciente posibilidad de que haya información oculta esperando a ser encontrada, es posible mejorar la calidad de los descubrimientos actuales y también dar una posible respuesta a preguntas puntuales que hayan surgido a lo largo de la investigación. Una de las pregunta más interesantes que el Dr. Martínez-Dávila se plantea (relacionada con el ejemplo de La Familia Carvajal y su inusual actuar) y de la que queda decir que no es fácil de responder sin un análisis detallado, se encuentra formulada específicamente en el vídeo No. 13 del MOOC ya antes mencionado, con título *Video #13 - Lecture: "Jews, Catholics, and Converts: Reassessing the Resilience of Convivencia in Fifteenth Century Plasencia, Spain"* justo en el minuto 00:43:17, corresponde a la siguiente: *"What changed for this carvajal family during this time period that would have facilitated or could have helped to created a new family?"* (¿Qué ha cambiado para ésta familia Carvajal durante este período de tiempo que habría facilitado o podría haber ayudado a crear una nueva familia?); esto después de haber explicado un poco más a fondo lo que se menciona anteriormente, lo relacionado con el linaje familiar y las tradiciones familiares de aquella época.

Desarrollando metodologías que permitan a historiadores contestar a preguntas como la anterior, que para el mundo de la investigación histórica son realmente de mucho valor para reconstruir el pasado, hace mucho más fácil que los expertos puedan probar o refutar sus hipótesis planteadas. No solo es posible dar respuesta a preguntas puntuales sino que también se generan muchas otras junto con su posible explicación, no solo enriquecerán las diferentes investigaciones, también permitirá resultados más profundos y certeros.

Además de lo anterior, gracias a la lectura detenida y el análisis de las Actas Capitulares de la Catedral de Plasencia por parte del historiador, a él le ha sido posible identificar que la historia que estas presentan difiere en muchos aspectos con la historia que se presenta actualmente, claro está, centrado siempre el foco de la investigación. Aunque en la práctica es imposible encontrar la verdad absoluta sobre el pasado, pues depende de aspectos externos como también de la percepción de cada académico, sí es posible encontrar "respuestas" mucho más acertadas y certeras sobre lo que sucedía. El uso de herramientas tecnológicas e informáticas sobre la gran cantidad de información que se tiene actualmente para estudiar, sobre Plasencia y en sí los aspectos económicos, políticos y sociales de la época, puede ayudar de manera absoluta a tener un mejor conocimiento y dominio de los textos y datos en un tiempo

más razonable, por lo que es importante destacar que, con el afán de fomentar la participación de dichas herramientas tecnológicas e informáticas en diferentes casos en donde puedan aportar valor (en este caso, las ciencias humanas), se desea apoyar al desarrollo del proyecto RCCP con el fin de cumplir con los objetivos propuestos además de colaborar a la comunidad y dejar huella con un producto que permita mejorar el proceso que un historiador, en este caso Dr. Martínez-Dávila, debe llevar a cabo para analizar grandes volúmenes de textos e información obteniendo así mejor dominio y entendimiento de aquel corpus.

A partir de lo anterior, cabe resaltar que con éste proyecto, no solo se apoya al desarrollo de las diferentes tecnologías como también al desarrollo de la línea de la minería de texto histórica sino que también es posible apoyar al desarrollo del proyecto de carácter internacional y abierto para llegar así a refutar o aprobar la hipótesis propuesta.

2.1. Aporte al proyecto Revealing Cooperation and Conflict Project

Desde el punto de vista del proyecto *RCCP* es de suma importancia, no solo para el desarrollo del mismo, sino también para el Dr. Roger Louis Martínez-Dávila, encontrar una posible forma de analizar más rápidamente el corpus base con el que cuenta, con el fin de seguir construyendo y avanzando en su proyecto, junto con lo anterior también es interesante para él, poder ver plasmadas gráficamente aquellas relaciones “ocultas” ya mencionadas para recrear de manera más próxima el lugar. Desde el punto de vista de la investigación histórica y humanística, lo que ocurría en aquel lugar y en aquel periodo junto con el hecho de que las actuales hipótesis pueden desviarse un poco de la situación real que se vivía, es bastante interesante de responder y de analizar pues apalanca directamente el desarrollo de éste campo de trabajo.

Haciendo uso de la minería de texto sobre las Actas Capitulares de la Catedral de Plasencia que está analizando el Dr. Martínez-Dávila, es posible no solo agilizar, sino también hacer menos tedioso el proceso de trabajo que debe hacerse para responder a los diferentes interrogantes. El volumen de textos y de datos con los que cuenta el historiador es considerablemente grande y el esfuerzo que debe hacerse para gestionar tal masa es bastante. Teniendo en cuenta que ya se cuenta con una parte las Actas Capitulares de la Catedral de Plasencia digitalizadas junto

con las respectivas transcripciones, pueden adecuarse para fines tales como análisis y clasificación, relación entre palabras, localización, descubrimiento de lugares y personas, entre otros; así entonces es posible crear objetos de análisis, **gracias a la intervención de las ciencias de la computación y la tecnología, que de otra manera sería muy difícil obtener**, para dar un paso más allá analizando con más precisión y exactitud, logrando entonces tener un conocimiento profundo sobre los textos en tópicos no evidentes, preservar información valiosa y dentro de lo más destacable, se logran disminuir considerablemente los tiempos empleados para los análisis y lectura de los documentos.

Por medio de la minería de texto sobre las Actas Capitulares de la Catedral de Plasencia, no solo es posible lo anterior, sino que es mucho más sencillo encontrar factores ocultos sobre el ambiente social, político, económico y religioso que se vivía en aquel momento en Plasencia, España, y sus alrededores y que llevaron al curioso desenvolvimiento del lugar y sus pobladores, a pesar de las inusuales condiciones para la época.

Al permitirse un diálogo “dinámico” entre la investigación histórica y las tecnologías emergentes se fomenta la experimentación y la colaboración pues dichas disciplinas juntas, están generando un impacto significativo en el contexto académico desde hace más de una década (ver capítulo 5) .

2.2. Aporte desde la Ingeniería

Debido a que el proyecto es multidisciplinario y se destaca la constante comunicación y colaboración entre las Humanidades y las Ciencias de la Computación y la informática, también es importante recalcar el aporte que se hace desde la ingeniería, que por su puesto tiene un tinte más técnico. El aplicar minería de texto, implica todo un proceso que involucra entendimiento de tecnologías, algoritmos que en su mayoría estadísticos, herramientas, metodologías y otros, que permiten llevar a cabo el proceso de trabajo de la minería (ver capítulo 7) .

A pesar de la suma importancia que tiene la historia que se pueda descubrir, es de interés también la metodología que se llevará a cabo para encontrar las relaciones interpersonales no evidentes, a partir del entorno del lugar, descrito en los documentos base que se están utilizando. La metodología que se aplicará para la gestión de la información con la que se cuenta (en formato no estructurado) nace a

partir de ideas ya existentes que han surgido en otras investigaciones, lo principal es que junto con la colaboración al proyecto “*Revealing Cooperation and Conflict Project (RCCP)*” se podrá proponer una metodología apoyada en la tecnología y en La Minería de Texto Histórica, que funcione bien para investigaciones de carácter histórico o afines y que permita analizar colecciones de texto con el fin de obtener un cuerpo de datos con el que se pueda capturar temas claves junto con conceptos para descubrir relaciones ocultas entre su contenido, patrones o tendencias de los datos y la información, sin conocer términos o conceptos fijos que haya usado el autor para expresarse.

Cabe resaltar que debido a la naturaleza del proyecto, aunque esté ligado a la investigación y disciplina histórica, también está ligado a investigación de carácter tecnológico y de cierta manera científico debido a que para poder generar conocimiento a partir del gran volumen de datos e información con el que se trabaja, es necesario ahondar en metodologías, técnicas y herramientas que permitan el análisis, modelamiento, tratamiento, limpieza, calidad y otros aspectos fundamentales de los datos y su preparación.

Se pretende hacer un aporte significativo no solo a la comunidad que le interesa la historia y el pasado sino también a la comunidad orientada a las ciencias o ramas de la matemática, estadística, ingeniería y afines, que les pueda interesar éste desarrollo. La metodología que se llegue a proponer junto con una serie de diccionarios para la investigación, que contienen palabras clave de la época (ver capítulo 3), estarán disponibles para quien requiera utilizarlos en otras investigaciones o incluso para resolver algunos otros interrogantes de ésta misma.

Dentro de las especificaciones de innovación que se plasman en la presentación del proyecto “*The revealing Cooperation and Conflict Project*” se indica que las bases de datos del mismo son enteramente de código abierto junto con las codificaciones de las API. Dentro de dichas bases de datos se encontrarán los datos que sean descubiertos por la comunidad a partir de la transcripción e indexación de las Actas Capitulares de la Catedral de Plasencia. Dado que el núcleo del proyecto dirigido por el Dr. Martínez-Dávila está basado en contar con un innovador Sistema de información geográfico (Geographic Information System) (GIS) que involucre datos sociales, económicos y demográficos será entonces vital para el éxito del mismo contar con conocimiento que difícilmente puede ser generado sin hacer uso de técnicas o herramientas para el manejo y entendimiento de grandes volúmenes de

datos.

Capítulo 3

Objetivos

3.1. Objetivo general

Presentar al proyecto **Revealing Cooperation and Conflict Project (RCCP)** una metodología con base tecnológica para optimizar los tiempos y mejorar calidad de análisis de las Actas Capitulares de la Catedral de Plasencia, esto mediante técnicas de **minería de texto**.

3.2. Objetivos específicos

- Conocer, entender y profundizar respecto a los nodos y diferentes funcionalidades con las que la herramienta de software KNIME cuenta para realizar minería de texto.
- Utilizar la herramienta KNIME para realizar la Minería de Texto sobre los documentos denominados Actas Capitulares de la Catedral de Plasencia, lo que se refiere específicamente a realizar la construcción algorítmica que permita gestionar las Actas Capitulares de la Catedral de Plasencia en base a las diferentes funcionalidades de la plataforma.
- Indagar e investigar sobre otros proyectos afines que hayan surgido anteriormente o que surjan paralelamente a éste para de ésta manera contar con visión sobre las diferentes técnicas y metodologías que pueden aplicarse para hacer Minería de Texto y encontrar asociaciones complejas.
- Colaborar en el desarrollo de una nueva línea en la minería de texto: **la minería de texto histórica**.

- Elaborar una metodología para la gestión y análisis de documentos de carácter histórico, teniendo en cuenta las diferencias y similitudes entre el español antiguo y el español moderno.
- Generar tres diccionarios para hacer análisis de documentos de la época (siglo XIV a XVI) de Plasencia, España. Dichos diccionarios quedan para el libre uso de la comunidad y otras investigaciones de la misma índole o que aplique.

Diccionario de nom-
bres

Diccionario de roles

Diccionario de luga-
res

- Generar un diccionario de *stop-words* (ver capítulo 4.2.2) para el análisis de textos comprendidos en los siglos XIV a XVI de Plasencia, España.

Capítulo 4

Minería de texto

4.1. ¿Qué es?

La minería de texto también es conocida como minería de datos de texto [10], esta consiste en la extracción de información y patrones no triviales contenidos en los diferentes documentos de texto usados para el análisis, con esta se busca identificar, deducir y ampliar el conocimiento sobre los documentos de texto tratados [10].

Tanto la minería de texto como el análisis de texto son una *sombrilla* muy amplia que involucra diferentes términos y técnicas especializadas para el procesamiento de los diferentes datos estructurados y los datos no estructurados [11], si bien estos algoritmos pueden llegar a ser completamente diferentes, en el fondo tienen el mismo objetivo, “realizar una transformación de texto a números” [11], esto con la finalidad de poderlos aplicar completamente a todo el documento.

Es complejo dar una única definición de minería de texto puesto que esta involucra siete áreas de conocimiento de siete campos diferentes, aunque todos se encuentran relacionados por el campo de la estadística tal y como se aprecia en el diagrama de Venn en la figura 4.1 [11].

Las áreas que complementan la minería de texto son:

1. Search and Information Retrieval
2. Document clustering
3. Document classification
4. Web mining
5. Information Extraction
6. Natural Language Processing
7. Concept extraction

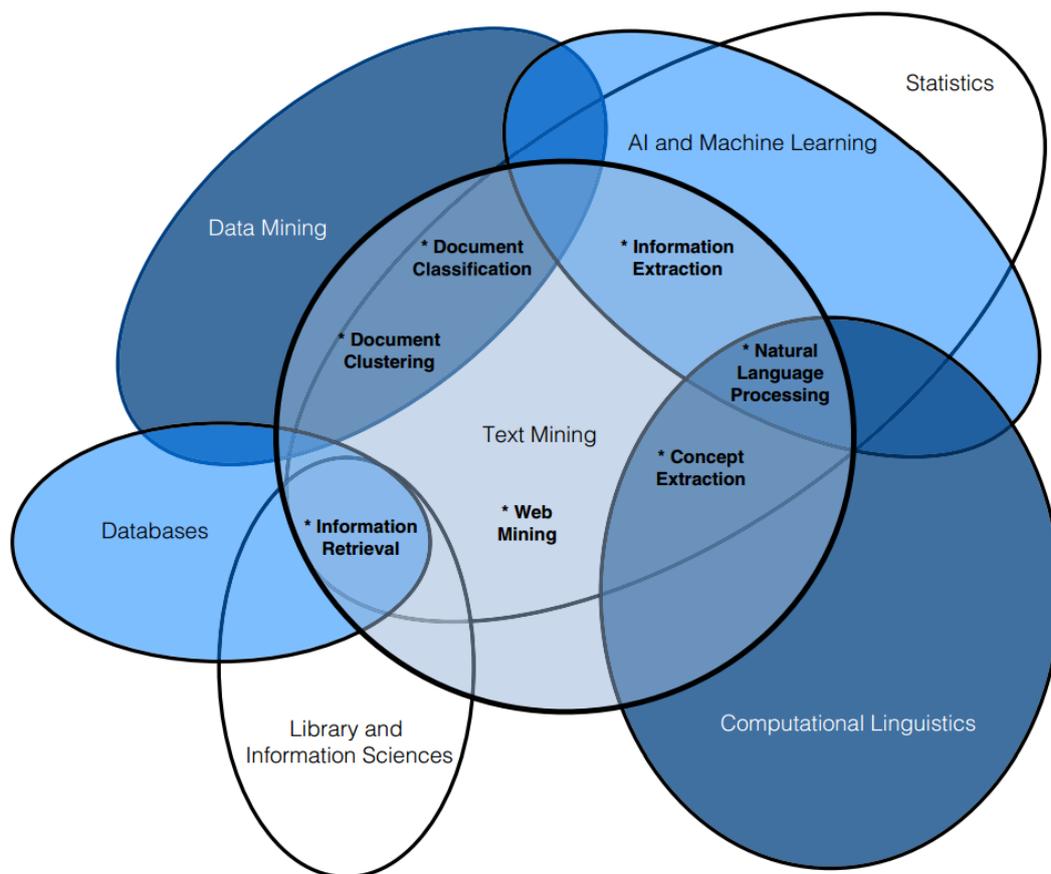


Figura 4.1: Las siete áreas prácticas del análisis de textos

Estas siete áreas que existen debido a la comunicación con los campos de estadística, Inteligencia artificial (Artificial Intelligence) (IA) y aprendizaje de máquina, lingüística computacional, minería de datos, Bases de datos (Databases) (DB) y bibliotecas y ciencias de la información, esto es porque gracias a la combinación de las técnicas propias de cada campo es posible generar mejores resultados, en la tabla 4.1 presentada en el libro *Practical Text Mining* [11] se evidencian solo algunos de los temas más comunes en el campo de la minería de texto y el área mayormente usada para ‘atacar’ dicho tema.

4.2. Ciclo de trabajo

Al igual que la minería de datos, la minería de texto sigue un marco de trabajo, o proceso, muy similar, el cual va desde la definición del problema hasta la implementación de los modelos matemáticos planteados buscando dar solución o respuesta a el problema establecido al comienzo del proceso; la diferencia radica en que sigue los siguientes cuatro pasos dentro del proceso metodológico

Tema	Área
Búsqueda de palabras clave	Search and Information Retrieval
Resumen de documentos	Search and Information Retrieval
Agrupación de documentos	Document clustering
Semejanza de documentos	Document clustering
Selección de documentos por características	Document classification
Análisis de sentimientos	Document classification, Web mining
Clasificación de documentos	Document classification
Descubrimiento electrónico	Web mining
Rastreo web	Web mining
Extracción de entidades	Information Extraction
Etiquetado gramatical / PoS	Natural Language Processing
Tokenización / Lematización	Natural Language Processing
Solución de interrogantes	Natural Language Processing, Search and Information Retrieval
Identificación de sinónimos	Concept extraction
Modelamiento de temas	Concept extraction

Cuadro 4.1: Relación entre los temas y las diferentes áreas de la minería de texto

4.2.1. Corpus

También conocido como **text corpus**, en inglés, es el conjunto de documentos que van a ser usados para el trabajo de investigación, generalmente son documentos digitales, aunque pueden ser físicos.

Es importante tener en cuenta que entre más grande sea el **corpus**, será posible que la recuperación de la información se haga de manera más completa.

Para el caso particular de este trabajo el **corpus** estará compuesto por las Actas Capitulares de la Catedral de Plasencia, más específicamente aquellas que ya se

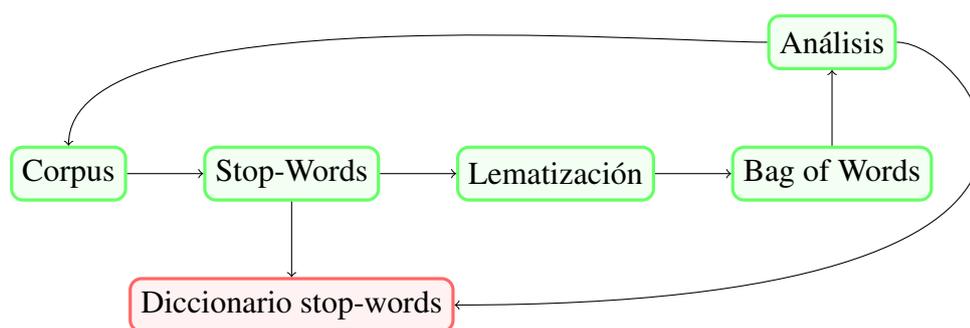


Figura 4.2: Diagrama del ciclo de trabajo

encuentran digitalizadas.

4.2.2. Stop - Words

Este paso consiste en la eliminación de pronombres, artículos y proposiciones, esto debido a que éstos no hacen un mayor aporte al trabajo de análisis, es decir, es indiferente si se encuentran o no en el texto, a esto también se le conocen como palabras vacías. Esto tiene como finalidad ayudar a realizar un análisis con mayor velocidad, en los siguientes pasos.

Ejemplo 1

Antes del proceso (Corpus)	He adoptado una perra con sus cachorros.
Eliminación de los stop-words	He adoptado una perra con sus cachorros.
Después del proceso	adoptado perra cachorros

Cuadro 4.2: Ejemplo stop-words

En el ejemplo del cuadro 4.2 se puede observar después de la eliminación de los **stop-words** la finalidad de la oración no se ve afectada, es más rápida de leer y analizar.

Éste es un proceso muy usual, debido a que los motores de búsqueda de Internet lo aplican siempre, un claro ejemplo es Google [12], pues para realizar una búsqueda más rápida y precisa es necesario este paso, puesto que de no realizarse esto incluiría en la búsqueda páginas que hagan uso de estos artículos, pronombres y/o proposiciones, lo cual resulta bastante ineficiente.

Ejemplo 2

Palabras	Lema
Perro, Perros, Perritos, Perra, Perras, Cachorro	Perro

Cuadro 4.3: Ejemplo 1 lematización

Es importante tener en cuenta que casos no se debe de aplicar éste proceso, puesto que se pueden eliminar partes de un nombre, por ejemplo, si tenemos una banda de música llamada *Los de adentro* y le aplicamos este procedimiento, el nombre de la banda se vería reducido a *adentro*, en este caso si cambia completamente el sentido, pues los **stop-words** identificados son una parte fundamental del nombre de la banda [12]; para evitar esto es necesario tener un filtro en el cuál se le indique al proceso cuales no son **stop-words** como en este caso.

Para la correcta identificación de los **stop-words** es necesario contar con un diccionario de los mismos. Para éste se puede hacer uso de uno ya *existente*, crear uno nuevo, esto se puede deber a que *no existe* uno sobre el idioma tratado o porque el existente no se aplica en su totalidad para el caso de estudio.

4.2.3. Lematización

En la lingüística computacional la lematización es un proceso importante y necesario al momento de realizar un procesamiento automáticamente del **corpus**. Es la representación de una normalización de los datos de texto en donde cada palabra se analiza para posteriormente reducirla a un lema [13, 14], la normalización del texto es crucial en los idiomas ricos en palabras, como lo es el caso del español, pues, es posible expresar una misma idea con una gran cantidad de palabras diferentes [14].

Para la realización correcta de éste paso es necesario hacerse con un **diccionario morfológico** lo más completo posible [14], pues de este se depende para lograr un buen resultado para la disminución de errores durante todo el proceso siguiente de la minería de texto.

La lematización consiste en la eliminación de plurales, pasados, futuros, entre otras cosas, esto con la finalidad de dejar solamente la raíz de la palabra, ésta será el lema de la palabra [13, 14].

Ejemplo 3

Después de stop-words	adoptado perra cachorros
Proceso de Lematización	adoptado perra cachorros
Después del proceso	adoptar perro perro

Cuadro 4.4: Ejemplo 2 lematización

En el ejemplo del cuadro (4.3) el resultado de la lematización es **perro**, puesto que todas las palabras usadas hacen referencia al mismo animal, que es *perro*, es decir, todos estos son sinónimos, diferenciación entre masculino y femenino y plurales.

En el ejemplo del cuadro (4.4) se puede ver claramente el proceso de **lematización**, en el cual se analiza cada palabra y se cambia por el lema correspondiente, tal como se mostro en el ejemplo 4.3. Ya en éste paso es donde, al leer nosotros mismos la frase, esta ya pierde un poco su significado original, puesto que ahora da a entender que se va a adoptar uno o dos perros. Es en este paso donde se suele pensar que al cambiar las palabras el resultado del análisis no va a ser correcto, este pensamiento ocurre debido a que se piensa en un análisis no matemático, puesto que matemáticamente hablando se trata de una simple simplificación de las variables, por lo tanto el resultado del análisis no se ve afectado [13, 14].

Antecedentes de minería de texto histórica

5.1. Expressing complex associations in medieval historical documents: the Henry III Fine Rolls Project

Se da inicio a este proyecto en El King's College London (Universidad pública de investigación) desde el Centro de Informática para las Humanidades, el cual específicamente, hace parte del Departamento de Humanidades Digitales de la Universidad. Los responsables de la investigación y divulgación de los resultados de la misma son Arianna Ciula, Paul Spence y José Miguel Vieira. La investigación se centra en el hecho de que, el uso de tecnologías asociadas con la gestión del conocimiento y manejo de información, puede ayudar a expresar y mostrar gráficamente asociaciones complejas entre “entidades” en textos históricos. Para esta investigación el texto ha sido clasificado o tratado en formato XML. En particular, se pretende facilitar la interpretación de información oculta dentro del texto como lo son asociaciones implícitas en el texto.

Para llevar a cabo la investigación se hizo uso de algunas tecnologías y/o metodologías que están directamente ligadas con los objetivos de la misma, un ejemplo de ello es RDF o Resource Description Framework que se entiende como ciertas especificaciones que establece la Word Wide Web Consortium para el modelado de información que se implementa en recursos web y se centra en poner a disposición un modelo para el intercambio de datos en la web. La anterior y otras herramientas se utilizaron con el fin de obtener información explícita sobre personas, lugares y

entidades dentro del texto. Todo lo anterior es demostrado bajo el desarrollo del proyecto denominado “*Henry III Fine Rolls project*” que además, logra exponer una de las problemáticas más importantes que se presentan en los proyectos e investigaciones de carácter humanístico y es la brecha que existe entre la información primaria o las fuentes de información primaria con las que cuenta un historiador y el contexto de interpretación que existe a partir del análisis de los mismos; por medio de la realización de la investigación y del proyecto *Henry III Fine Rolls project*, los autores logran proponer un modelo que representa la complejidad entre las dos partes que componen la brecha y que además facilita el proceso de interpretación de las fuentes de información.

Entrando más en detalle acerca del proyecto *Henry III Fine Rolls project*, es importante destacar el corpus principal sobre el que se trabajó, según el mismo artículo del proyecto, se sabe que existe “*un total de sesenta y cuatro rollos que contienen alrededor de 800 membranas de pergamino, uno para casi todos los cincuenta y seis años del reinado de Enrique III de 1216-72, sobreviven en Los Archivos Nacionales. Cada rollo se compiló en latín por un puñado de escribas. Tomados como un cuerpo de evidencia documental, 'los rollos son de Importancia en el estudio de la historia política, social y económica y del gobierno y la administración a nivel local y nacional' ”* [15]. Debido a que los textos estaban en latín, se hace el esfuerzo por publicar algunos fragmentos, sin definición de tiempo, en inglés para que pudieran ser consultados por medio de un sitio web publicado hacia el año 2007, allí también se hicieron publicaciones de índices o diccionarios de lugares, personas y temáticas; traducciones del texto, imágenes del texto, representaciones gráficas de las asociaciones encontradas, entre otros aspectos relevantes.

La fuente de información o los rollos mencionados anteriormente, se manipularon de tal manera que se cumpliera con los estándares para la investigación y además se permitiera una preparación y manipulación de los mismos más sencilla, haciendo uso del marco de trabajo denominado Electronic Text Encoding and Interchange fue posible representar la estructura de los documentos y así mismo generar un recurso que pudiese ser utilizado como guía no solo para extraer información sino para entender el contexto histórico de la época profundizando en aspectos que el investigador/historiador pudiera tener interés como por ejemplo política, economía, cultura. **De los resultados más importantes de la investigación se destaca el hecho de que, “para el periodo de 1216 a 1224 (un cuarto del periodo cubierto por la primera fase del proyecto) los investigadores ya habían sido capaces de identi-**

car 3.436 hombres, 499 mujeres, alrededor de 4.070 lugares y 1.159 sujetos.” [15].

Los resultados más inmediatos que se obtuvieron al capturar relaciones implícitas en el texto, siguiendo la estructura y resultados obtenidos a partir del marco de trabajo se reflejaron en la obtención de conocimiento a un mayor nivel de profundidad acerca de las personas, los lugares y entidades; la cantidad de información obtenida acerca de ello, se basa en que fue posible que a cada persona se le asociaran inmediatamente componentes referentes a sus relaciones con otras personas, a su ocupación, lugares en común, etc. Después de obtener dicho resultado era necesario continuar con el proceso y entonces obtener las relaciones complejas y no tan evidentes contenidas en el texto. Los datos relevantes se extraen y se hace uso de tecnologías como lo fueron RDF y OWL6 (con RDF se definió la estructura de la información y con OWL se define por medio de programación, la estructura semántica de las relaciones de tal manera que la semántica compleja pueda reconstruirse desde conceptos más simples); en palabras de los autores: *“En términos más prácticos, nuestra elección de RDF / OWL fue impulsada por una serie de factores, entre ellos: nuestro interés en facilitar las interconexiones con otros proyectos de Humanidades Digitales, especialmente aquellos que abarcan períodos y áreas temáticas similares, utilizando estándares internacionales en el corazón de la Semántica Web; La madurez relativa de las herramientas de soporte; Y el hecho de que RDF / OWL puede expresarse en formato XML, lo que permite la fácil re-definición de los datos para la entrega de la web.” [15]*

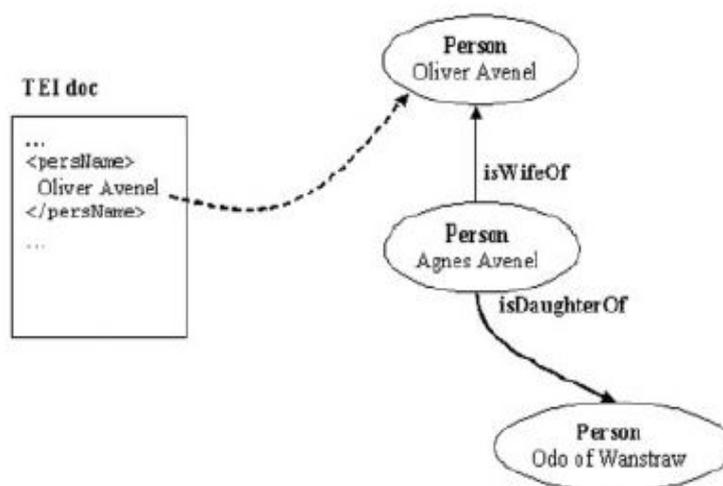


Figura 5.1: Ejemplo de asociaciones a partir de documento estructurado

El siguiente paso fue iniciar con la creación de la ontología para lo cual fue nece-

sario hacer un análisis con el debido detalle requerido para poder representar dicho conocimiento correctamente, los documentos TEI fueron la clave para recrear la ontología y así mismo incluir la información para aquel modelado. Por la naturaleza de la creación de la ontología, los personajes, lugares o entidades no existirían en la misma hasta que no fueran mencionados en el corpus a partir del cual se modela; del XML resultante, se extraía información como por ejemplo relaciones familiares y se traspasaban a la ontología para ir formando el contexto poco a poco, los parentescos o relaciones muy específicas debieron ser incluidas “manualmente” dentro de la ontología.

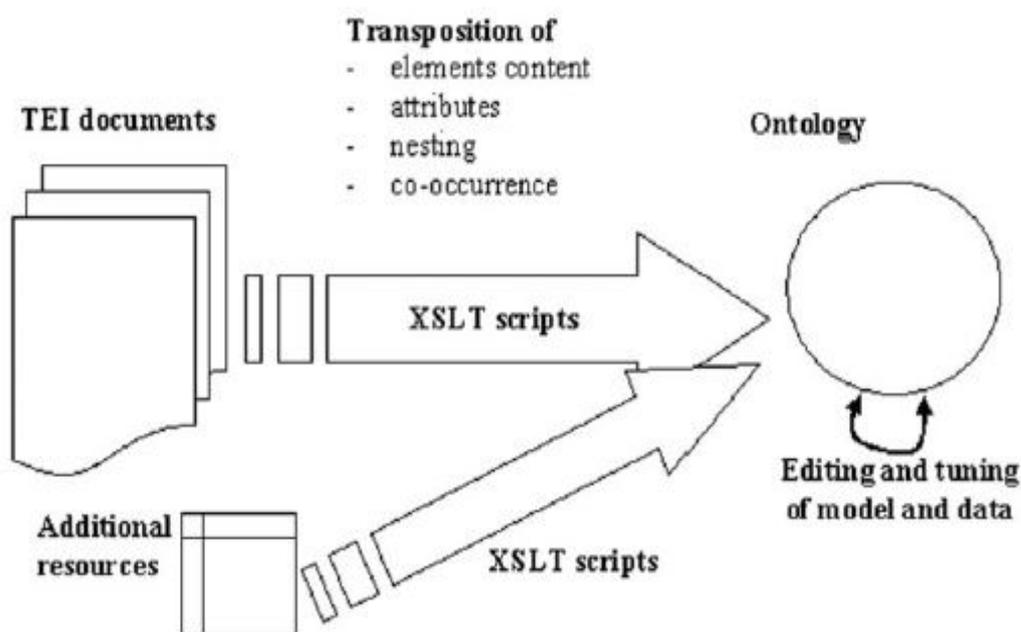


Figura 5.2: Proceso para construir la Ontología

Para nutrir aun más la ontología fue necesario encontrar patrones de comportamiento de los datos y de la información de tal manera que el proceso para encontrar elementos anidados fuera de forma automatizada y se redujeran los tiempos considerablemente, junto con lo anterior también fue posible descubrir diferentes categorías de sucesos al que podía pertenecer una asociación; por ejemplo el que hubiese un anidamiento de un nombre de un lugar dentro del nombre de una persona podía implicar que dicho lugar se refiriese al apellido del personaje (*Nombre_Personaje* de *Nombre_Lugar*), también podía implicar la relación estrecha entre dicho lugar y la persona. El proceso anterior muestra una pequeña parte del nivel de automatización al que se pretendía llegar y además lo útil que es al momento de encontrar elementos anidados directamente relacionados con co-ocurrencias y sus relaciones semánticas.

Tener la información en formato XML fue clave porque de cierta manera ratificaban con seguridad el contexto de la información y dan seguridad a la reconstrucción histórica que se lleva a cabo.

Además de todos los beneficios que la construcción de la ontología trajo al proyecto “*Henry III Fine Rolls project*”, también se destaca el hecho de que este modelo podría servir a otras investigaciones de la misma índole y que traten también un tiempo determinado a partir de fuentes históricas. Para expresarlo más fácilmente, la ontología se forma a partir las siguientes especificaciones:

- Los documentos que permiten contextualizar la realidad descrita en los rollos finos utilizados como fuente principal. Se usaron también documentos externos que dieran información afín adicional.
- Se realizó con el fin de describir anidaciones entre personas, lugares y entidades pertenecientes al texto, dar contexto a la posible realidad modelándola y además asegurando de cierta manera el contexto resultante.
- Fue clave para encontrar categorías de roles dentro del texto, finalmente a ello se llegaría. Por ejemplo una categoría válida es el rol que desempeñó una persona que apareció en los textos, por ejemplo Mayordomo, arzobispo, etc; otra categoría válida es un rol que especifica una relación directa con otro rol principal, como por ejemplo Sastre del Rey.
- Para las clasificaciones existen “clases” por medio de las cuales se especifica un rol y posibles subroles. Igual ocurre con las entidades y lugares.

En la visualización 5.3 es posible ver un ejemplo de como resultan las conexiones entre la fuente de datos, la ontología (con “clases incorporadas”).

Después de obtener los resultados aplicando el método y todo el proceso propuesto se llega al punto de publicación. Por el hecho de que se trabajó con tecnologías que facilitan el intercambio de datos web, la publicación de los dichos resultados en la página web de la institución fue un poco más sencilla. Los desarrolladores del proyecto hicieron uso de xMod, un marco de publicación diseñado por el mismo Centro de Informática para las Humanidades. El uso de OWL facilitó la capacidad de procesar datos lógicamente para seguir apoyando a la ontología y así encontrar información no evidente en las fuentes (una persona pudo ser “rastreada” dentro de los resultados por su nombre o sus diferentes maneras de aparición en las anidaciones XML, sin la ontología no sería posible. También fue posible clasificar las relaciones

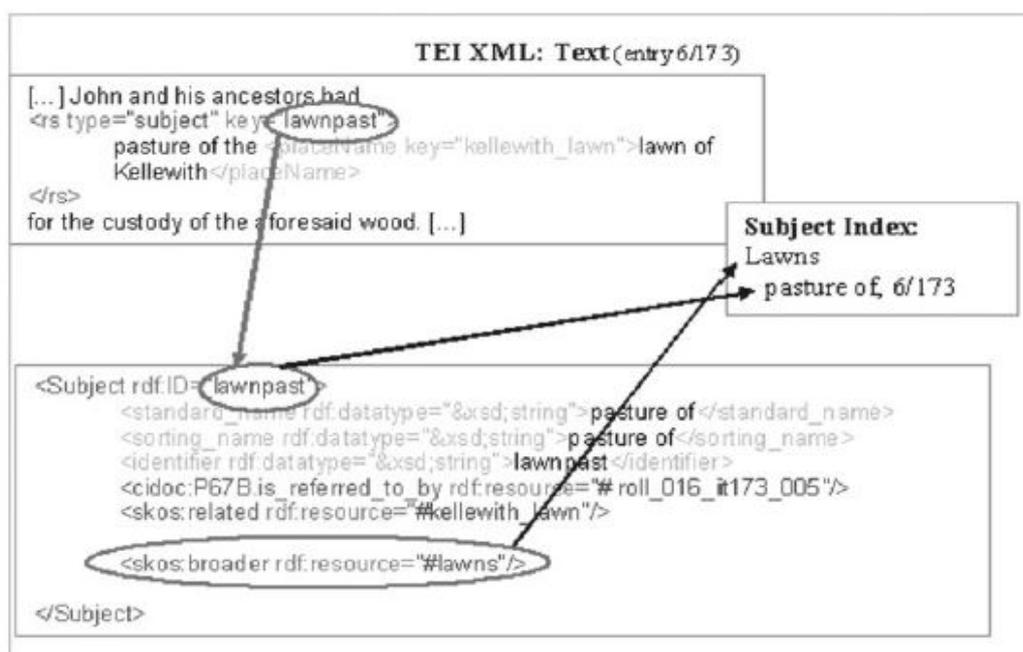


Figura 5.3: Ejemplo de anidaciones entre conceptos, TEI XML

y asociaciones).

En cuanto a los resultados y conclusiones del proyecto, los autores lograron generar un enfoque de transferible a otros proyectos históricos destacando el hecho de que la facilidad que brinda las tecnologías utilizadas hace que la publicación y personalización de publicación de los resultados sea más sencilla y reduzca tiempos. En cuanto a lo que se descubrió desde la fuente de datos, puede ser muy útil para otras investigaciones y otros investigadores ya que puede que las personas, lugares y entidades que aparecen en este caso en los rollos finos, también aparezcan en otros documentos de la misma época y del mismo carácter, lo que es un gran avance en cuestión de iniciar otra investigación. Aunque la ontología no demuestra un contexto totalmente certero, pues la historia depende de la percepción, si tiene un nivel de adaptabilidad bastante destacable, si se diera el hecho de que en otra investigación se descubriera información nueva o se modificara de una u otra manera el contexto dado a la misma, sería evidentemente sencillo permitir que los cambios se hagan efectivos basados en certeza de interpretación.

En cuanto al proceso de análisis de las anidaciones y la relación con la ontología, aun quedaban algunos aspectos por retocar en cuanto a los niveles de anidación, clases y subclases pues los niveles de los mismos en cierto momento dejaban de

tener la lógica y el contexto propuesto. La ontología a parte de esto sí permitió que los investigadores refinaran las asociaciones encontradas apeándose o no al texto, es por ello que da cierta libertad al investigador para que juzgue el contexto e incluso identifique aspectos que no parezcan ser como se indica. Como conclusión valiosa de los autores se destaca “*consideramos que el uso de un enfoque ontológico, junto con el marcaje XML de TEI XML para la codificación de las fuentes, representa un poderoso marco técnico para proyectos históricos, que equilibra el respeto al texto como testigo único con la necesidad de representar su Contexto histórico e interpretación.*” [15]

5.2. Visualization of relationships among historical persons from Japanese historical documents

Este proyecto que fue realizado por Fuminori Kimura, Takahiko Osaki, Taro Tezuka, Akira Maeda hacia el año 2013 y surge debido a que los documentos históricos en Japón ya hace un tiempo están siendo digitalizados y por tanto el auge por analizarlos y generar conocimiento en áreas humanísticas va en crecimiento. Surge un percance parecido al problema actual que se tiene con éste proyecto pues los textos claramente no se encuentran en Japonés moderno por lo que la principal justificación para llevar a cabo todo éste proceso es el hecho de presentar una metodología que permita encontrar y visualizar asociaciones poco evidentes entre personajes históricos japoneses a partir de textos históricos, teniendo en cuenta datos sobre lugares y nombres relevantes. Además de lo anterior los autores expresan que es la posibilidad para apalancar el surgimiento de herramientas basadas en componentes tecnológicos que permitan su aprovechamiento al máximo en campos humanísticos en los que sea necesario gestionar textos con japonés pre-moderno ya que hacerlo en las herramientas actuales es absolutamente complicado.

Para realizar la metodología de la que se habla, se hace uso de la **minería de texto histórica** debido a que es posible obtener información que no es muy evidente al analizar manualmente o simplemente al leer el documento, esto con el fin de encontrar relaciones entre las personas según sus actividades y locación geográfica y sacar conclusiones a partir de ello. Se hizo uso de un documento histórico denominado *Hyohanki* del cuál se sabe que es un **diario** escrito por **Noburoni Taira**, correspondiente desde el año **1112 hasta 1187** [16]. Con respecto a éste documento

se resalta el hecho de que es fácil obtener el orden del documento porque las fechas y la escritura diaria definen el mismo.

En este caso, también fue necesario realizar un diccionario que contiene los nombres propios que se mencionan o aparecen en el diario, esto es importante porque de ésta manera se puede dar contexto a dichos nombres para encontrar las asociaciones complejas que se requieren; debido a que los diccionarios que usan las herramientas con las que se aplican las técnicas de minería de texto claramente no contienen “soporte” lingüístico para el japonés pre-moderno es un paso muy importante y, al igual que acá, en éste proyecto que se quiere llevar a cabo es sumamente importante tener los diccionarios ya mencionados en los objetivos específicos debido a que las herramientas actuales (específicamente KNIME) al igual que ocurre con el japonés pre-moderno, tampoco cuentan con “soporte” para el procesamiento del lenguaje natural correspondiente al español antiguo.

Entrando un poco más en detalle con respecto a lo anterior, las técnicas parten de extraer todos los nombres de personas y de lugares existentes en el diario, también se incluyeron los sobrenombres. Para conocer qué tan fuertes eran las relaciones se usó la modalidad de co-ocurrencia entre el nombre de una persona, o su sobrenombre, con el nombre de un lugar, o el sobrenombre de este; la co-ocurrencia ocurre si alguno de dichos nombres propios de personas y de lugares aparecían en el mismo párrafo o en un mismo bloque específico de texto, entonces se considera que existe co-ocurrencia. Se hace mención al hecho de que puede ocurrir que aunque halla co-ocurrencia entre una persona y un lugar, eso no implica que aquella persona hubiera estado o no ahí, aunque en la mayoría de casos ocurre que la persona si estuvo allí en algún momento.

Para realizar la visualización de las relaciones interpersonales usando la información de las co-ocurrencias entre información sobre personas y l se genesneraban vectocacioores de características, en dicho vector cada locación se considera como una dimensión del vector en el espacio, seguidamente se hace uso de el algoritmo de **K-MEANS** formando un total de tres *clusters*. Los clusters en este caso representan que personas de las mencionadas eran seguidoras de un emperador o de otro según los indicados en el diario, uno correspondiente a los seguidores del emperador Suto-ku, otro correspondiente a los seguidores del emperador Goshirakawa y el último mostrando una participación neutral entre ambos emperadores. Los vectores son utilizados para calcular la similitud entre ellos y así poder deducir las relaciones

interpersonales entre personas sin la necesidad de confiar en o recurrir únicamente a los resultados de las co-ocurrencias directas.

El algoritmo correspondiente para aplicar la técnica o metodología propuesta en este caso es el siguiente:

1. Obtener nombres de personas y lugares a partir del texto.
2. Contar la frecuencia de las co-ocurrencias entre cada nombre de una persona y el nombre de un lugar.
3. **Por cada persona:** se construye el vector de características compuesto por el número de co-ocurrencias con el nombre de un lugar que sea componente del vector.
4. Calcular las similitudes entre las personas por medio de la comparación de los vectores ya construidos.
5. Se realizan los clusters usando el método K-means.
6. Realizar las visualizaciones de las relaciones usando las similitudes entre vectores y los resultados de los clusters.

Para la visualización del resultado de los clusters se hace uso de una biblioteca de **Java** la cual es de código abierto y permite dibujar la estructura por medio de grafos. El nombre de aquella biblioteca es - **Java Universal Network/Graph Framework**. *“Es una biblioteca de software que proporciona un lenguaje común y extensible para el modelado, análisis y visualización de datos que se puede representar en forma de gráfico o de la red”* [17]. La arquitectura JUNG soporta una gran variedad de representaciones como grafos dirigidos, no dirigidos, multimodales, bordes paralelos, entre otros. Además de lo anterior facilita la creación de herramientas para analizar datos complejos y las relaciones entre entidades. Se apoya en distintos algoritmos de la teoría de grafos, **minería de datos** y análisis de redes sociales para poder agrupar, descomponer, optimizar, hacer análisis estadístico, etc.

A continuación, en la visualización 5.4 se muestra el resultado visual de graficar el resultado de los clusters según la persona y los factores históricos.

En la visualización 5.4 se diferencian las personas según lo siguiente: quienes son seguidores del emperador Sutoku están representados por el nodo cuadrado y quienes siguen al emperador Goshirakawa están representados por el nodo circular.

5.2. Visualization of relationships among historical persons from Japanese historical documents

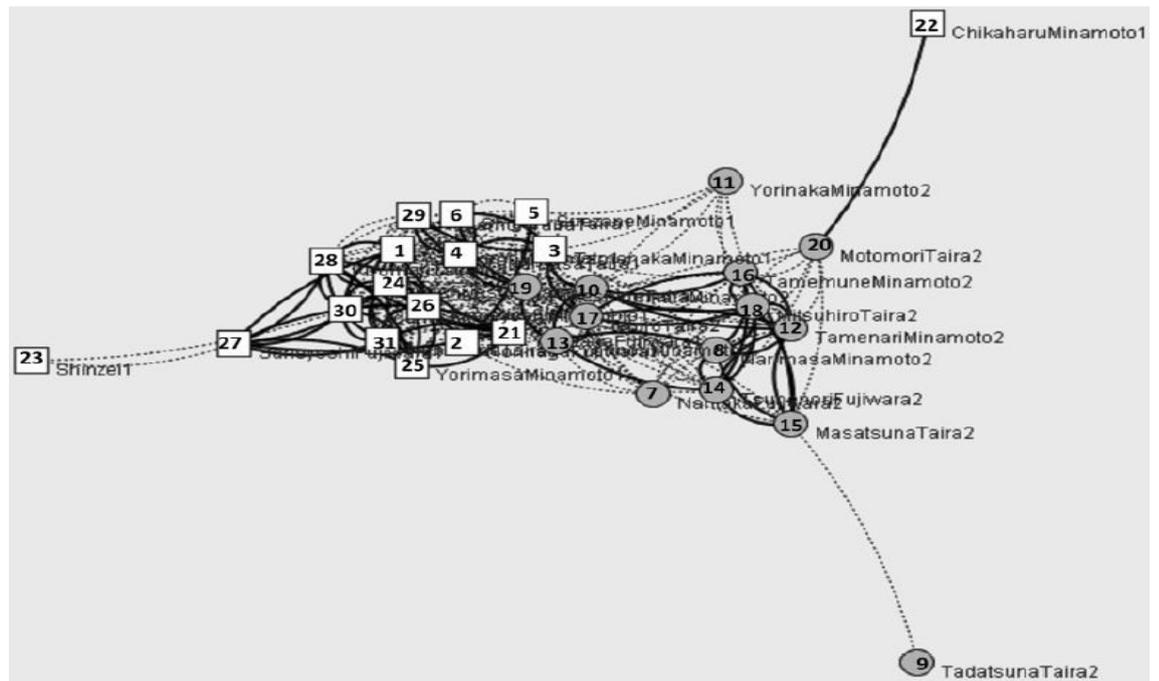


Figura 5.4: Gráfica del relaciones entre personas y factores históricos

El número que está dentro de cada nodo corresponde al mismo número que tiene asociado cada persona en la tabla 5.5. Las líneas se dibujan si la similitud entre los vectores es superior a 0.4; si la línea es punteada quiere decir que la similitud entre dichos dos vectores es entre 0.4 y 0.7 y si la línea es continua quiere decir que la similitud entre los vectores es mayor a 0.7.

En la tabla 5.5 se muestran los resultados de los clusters que resultaron de utilizar la metodología planteada para el desarrollo de la investigación teniendo en cuenta las relaciones interpersonales y los nombres de los lugares, como se mencionó anteriormente son 3 agrupaciones que según las similitudes entre los vectores, también se clasifican según el emperador del que son seguidores o si son neutrales entre ambos:

En la visualización 5.6 ya es posible ver gráficamente las relaciones, ésta vez usando información por locación de la persona y los resultados de la tabla 5.5. Esta vez se evidencian los clusters de la siguiente manera: El cluster 1, quienes son los personajes neutros están representados por el nodo triangular; el cluster 2 corresponde a aquellos que son seguidores de Sutoku representados por el nodo circular; finalmente el cluster 3 corresponde a los seguidores de Goshirakawa representados por el nodo cuadrado.

5.2. Visualization of relationships among historical persons from Japanese historical documents

	Cluster 1	Cluster 2	Cluster 3
Faction of former Emperor Sutoku	1. Nagamori Taira	7. Naritaka Fujiwara	21. Yorinaga Fujiwara
	2. Norinaga Fujiwara	8. Narimasa Minamoto	22. Chikaharu Minamoto
	3. Tamenaka Minamoto	9. Tadatsuna Taira	
	4. Tadamasa Taira	10. Yorikata Minamoto	
		11. Yorinaka Minamoto	
		12. Tamenari Minamoto	
		13. Yorinori Minamoto	
		14. Tsunenori Fujiwara	
		15. Tadatsuna Taira	
		16. Tamemune Minamoto	
		17. Iehiro Taira	
		18. Mitsuhiro Taira	
Faction of Emperor Goshirakawa	5. Suezane Minamoto	19. Koreshige Taira	23. Shinzei
	6. Shigemori Taira	20. Motomori Taira	24. Yoshitomo Minamoto
			25. Yorimasa Minamoto
			26. Tameyoshi Minamoto
			27. Saneyoshi Fujiwara
			28. Kiyomori Taira
			29. Yoshiyasu Minamoto
			30. Tadamichi Fujiwara
			31. Nobukane Taira

Figura 5.5: Tabla del relaciones entre personas y factores históricos

Al final de la investigación, después de tener los resultados de la misma y los objetivos del proyecto cumplidos, se consulta con conocedores del tema, involucrados en temas de índole humanístico si los resultados son prometedores y expresan conocimiento útil o simplemente la metodología propuesta no es aplicable. Los resultados se evidencian en la tabla 5.7.

Para cada criterio de evaluación presentado, quienes respondieron la “*encuesta*” tienen la posibilidad de responder usando puntajes de 1 a 7, siendo 1 el caso en que estuvieran totalmente en desacuerdo, 4 ni de acuerdo ni en desacuerdo y 7 totalmente de acuerdo. Se concluye entonces de la metodología propuesta lo siguiente:

- Existe credibilidad histórica: La puntuación del método para éste punto supera las expectativas con un 4.50 por lo que se deduce que el método es capaz de mostrar relaciones complejas no evidentes entre personas mencionadas dentro del texto.
- Aprueba ser novedoso ante métodos tradicionales humanísticos: El método es puntuado con 5.25 en cuanto a la novedad de la investigación y el descubrimiento histórico.
- Es posible usarlo en otras investigaciones humanísticas o históricas: La metodología propuesta tiene potencial para poder hacer descubrimientos históricos en investigaciones afines y es puntuado con 5.00

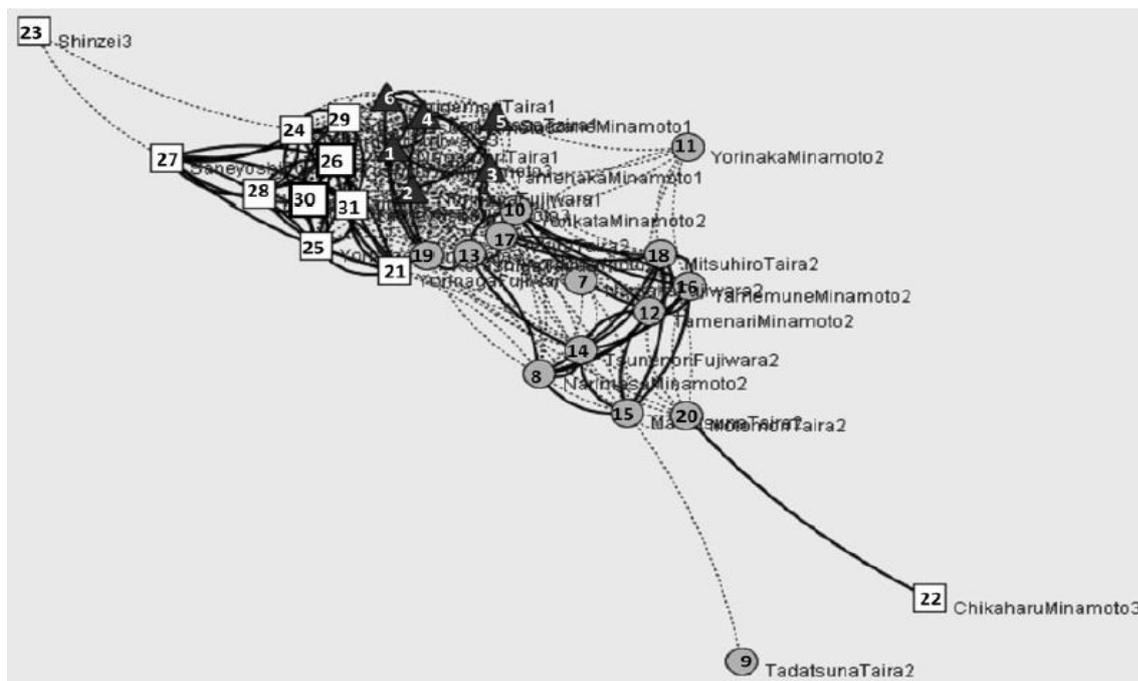


Figura 5.6: Gráfica del resultado del agrupamiento utilizando información por locación

Evaluation criteria	User				Average
	A	B	C	D	
Historical credibility	5	5	4	4	4.50
Novelty for historical research	5	5	5	6	5.25
Availability for historical research	5	5	5	5	5.00
Average	5.00	5.00	4.67	5.00	4.92

Figura 5.7: Tabla del resultado del agrupamiento utilizando información por locación

- Se comprueba la efectividad de usar la locación de personas para hacer agrupamientos, el resultado es mucho más preciso y confiable.

5.3. Information Access to Historical Documents from the Early New High German Period

Actualmente, refiriéndose a literatura y textos que circulan por la web, una gran cantidad pertenece a la categoría de libros y documentos históricos pero aun así, todavía hay una gran cantidad de ellos incluyendo también repositorios de texto, con-

siderados incluso patrimonio cultural mundial, que siguen sin presentarse en formato digital; es por esto que ha surgido la necesidad de realizar esfuerzos solucionar dicho problema y hacer que dicha información sea accesible y pública, no sólo desde las humanidades sino desde otras disciplinas como la informática.

La digitalización de dichos textos históricos es la oportunidad perfecta para poner en práctica técnicas de acceso y manejo de grandes volúmenes de información, como por ejemplo Search and Information Retrieval o Minería de Texto. Hoy en día la colaboración entre las humanidades y la ciencia ha crecido más que nunca y el trabajo se ha visto simplificado gracias a los avances que han surgido para poder presentar y compartir información (tanto homogénea como heterogénea) de investigación y educativa considerada valiosa.

Andreas Hauser, Markus Heller, Elisabeth Leiss, Klaus U. Schulz y Christiane Wanzeck son quienes llevaron a cabo el informe inspirados en el interés de permitir acceso electrónico a miles de documentos y literatura lo que no solo aliviana el trabajo de historiadores, filósofos, lingüistas o Paleólogos sino que también permite compartir conocimiento de forma masiva con todos aquellos interesados y que no necesariamente son expertos. Para la presentación de sus resultados enfocaron sus esfuerzos primeramente, en mostrar las diferentes observaciones que hicieron con respecto al hecho de que muchos de estos textos no están en lenguas modernas (difieren en muchos aspectos del lenguaje moderno) y como eso influye a la hora de realizar técnicas de Search and Information Retrieval o minería de datos y obtener conclusiones. En segundo lugar se enfocaron en demostrar el desarrollo de su trabajo, focalizados en demostrar estrategias que ayudan a relacionar las palabras y el comportamiento del lenguaje moderno con las variaciones correspondientes de las lenguas antiguas. La fuente principal de información sobre la que trabajaron fueron una colección de documentos perteneciente al periodo del Nuevo alto alemán temprano.

El problema principal que surge al querer indexar textos de forma digital es la cantidad de formas o variantes que pudo haber tenido una palabra o incluso un grafema para escribirse según el periodo pues no necesariamente se hizo de la misma manera durante toda la historia. Las técnicas modernas de Search and Information Retrieval y minería de datos hasta ahora están evolucionando para contemplar dichos obstáculos y los trabajos recientes son con los que se ha dado inicio a la resolución de este tipo de inconvenientes. Las siguientes preguntas son claves para empezar a

tratar el problema de manera certera y profunda: [18]

1. *¿Qué tipo de alteraciones o variantes pueden ser identificadas en la ortografía de los distintos lenguajes? ¿Cómo se podrían describir dichas variaciones formalmente?*
2. *¿Cuáles son las consecuencias directas en los distintos campos como lo son Search and Information Retrieval y la minería de texto?*
3. *¿Cómo pueden ser adaptadas las técnicas existentes para hacer frente al problema haciendo uso de textos históricos?*

Los textos históricos generalmente se tratan de documentos que contienen información sobre administración, por ejemplo diarios de gestión judicial o administración de bienes por parte de la iglesia, los mismos se han escrito generalmente con el fin de informar a posibles lectores futuros, dichos textos pueden encontrarse en diferentes formatos, cada uno con sus ventajas y desventajas. Una opción es encontrar los documentos digitalizados pero por medio de imágenes de los libros originales lo que, aunque si da acceso a los mismos, limita en todo sentido acceder a la información que allí esta contenida. Existe también el caso en el que el texto histórico se encuentra transcrito (generalmente usando una representación de Unicode como UTF-8). La tercera opción es que se encuentre disponible por medio de su estructura y anidaciones, generalmente en formato Extensible Markup Language (XML), Electronic Text Encoding and Interchange (TEI).

Para cumplir con los objetivos y lograr generalizar los beneficios fue necesario para los autores identificar cuatro puntos importantes a tener en cuenta que serían claves para suplir las necesidades de las diferentes categorías de posibles interesados y beneficiados con el avance del proyecto: [18]

- *Los lingüistas estarán interesados en el lenguaje del texto y desearán generar análisis profundos sobre el corpus lingüístico como por ejemplo respecto a las concordancias, esquemas estadísticos de distribución en el texto, etc.*
- *Los Paleólogos estarán interesados en la información sobre las propiedades externas y no textuales de la fuente histórica.*
- *Los historiadores estarán interesados en trabajar directamente sobre el contenido de la fuente, tanto en la fuente original como en la fuente digitalizada, también sobre la información del contexto histórico.*

- *El publico en general puede caer en la misma categoría que el historiador a pesar de que sus consultas no pueden basarse en un enfoque metódico.*

Los requerimientos de cada categoría debían ser atendidas con cuidado, las consultas que se quisieran hacer desde el texto original seguramente no tendrían mayor problema para ser contestadas pero, aquellas consultas que implicaran el contexto a la información o información paleográfica fueron consideradas de un nivel más alto de complejidad que por el momento requerían aún gran cantidad de trabajo manual. El acceso directo a los textos y el cambio de lenguaje implican entonces que las técnicas utilizadas pudieran no dar los mejores resultados ya que se basa en identidad del término de búsqueda o en las co-ocurrencias; como ya se indicó anteriormente las variables para un solo grafema son muchos y eso dificulta obtener resultados con real certeza. No solo para este proyecto sino en los similares, se deben tener en cuenta aspectos como la variación fonética, semántica, entre otros.

Entrando en detalle específicamente acerca del cambio del lenguaje histórico que los autores identificaron sobre los documentos fuente sobre los que se trabajó, destacan el hecho de que el alemán pasó por varias etapas que cronológicamente hicieron que fuera cambiando hasta llegar al punto de que por ejemplo, cada grafema tenga una serie de variantes.

Las siguientes son las etapas cronológicas de desarrollo y transformación por las que ha pasado el alemán:

- Antiguo alto alemán, del ingles Old High German (OHG): aproximadamente hasta c. 1100. Está presente en las rúnicas, glosas y textos religiosos.
- Medio alto alemán, del ingles Middle High German (MHG): aproximadamente hasta 1350 o 1400. Tiempos de poesía cortesana y épica.
- Nuevo alto alemán, temprano del ingles Early New High German (ENHG): aproximadamente hasta c. 1650. Se amplían los horizontes de textos que lo incluían y se evidencian grandes variaciones dialécticas.
- Nuevo alto alemán, del ingles New High German (NHG): aproximadamente desde c. 1650, encuentra sus fundamentos en el ENHG.

A continuación se presentan las variaciones lingüísticas, explicadas por niveles.

1. **Fonológico/gráfico:** Los cambios gráficos y las diferentes variables existentes para los grafemas se incrementa cuando de textos históricos se trata. Las variantes generalmente se tratan de elementos estilísticos.

Grapheme	Variants
<a>	< á, â, ah, aa, ai, ae, â̇ >
<e>	< eh, ee, ei, ey, â̇, ê̇, â̇ >
<i>	< j, y, ÿ, ie, iee, î̇, ij, ye, ih, jh, ieh, yh >
<o>	< oh, ó, oe, oi, oy, oo >
<u>	< ú, û, ù, v, w, uh, wh, ûh, uy >
<ã>	< â̇, e, a, æ, ae, âh >
<ü>	< û̇, u, ù, v, ù̇, ÿ, y, w, ue, üe, ûh, uy >
<ö>	< ô̇, ó, o, ôh, oe, öe, œ >

Figura 5.8: Ejemplo Variantes en grafemas vocálicos

2. **Morfológico:** El grado de variabilidad para este nivel es alto, entre más antigua sea la referencia más complejidad se representa y a medida que se desarrolla el lenguaje también se desarrolla la formación del plural.
3. **Léxico:** Los cambios que ha este nivel se refieren son de mucha importancia para el entendimiento del propio documento, los significados de una palabra al día de hoy pueden no ser los mismos significados del pasado, más de un significado para una palabra puede aparecer en el texto. Para el alemán los significados de las palabras cambiaron según la etapa cronológica, por ejemplo, *urlaub* que en inglés significa “vacaciones”, significaba “permiso” en la etapa de OHG y MHD; vuelve a cambiar su significado a “despedida” para la etapa ENHG.
4. **Sintáctica:** Las frases en los textos históricos se comienzan a ver de apoco con cierta extensión considerable debido a que surgen nuevas posibilidades para hacerlo. En cuanto a la sintaxis los cambios no son en tal escala como las extensiones, antes de la época NHG no había un manejo marcado de signos de puntuación.

Se destaca el hecho de que para que apliquen las diferentes variaciones hay que tener en cuenta el tamaño y las condiciones del texto pues puede que maneje periodos diferentes en su contenido o no lo haga o lo haga de manera particular. La ventaja de tener los textos en formato digital según los autores: “*Los corpus de texto digital nos permiten evaluar los procesos de cambio de lenguaje sobre el pilar de una base de datos completa y así recoger todas las variaciones lingüísticas relevantes*” [18].

En el desarrollo del informe y del proyecto, se ratifica de nuevo, el mayor problema a tratar era la variabilidad del lenguaje, al aplicar los conceptos de anidación y los métodos de minería de textos basados en frecuencia se corría con el riesgo de obtener resultados alejados de los que realmente deberían de ser; así mismo al aplicar técnicas de anotación o agrupación. Una posible solución contemplada era el *hacer uso de Recuperación de información (Information Retrieval) (IR) específicamente orientado a los textos históricos*, para poder llevar a cabo las diferentes computaciones y algoritmia que permitiría trabajar el lenguaje antiguo los investigadores contemplaron posibles soluciones, la primera posibilidad que surgió era la creación de diccionarios especializados que incluyeran cada palabra moderna con sus respectivas variantes encontradas (incluyendo información valiosa como tiempo o lugar), la principal desventaja de esta posibilidad era la gran cantidad de tiempo que esto podría consumir junto con el hecho de que se obtendría un diccionario estático no totalmente compatible con textos diferentes a la fuente definida para este caso.

Como segunda solución se contemplaba el *generar relaciones basadas en reglas*. Las diferencias entre el lenguaje moderno y antiguo se le presentarían a la máquina por medio de un conjunto de reglas. La posibilidad online estimaba el proceso de incluir una palabra para así generar posibles variantes de búsqueda; con la posibilidad offline se intentaría normalizar las variantes históricas e indexarlas aplicando las reglas de manera inversa.

Como tercera solución los autores proponen el *encontrar relaciones basados en similitud de palabras*, se especifica un formato con las similitudes entre las palabras. Se presenta una palabra y como salida se mostraría un conjunto de resultados que cumplen similitud suficiente con dicha palabra consultada.

Entrando en detalle sobre el desarrollo del informe, los autores especifican que su foco de interés era la adquisición de impresiones del siglo XIV - XVII ya que son bastante numerosos y se podría obtener una base de datos robusta. Si se conseguían textos de este tipo, se accedería a crónicas, sermones o documentos legales con posibilidad de digitalización automática. El proceso a seguir para llevar a cabo la investigación fue: [18]

1. *Crear manualmente un pequeño corpus*
2. *Manejar la ortografía y las variaciones compuestas*
3. *Crear un diccionario electrónico utilizable*

4. *Incorporar morfología y sintaxis (del lenguaje)*
5. *incorporar la estructura del documento y metadatos*
6. *Utilizar todo lo anterior para mejorar el Optical Character Recognition (OCR) y digitalizar más textos*

Resulta entonces como fuente principal de la investigación el siguiente corpus: “De una selección de 23 textos de la época del Nuevo Alto Alemán, once han sido digitalizados. Cuatro de éstos han sido etiquetados para incluir información sobre la categoría, la nueva traducción del Alto Alemán. Los 11 textos representan un total de unas 18.000 líneas y 130.000 palabras (tokens)” [18]. Se crea un diccionario en donde se recolectaron las correspondencias entre las antiguas y nuevas variantes en el texto *Dyll Vlmspiegel* y como entregable destacable los investigadores han recopilado una lista de sucesos que explican las correspondencias entre las palabras del alemán moderno y el antiguo: [18]

- *Formación de una nueva palabra*
- *Palabras en latín*
- *Variaciones en la separación por sílabas*
- *Formación parcial de una nueva palabra*
- *Variación en prefijos y sufijos*
- *Variaciones en la tipografía*
- *Variaciones fonéticas*
- *Nuevos caracteres*

Con el fin de obtener mejores resultados en la investigación se empezó a diseñar una estrategia para optimizar la precisión al obtener coincidencias pretendiendo incluir formaciones de nuevas palabras, palabras en latín y variaciones en la separación por sílabas de las palabras. Lo anterior llevaría a una variación en lo ya trabajado llevando a que algunos resultados sean ilegibles por el sistema desarrollado por lo que se pasaría a manejar un conjunto de reglas de adaptación para tratar específicamente las siguientes variaciones: Formación parcial de una nueva palabra, variaciones en la separación por sílabas, nuevos caracteres, variaciones en prefijos y sufijos y variaciones en la tipografía.

Para la construcción del diccionario mencionado anteriormente se ha realizado una base de datos que apoyada en Structured Query Language (SQL) se centra en proporcionar estadísticas de co-ocurrencias de las palabras en el texto, presentar variables ortográficas y coincidencias sobre documentos con estadísticas también.

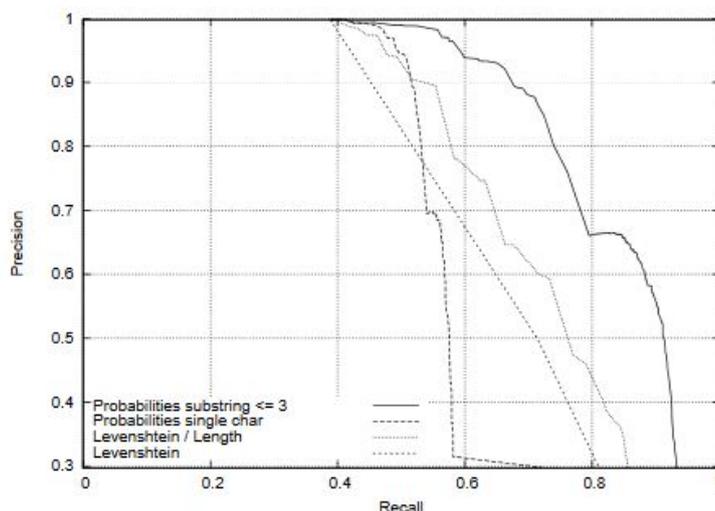


Figura 5.9: Resultados del sistema al encontrar relaciones

Como principales conclusiones de la investigación se encuentra el hecho de que efectivamente las variaciones en los lenguajes modernos y antiguos pueden influir negativamente en los resultados de los sistemas construidos a partir de Recuperación de información (Information Retrieval) (IR) o Minería de texto, modificando los resultados a resultados inciertos. En cuanto a la digitalización de textos históricos, también se presentan ciertos inconvenientes, por ejemplo, haciendo uso de Optical Character Recognition (OCR) se obtienen resultados muy deficientes debido a que la caligrafía de los textos históricos no es la misma que se ve actualmente, es mucho más compleja y con sin fin de variantes visuales.

En cuanto al uso de Optical Character Recognition (OCR) se destaca como principal inconveniente el que los software identifican mal las letras lo que tergiversa los resultados, los investigadores en ese entonces trataban de diseñar una medida de confianza para definir si el carácter que reconoció el software es el correcto o no.

Otra conclusión importante fue que los documentos históricos electrónicos estaban generalmente basados en formato Extensible Markup Language y era un poco complicado hacer búsquedas “inteligentes” a partir de las entradas o palabras al

sistema, para lo anterior los investigadores pretendían desarrollar un marco de trabajo multiplataforma que lograra soportar las consultas Extensible Markup Language y lograr resultados desde la perspectiva de la indexación y construcción de relaciones directas.

5.4. Information Retrieval from Historical Corpora

Actualmente el numero de documentos antiguos digitalizados están aumentando de una manera significativa, estos documentos difieren a los actuales de tres maneras, el vocabulario y la ortografía han cambiado y en algunos casos era inconsistente, los objetivos de esta investigación fueron identificar los cuellos de botella de la recuperación de la información de los corpus históricos y encontrar soluciones [20].

En este trabajo se realizo un experimento para encontrar las diferencias entre textos antiguos y modernos, el corpus utilizado fue una colección de textos legales holandeses y belgas conocidos como Antwerpse Compilatae y los Gelders Land en Stadsrecht, que datan de los siglos XVI y XVII. Los textos se dividieron en 393 documentos, con un total de 371862 palabras. Se pusieron a disposición en forma electrónica mediante reconocimiento óptico de caracteres (OCR) y en parte mediante introducción manual de datos. [20]. Luego se le pidió a 6 expertos en el campo que formularan cada uno 5 necesidades de información, éstas necesidades se convertirían en consultas y se consultarían en un sistema de IR(Interpretación simultanea) de modelo vectorial básico, también se les pidió a cada uno que señalaran que documentación podría ser útil para cada una de las consultas, dentro de la inspección de los documentos que no fueron recuperados por el sistema, mostraron dos características, la primera los documentos contienen uno o más de los términos de la consulta pero con ortografía diferente y la segunda los documentos no contienen los términos de la consulta específicos, sino similares, dentro de la primera característica sucede porque el modelo vectorial solo determina relevante si dentro del documento se encuentran los términos exactos de la consulta, entonces se entra a evaluar cada termino teniendo en cuenta que aunque tenga ortografía difiera, tengan una relación permitida, es aquí donde se encuentra un cuello de botella y unos de los problemas mas complejos en la digitalización de documentos antiguos, al ser la ortografía inconsistente y al aplicar técnicas de OCR la magnitud de los errores va a ser mayor que con los documentos modernos. Como se puede apreciar en la siguiente imagen las variaciones de las palabras y los sinónimos es mas alta en documentos antiguos que en documentos

modernos.

Word	Historical texts		Modern texts	
	var	syn	var	syn
<i>advocaat</i>	4	9	0	4
<i>arbitrages</i>	2	1	0	0
<i>borgtocht</i>	9	0	0	4
<i>dadingen</i>	4	0	0	3
<i>gehuwd</i>	3	2	0	1
<i>notaris</i>	2	4	0	0
<i>panding</i>	1	0	0	1
<i>persoon</i>	0	2	0	0
<i>procederen</i>	2	1	0	1
<i>procureur</i>	1	1	0	0
<i>rechter</i>	5	0	0	1
<i>rente</i>	4	5	0	1
<i>secretaris</i>	2	5	0	0
<i>termijn</i>	3	0	0	0
<i>verbintenissen</i>	6	0	0	0
<i>vonnis</i>	7	2	0	2
<i>vrouw</i>	1	2	0	10

Figura 5.10: Variantes y sinónimos encontrados en documentos históricos y en documentos modernos

La segunda característica se da por la incapacidad del modelo de reconocer los sinónimos de una consulta, al no cumplir las condiciones del sistema, los documentos que contienen uno o más sinónimos de un término de consulta, pero no el término de consulta exacta, se consideran incorrectos, en la recuperación de los documentos modernos también se da el mismo problema aunque en ésta muestra se da la particularidad que los términos de los documentos históricos tiene mas sinónimos que los modernos. A partir de los resultados de la inspección de los documentos, concluimos que hay dos principales cuellos de botella en la recuperación de información con textos históricos [20]:

- *Ortografía variable e incoherente: el cuello de botella de ortografía*
- *Uso de un vocabulario diferente: el cuello de botella del vocabulario*

Para solucionar el problema de botella del vocabulario se hace uso de un tesoro, pero esta solución no se implemento porque no existía un tesoro adecuado para el corpus de texto utilizado en esta investigación y también fue difícil su construcción por el limitado tiempo de los expertos, entonces se decidió concentrarse en la ortografía cambiada e incoherente. Otra posible solución era hacer uso de heurística de transformación para transformar las formas de las palabras viejas en modernas, las heurísticas se basaron fuertemente en las reglas aplicadas por el algoritmo holandés

stemming. Este algoritmo transforma las palabras en sus raíces basándose en sus sufijos, prefijos e infijos. La antigua forma de la palabra «uuytricht-inghe» tiene, por ejemplo, el sufijo «inghe», el prefijo «uuyt» y el infijo «richt». Sin embargo, los sufijos, prefijos e infijos de formas de palabras antiguas podrían no coincidir exactamente con los requeridos por el algoritmo de derivación. Por lo tanto, el algoritmo no funcionará en formas de palabras antiguas. Sin embargo, utilizando heurísticas, las formas de palabras antiguas pueden ser transformadas de tal manera que sus sufijos, prefijos e infijos puedan ser combinados y transformados por el algoritmo de derivación. La antigua forma de la palabra «uuytrichtinghe» puede, por ejemplo, transformarse en «uitrichtingen» [20].

Se desarrollaron tres tipos de heurística, heurística para la transformación del sufijo, heurística para la transformación del prefijo, y heurística para la transformación de infijo. La razón para el desarrollo de tres conjuntos específicos de heurísticas es que la transformación de una combinación específica de caracteres depende de si esta combinación de caracteres es un sufijo, un prefijo o un infijo. Un ejemplo es la heurística para la transformación del sufijo $ff \rightarrow f$, lo que indica que los caracteres 'ff' tienen que ser transformados en 'f' cuando forman el sufijo de una palabra. Sin embargo, si forman el prefijo de un infijo de una palabra, no siempre se pueden transformar [20].

Para poder elegir el mejor de los diferentes procedimientos de combinación (n-gram matching, stemming, programación dinámica y heurística de transformación) se llevó a cabo un experimento. Basándonos en los resultados de Robertson y Willett elegimos $n = 3$ para la adaptación de n-gramos y como enfoque de programación dinámica particular el algoritmo de Wagner-Fischer. La configuración de este experimento fue la siguiente. Todos los términos de consulta se extrajeron de las consultas de cada experto (ver sección 1). Para cada uno de estos términos de consulta, las variantes del término fueron recuperadas de la lista completa de términos de documento extraídos de los documentos de la colección bajo consideración. La recuperación de las variantes de cada término de la consulta se hizo una vez por cada método a ser probado. Para cada método, esto resultó en una lista de términos de documento para cada término de consulta. Si un término de documento era en realidad una variante del término de la consulta, se calificó como pertinente. Si no lo era, se denotaba como no pertinente. El anterior procedimiento se realizó en varias combinaciones de las cuatro posibles, dando como resultado 8 tipos de combinaciones posibles donde para cada uno se hizo un recuadro comparativo de desempeño.

Retrieval method	Comp. recall	Precision
Tri	70.4	57.9
Tri – stem	74.0	62.5
Tri – prepro	74.8	53.7
Tri – stem – prepro	82.1	57.8
Wag	67.2	12.1
Wag – stem	70.6	13.2
Wag – prepro	73.8	11.9
Wag – stem – prepro	77.4	12.1

Legend: Tri: Trigram matching, Wag: Wagner-Fischer, Stem: stemming, Prepro: preprocessing

Figura 5.11: Resultados de la evaluación de desempeño

Como conclusiones finales, se demostró que existen dos problemas de cuello de botella de ortografía y de vocabulario para documentos que datan de los siglos XVI y XVII, para el cuello de botella de ortografía se usó procedimientos de combinación de trigramas, derivación, pre-procesamiento y programación dinámica, el pre-procesamiento consistió en aplicar heurísticas para mapear las viejas formas de las palabras a las modernas, para hacer que las palabras fueran adecuadas para derivar un stemmer moderno. Posteriormente, este nuevo sistema se comparó con un sistema basado en vectores estándar en una tarea de recuperación de información, el rendimiento del nuevo sistema fue significativamente mejor. Vale la pena resaltar que este sistema solo aplica para textos holandeses, lo que hace que no funcione para otros idiomas, aunque se puede investigar en qué medida otros idiomas pueden beneficiarse de este enfoque.

5.5. Topic Modeling on Historical Newspapers

Dentro del campo de minería de texto histórica, por lo general la fuente de información proviene de texto antiguos que pertenecían a la iglesia o que eran de difícil acceso, dentro de este proyecto en su primera fase, se dio la particularidad de usar periódicos antiguos con el fin de ayudar a la investigación histórica. Para los investigadores históricos una de las fuentes de información más interesantes son los periódicos, para este proyecto se rescataron periódicos que constan del siglo XIX al siglo XX en Estados Unidos, cabe resaltar la gran importancia de estos, ya que dentro del contenido de estos los norteamericanos debatían toda clase de temas que hacían parte de la sociedad y la vida cotidiana, un aspecto de gran importancia de los periódicos es que documentan todas las experiencias humanas que ninguna otra

fuelle de informaci3n puede tener. A pesar de su gran valor, se puede considerar que los peri3dicos antiguos son una mina de oro de informaci3n que no ha sido explotada y que hasta ahora esta siendo tenida en cuenta en trabajos de esta 3ndole, pero no ha sido lo suficientemente explotada por la sencilla raz3n que son vol3menes de informaci3n inimaginables y que a la final le va a dificultar mucho al investigador recorrer semejante vol3menes de informaci3n.

A pesar de la gran cantidad de informaci3n que no se esta utilizando, iniciativas de The National Endowment for the Humanities (NEH) y The Library of Congress (LOC) est3n patrocinando proyectos para digitalizar todos los peri3dicos sobrevivientes de los Estados Unidos desde 1836 hasta el presente, la finalidad de este proyecto es poder ofrecer una gran cantidad de peri3dicos hist3ricos en formato digital. Actualmente las herramientas de b3squeda se vuelven mas eficientes para los investigadores hist3ricos, sin embargo el problema permanece hay, la gran cantidad de informaci3n sigue siendo enorme y esta en constante crecimiento, entonces este proyecto como objetivo principal busca identificar los temas mas importantes durante un periodo de tiempo determinado, la idea es agrupar varios temas en conjuntos con patrones inusuales, lo cual puede llevar a investigaciones nunca antes hechas y a revelar informaci3n nunca antes vista. El modelado de temas se puede aplicar para un a3o en particular o para un periodo de a3os. [21]

El modelo se basa en dos modelos, el primero un modelo de an3lisis sem3ntico latente probabil3stico (pLSA) y el segundo un modelo latente de asignaci3n de Dirichlet (LDA), ambos modelos probabil3sticos consideran cada documento como una mezcla de temas. Los modelos descomponen la colecci3n de documentos en grupos de palabras que representan los temas principales. Tambi3n se uso la herramienta MALLET que es un paquete basado en Java para el procesamiento de lenguaje natural estad3stico, clasificaci3n de documentos, agrupaci3n, modelado de temas, extracci3n de informaci3n y otras aplicaciones de aprendizaje de m3quinas a texto. [22]

Para aplicar el modelo de temas se escogi3 una colecci3n de peri3dicos hist3ricos publicados en Texas desde 1829 hasta el 2008, dentro de la colecci3n hab3an 232.567 de paginas que pertenec3an a 180 a3os. Para dividir los a3os se separaron en periodos o en a3os en espec3ficos por caracter3sticas propias, el primer conjunto de datos fue peri3dicos de 1865 a 1901 porque en esta 3poca los texanos buscaron reconstruir su econom3a de posguerra invirtiendo fuertemente en la producci3n de algod3n en

todo el estado. El algodón se consideró una inversión segura, por lo que los texanos produjeron lo suficiente durante este período para convertir a Texas en el mayor productor de algodón de los Estados Unidos en 1901. Sin embargo, la sobreproducción durante ese mismo período empobreció a los agricultores de Texas al bajar el precio del algodón y por lo tanto un gran porcentaje se declaró en bancarrota y perdió sus tierras. Como resultado, los algodoneros enojados en Texas durante la década de 1890 se unieron a un nuevo partido político, los Populistas, cuyo objetivo era utilizar al gobierno nacional para mejorar las condiciones económicas de los agricultores. Este esfuerzo fracasó en 1896, aunque representó una de las mayores revueltas políticas de terceros en la historia de los Estados Unidos. Entonces todos estos temas se esperan que sean mencionados en un conjunto de 52.555 páginas en más de 5.902 ejemplares. [21]

El segundo conjunto fueron todos los periódicos de 1892 este fue el año de la formación del Partido Populista, que una gran parte de los campesinos de Texas se unió para las elecciones presidenciales de 1892. Los Populistas buscaron que el gobierno federal estadounidense se involucrara activamente en la regulación de la economía para evitar que los productores de algodón se endeuden más. Este conjunto de datos consta de 1.303 páginas sobre 223 ejemplares.

El tercer conjunto fueron los todos los periódicos de 1893 ya que una depresión económica importante golpeó los Estados Unidos en este año, devastando la economía en cada estado, incluyendo Texas. Esto perjudicó el problema del algodón dentro de la economía de los estados y aumentó los esfuerzos de los populistas dentro de Texas para impulsar reformas políticas importantes para abordar estos problemas. Lo que vemos en 1893, entonces, es un gran estrés que debería incrementar las tendencias dentro de la sociedad texana de ese año. Este conjunto de datos consta de 3.490 páginas en más de 494 ejemplares.

El cuarto conjunto de datos fue periódicos de 1929 a 1930, estos años representaron el inicio y el comienzo de la Gran Depresión. La economía de los Estados Unidos comenzó a colapsar en Octubre de 1929, cuando el mercado bursátil se estrelló y comenzó una serie de fracasos económicos que pronto derrumbaron casi toda la economía de los Estados Unidos. Texas, con su ya débil dependencia económica del algodón, estaba tan devastada como cualquier otro estado. Como tal, este período estuvo marcado por discusiones acerca de cómo salvar tanto la economía del algodón de Texas como la posible intervención del gobierno en la economía para prevenir

la catástrofe. Este conjunto de datos consta de 6.590 páginas sobre 973 ejemplares. [21]

Cabe resaltar que para muchos investigadores y expertos en la historia de los Estados Unidos, la economía y el algodón eran temas de gran importancia, además con eso fue el ascenso y la caída del Partido Populista durante la década de 1890, cuando los agricultores trataron de usar el sistema político como un medio para enfrentar sus problemas económicos. Entonces se espera encontrar todos estos temas como dominantes en los periódicos de ese periodo de tiempo.

Antes de aplicar el modelo de temas sobre la información de los periodos de los periódicos, se hizo un proceso de pre-procesamiento de la información la cual tenía algunos inconvenientes, uno de ellos fue la falta de puntuación y separación de los artículos de una misma página, para empezar se hizo una corrección ortográfica usando un diccionario de Aspell y de-hyphenates para identificar las palabras separadas por guiones, luego de tener la ortografía corregida se procede a utilizar el Stanford Named Entity Recognizer el cual clasifica las palabras en cuatro grupos, person(Persona), organization(Organización), location(Lugar) y Miscellaneous(Varios), el software usado para el desarrollo del proyecto proporciona esta funcionalidad, luego las palabras que no entraban en estos grupos, se pasaron por un stemmer en ingles el cual toma la raíz de la palabra. Omitir alguno de los pasos anteriores tenía un gran impacto en el resultado por lo cual se llegó a la conclusión de pasar la información varias veces por el modelo por cada una de las fases para obtener mejores resultados. [21]

Los resultados arrojados por el modelo fueron validados por un historiador experto en la historia de Texas y el resultado fue muy satisfactorio dentro de los temas, el lenguaje orientado al mercado es el tema dominante, lo que es exactamente lo que el experto esperaba como historiador de esta región. Se puede ver, por ejemplo, que gran parte de la economía del algodón estaba orientada a abastecer a los molinos industriales de Inglaterra. La palabra "Liverpool" que es el nombre del puerto inglés a donde fue enviado el algodón de Texas, aparece bastante a través de las muestras. Estos resultados sugieren un alto grado de precisión en la identificación de temas dominantes e importantes en el corpus. Como conclusiones finales se puede usar el modelo de temas como una herramienta muy poderosa para obtener los temas mas importantes dentro de un volumen de datos muy grande, pero con el inconveniente de no saber cuales de estos temas son importantes para el investigador en este

caso todos los referentes a Texas durante los periodos establecidos, es decir solo el profesional puede saber cual o cuales son los temas relevantes y cuales no, reduciendo la cantidad de información a procesar y haciendo que no se requieran técnicas de pre-procesamiento de la información tan robustos.

Herramientas para minería de texto

6.1. KNIME Analytics Platform

Konstanz Information Miner (KNIME) es una plataforma de análisis, generación de informes e integración de datos de código abierto, integra diversos componentes para Machine Learning y minería de datos a través de su concepto de pipelining modular de datos [6.1]. Una interfaz gráfica de usuario permite el montaje de nodos para el procesamiento de datos (ETL: Extracción, Transformación y Carga), para el modelado, análisis y visualización de datos. Con más de 1000 módulos, cientos de ejemplos listos para ejecutar, una amplia gama de herramientas integradas y la más amplia selección de algoritmos avanzados disponibles.[23]



Figura 6.1: Pipelining modular de datos

Una de las ventajas que posee KNIME es la gran cantidad de nodos nativos y las contribuciones de una enorme comunidad mundial de científicos de datos, también permite trabajar con varios tipos de datos como archivos de texto simples, bases de datos, documentos, imágenes, redes e incluso datos basados en Hadoop pueden combinarse dentro del mismo flujo, su amigable interfaz gráfica fácil de aprender significa que la codificación es opcional. KNIME está escrito en Java y está basado en Eclipse y hace uso de sus métodos de extensión para soportar plugins

proporcionando así una funcionalidad adicional.

KNIME cuenta con soporte para una gran cantidad de tipos de datos como Extensible Markup Language (XML), JSON e imágenes, posee funciones matemáticas y estadísticas, algoritmos avanzados de aprendizaje predictivo y de máquina, control de flujo de trabajo, combinación de herramientas para Python, R, SQL, Java, Weka, realizar vistas e informes interactivos de datos, los flujos de trabajo KNIME se pueden utilizar como conjuntos de datos para crear plantillas de informes que se pueden exportar a formatos de documento como doc, ppt, xls, pdf y otros.

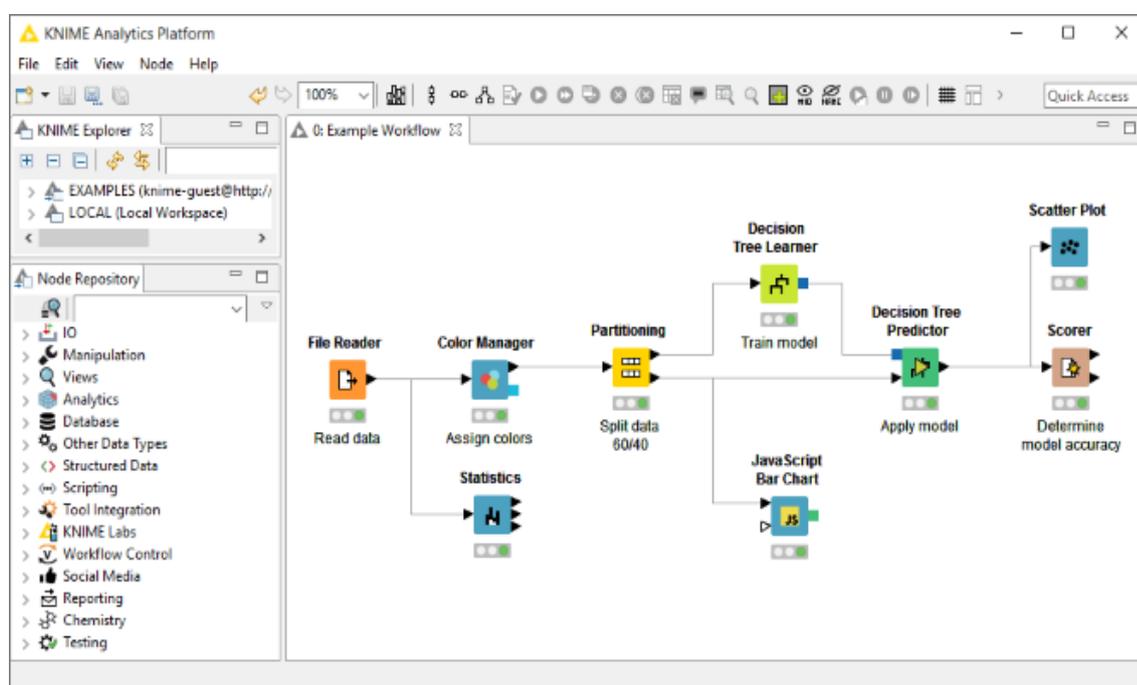


Figura 6.2: KNIME Analytics Platform

Por ser una plataforma intuitiva de código abierto, fácil de usar, tener la capacidad de crear de forma visual flujos o tuberías de datos, ejecutar selectivamente algunos o todos los pasos de análisis, modelar y generar vistas interactivas fue escogida para la realización de este proyecto, ya que posee las herramientas y complementos necesarios para la finalización del mismo.

6.2. RapidMiner

RapidMiner es una plataforma de software que proporciona un entorno integrado para el aprendizaje automático, minería de datos, minería de texto, análisis negocios

y análisis de predictivo. Se utiliza para aplicaciones empresariales y comerciales, así como para la investigación, la educación, el entrenamiento, el prototipado rápido y el desarrollo de aplicaciones y soporta todas las etapas del proceso de minería de datos, incluyendo la preparación de datos, la visualización de resultados, la validación y la optimización. RapidMiner se desarrolla en un modelo de núcleo abierto.[24]

RapidMiner utiliza un modelo cliente/servidor con el servidor ofrecido como (SaaS)Software as a Service o en infraestructuras en la nube. RapidMiner proporciona el 99 % de una solución analítica avanzada a través de marcos basados en plantillas que aceleran la entrega y reducen los errores eliminando casi la necesidad de escribir código. RapidMiner ofrece procedimientos de minería de datos y aprendizaje de máquinas, incluyendo: carga y transformación de datos (extracción, transformación, carga (ETL)), procesamiento y visualización de datos, análisis predictivo y modelado estadístico, evaluación e implementación. RapidMiner está escrito en el lenguaje de programación Java. RapidMiner proporciona una GUI para diseñar y ejecutar flujos de trabajo analíticos. Estos flujos de trabajo se llaman procesos en RapidMiner y consisten en múltiples operadores. Cada operador realiza una sola tarea dentro del proceso, y la salida de cada operador forma la entrada de la siguiente. Alternativamente, el motor puede ser llamado desde otros programas o utilizado como API. Las funciones individuales se pueden llamar desde la línea de comandos. RapidMiner proporciona esquemas de aprendizaje, modelos y algoritmos y puede extenderse utilizando scripts R y Python. [25]

6.3. R-Programming y R-Studio

R es un lenguaje y un entorno para la informática estadística y los gráficos. R proporciona una amplia variedad de modelos estadísticos como modelos lineales y no lineales, pruebas estadísticas clásicas, análisis de series de tiempo, clasificación, agrupación y técnicas gráficas. R es una implementación de software libre del lenguaje S pero con soporte de alcance estático. Se trata de uno de los lenguajes más utilizados en investigación por la comunidad estadística, siendo además muy popular en el campo de la minería de datos, la investigación biomédica, la bioinformática y las matemáticas financieras. Una de las fortalezas de R es la facilidad con la que se pueden producir parcelas de calidad de publicación bien diseñadas, incluyendo símbolos matemáticos y fórmulas donde sea necesario. Se ha prestado gran atención a los valores predeterminados de las opciones de diseño menores en gráficos, pero el usuario conserva el control total. R está disponible como Software Libre bajo

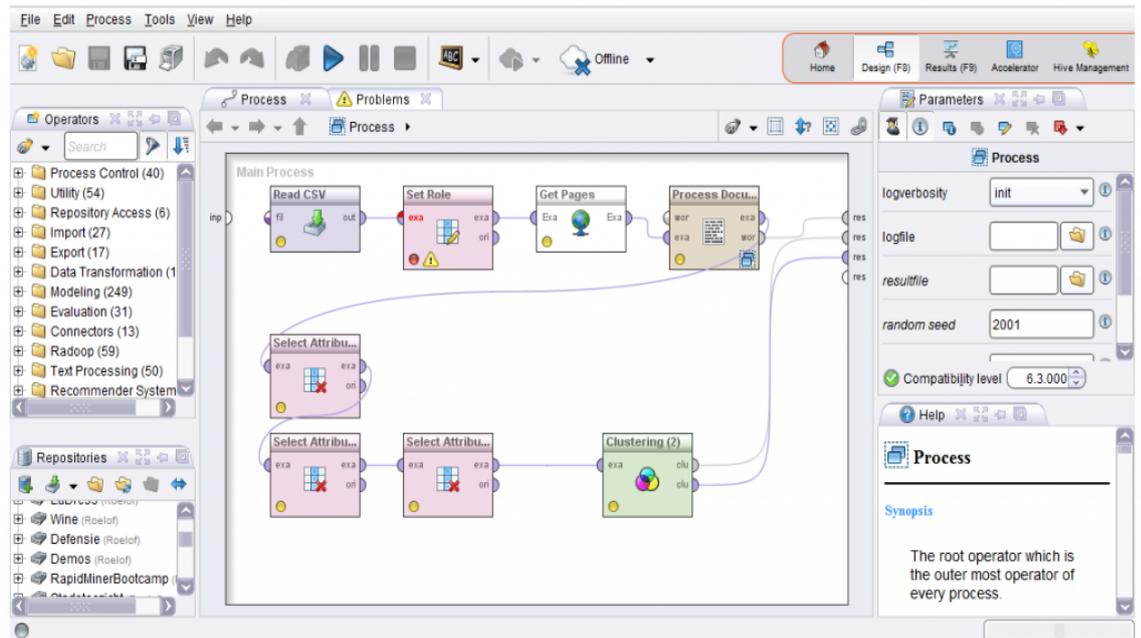


Figura 6.3: RapidMiner Studio

los términos de la GNU General Public License de la Free Software Foundation en forma de código fuente. Compila y ejecuta en una amplia variedad de plataformas UNIX y sistemas similares (incluyendo FreeBSD y Linux), Windows y MacOS. [26]

RStudio es un entorno de desarrollo integrado (IDE) libre y de código abierto para R. Uno de los aspectos más poderosos del uso de R es que se puede descargar paquetes gratuitos para varios tipos de análisis. El análisis de texto todavía se encuentra en etapa de desarrollo, pero es muy prometedor.

6.4. Weka

Weka es un software de código abierto emitido bajo la GNU General Public License. Contiene una colección de algoritmos de aprendizaje automático para tareas de minería de datos y interfaces gráficas de usuario para facilitar el acceso a estas funciones.

Los algoritmos pueden ser aplicados directamente a un conjunto de datos o llamados desde su propio código Java. Weka contiene herramientas para pre-procesamiento de datos, clasificación, regresión, clustering, reglas de asociación y visualización. También es adecuado para desarrollar nuevos esquemas de aprendizaje de máquinas.[27]

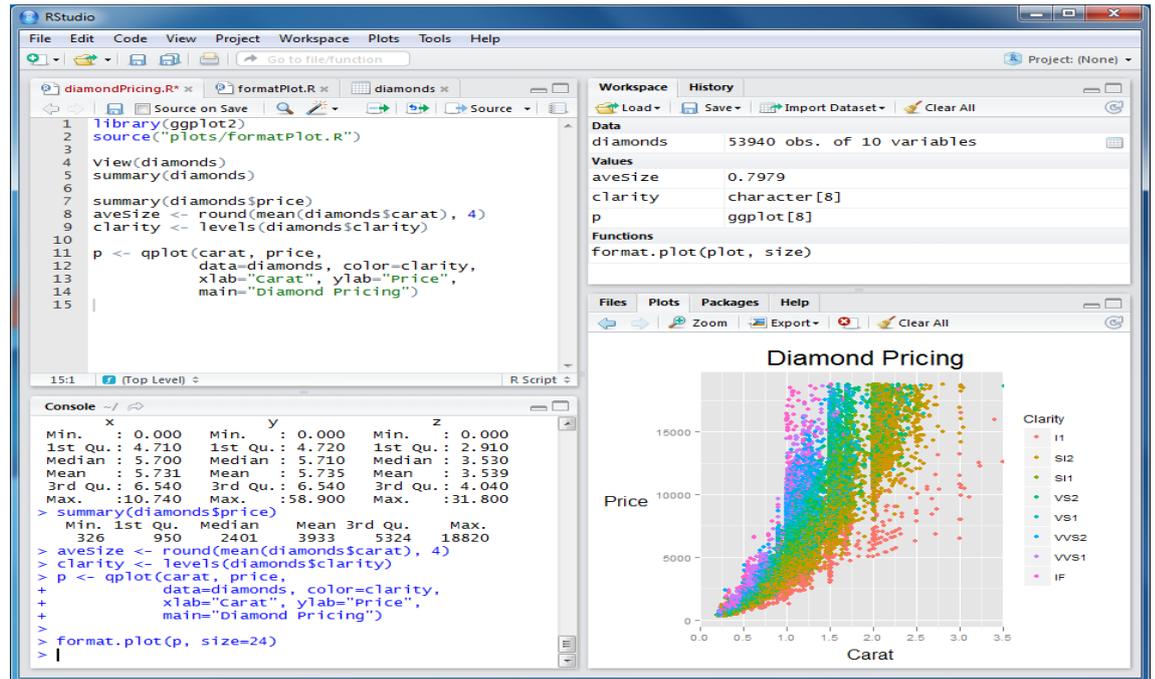


Figura 6.4: RStudio

Algunas de las ventajas de usar Weka es la portabilidad, ya que se implementa completamente en el lenguaje de programación Java y por lo tanto se ejecuta en casi cualquier plataforma de computación moderna. Posee una colección completa de preprocesamiento de datos y técnicas de modelado. La facilidad de uso gracias a sus interfaces gráficas de usuario. Weka soporta varias tareas estándar de minería de datos, más específicamente, pre-procesamiento de datos, agrupación, clasificación, regresión, visualización y selección de características. Todas las técnicas de Weka están basadas en la suposición de que los datos están disponibles como un archivo plano o relación, donde cada punto de datos se describe por un número fijo de atributos (normalmente, atributos numéricos o nominales, pero también se admiten otros tipos de atributos). Weka proporciona acceso a las bases de datos SQL utilizando Java Database Connectivity y puede procesar el resultado devuelto por una consulta de base de datos. No es capaz de hacer minería de datos multi-relacional, pero hay software separado para convertir una colección de tablas de base de datos enlazadas en una sola tabla que es adecuada para el procesamiento utilizando Weka.

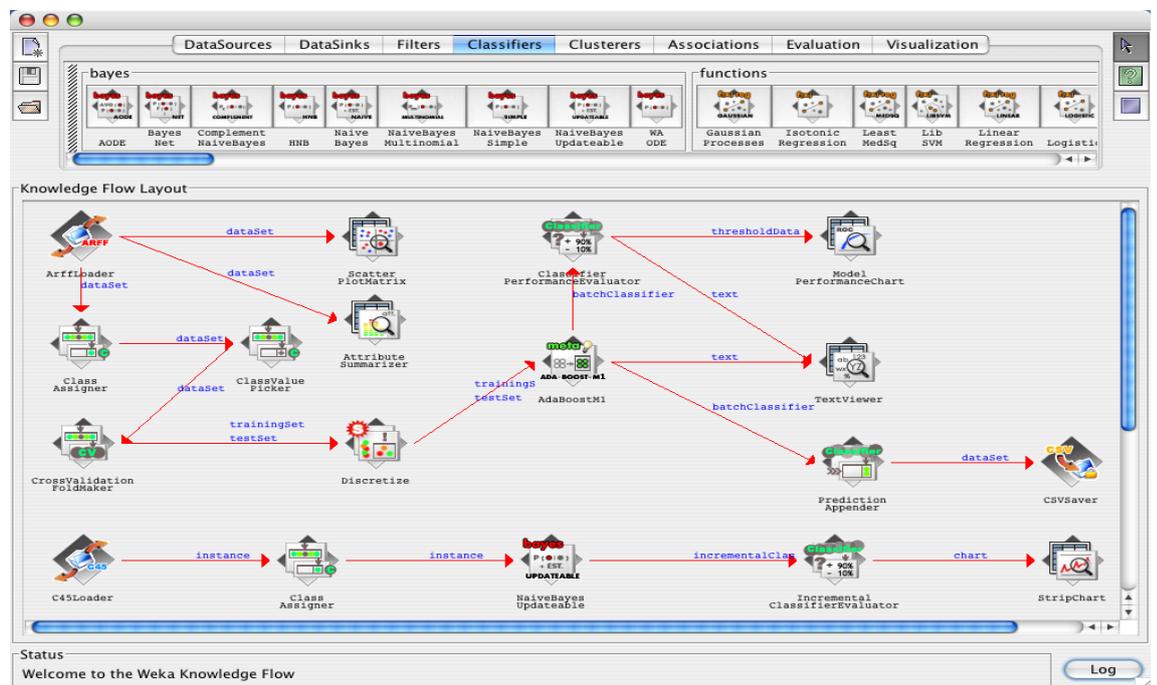


Figura 6.5: Weka Knowledge Flow

Proceso del trabajo

7.1. Metodología de trabajo

Existen muchos modelos para el desarrollo de proyectos de Minería de datos tales como SEMMA (Sample, Explore, Modify, Model, Assess), DMAMC (Definir, Medir, Analizar, Mejorar, Controlar) o CRISP-DM (Cross Industry Standard Process for Data Mining), pero el mas utilizado en ambientes académicos o industriales es CRISP-DM, para este proyecto se utilizo varias fases de ésta metodología que ayudaron en la realización del mismo, excluyendo el caso de negocio, ya que se encuentra en un contexto académico.

La metodología CRISP-DM es un enfoque multinacional basado en estándares para describir, documentar y mejorar continuamente los procesos de minería de datos y los procesos asociados al almacenamiento de datos e inteligencia empresarial. El marco de trabajo identifica seis pasos en el proceso de minería de datos, como se muestra en la siguiente imagen. Se añadió un séptimo paso de rendimiento para la mejora continua de procesos a través de un plan sucesivo que se compone en analizar, implementar y realizar iteraciones a los proyectos de minería de datos.[11]

1. Fase 1 : Determinar el propósito del estudio

Como en cualquier proyecto, se define el problema a resolver, lo cual requiere entender el caso de negocio, identificar la oportunidad, interactuar con los implicados para entender a fondo la situación, establecer los objetivos y metas de la minería de texto y generar el plan del proyecto.

2. Fase 2 : Compresión de la naturaleza de los datos

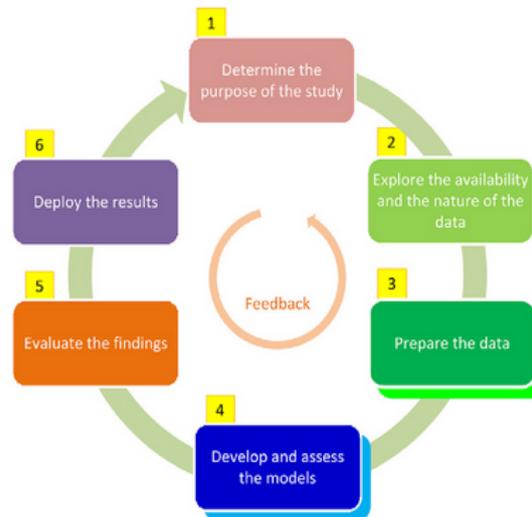


Figura 7.1: Diagrama CRIPS-DM

Una vez el propósito del estudio está claro se debe evaluar la disponibilidad, accesibilidad y aplicabilidad de los datos necesarios para la realización del estudio, para esto se debe tener en cuenta de donde provienen los datos, si son internos o externos de la empresa y el tipo de datos por ejemplo si son digitales o físicos.

3. Fase 3 : Preparación de los datos

La tercera fase se divide en cuatro fases:

- Establecer el Corpus: El propósito de esta actividad es recolectar todos los documentos que son relevantes para el contexto del problema, dos atributos a tener en cuenta de los datos son la calidad y la cantidad. Se pueden utilizar técnicas manuales o automatizadas para la recolección de la información y ésta información pueden ser archivos como PDF, tablas de Excel, documentos de Word, presentaciones de PowerPoint, emails, web posts, archivos HTML o notas. Una vez recopilada toda la información, se deben organizar y transformar si es el caso para ser procesados por computador, la organización de los datos puede ser tan simple como guardarlos en una carpeta.
- Limpieza de los datos: La probabilidad de que los datos del corpus estén sin errores es baja, por eso se debe realizar un trabajo de limpieza el cual puede incluir reemplazar valores, realizar correcciones ortográficas, reemplazar campos vacíos por nulos, inclusive se pueden incluir técnicas de reemplazo sofisticadas. Al finalizar el trabajo de limpieza debería existir un documento

donde se detalla todos los cambios realizados y los problemas de calidad que se identificaron en los datos, este documento sirve para medir el impacto en los resultados de los cambios que se realizaron durante la limpieza de datos.

- **Construcción de datos:** En esta actividad se debe documentar si se realizan modificaciones a la información para llevar a cabo cálculos, por ejemplo si se agregaron columnas o nuevos registros.
- **Integración de los datos:** Por lo general en este punto la información proviene de varias fuentes, la idea de esta actividad es hacer la integración de la información para tener una sola fuente.

4. **Fase 4 : Desarrollar y evaluar los modelos**

Una vez se tiene el corpus listo ya se pueden identificar patrones en la información, para esto se debe seleccionar la técnica de modelado a utilizar, diseñar las pruebas, construir el modelo y por último evaluar el modelo utilizado. Existen muchas técnicas de modelado pero no todos se adaptan a las necesidades del problema, se debe escoger en función de los tipos de variables involucradas. Al final se debe tener especificado el modelo que se usará.

5. **Fase 5 : Evaluación de los datos obtenidos**

Después de explorar los datos y encontrar patrones en la información, se debe evaluar la calidad de los resultados, no solo se evalúan los modelos aplicados sino también los procesos que se usaron para crearlos, como tarea de esta fase se debe evaluar el valor de los modelos usados para resolver el problema planteado para el caso de uso. Luego revisar a profundidad el modelo utilizado, para detectar posibles problemas antes de salir a producción y también para revisar como mejorar el proceso para posibles proyectos en el futuro. Esta fase concluye con la revisión completa del modelo listo para desplegarlo.

6. **Fase 6 : Despliegue**

Cuando el modelo está listo para ser usado, se debe especificar una estrategia para desplegarlo en función del negocio, dentro de la estrategia se debe definir el resumen de los detalles del proyecto en general, los reportes obtenidos y los resultados, también se debería incluir todos los problemas asociados durante todas las fases, como problemas con los datos, malas experiencias e incluir recomendaciones para proyectos similares que se puedan desarrollar en el futuro.

7. Fase 7 : Mejora continua

El proceso de minería de datos es cíclico, es decir que se debe desarrollar un plan de control y mantenimiento que asegura la mejora continua del plan en cada iteración, en donde se haga uso apropiado de las estrategias definidas en los pasos anteriores y detecte problemas en el desempeño del modelo.

7.2. El contexto de los datos

La base de datos contenía todos los datos correspondientes al MOOC, ya antes mencionado (ver capítulo 1.3) , del año 2014. Los datos contenidos en dicho son las transcripciones de las Actas Capitulares de la Catedral de Plasencia digitalizadas por parte de los estudiantes del mismo, adicionalmente, como se trataba de un curso, cada transcripción realizada por parte de los estudiantes presenta una calificación, la calificación de dichas transcripciones se encuentra dada por dos (2) estudiantes quienes previamente realizaron la misma actividad, cada uno daba una nota y esta era promediada, en caso de haber unas notas bastante diferentes entraba un tercer estudiante a calificar, esto con la finalidad de dar la nota más adecuada posible.

7.2.1. Estructura de los datos

La base de datos es un conjunto de archivos en formato HTML debidamente ordenado de acuerdo a como se dicto el curso, es decir, en el caso de las transcripciones, estas se encuentran en una carpeta la cual contiene a su vez las transcripciones por cada alumno inscrito en el MOOC, tal como se ve en la imagen 7.2, en su respectiva carpeta con la identificación del mismo dentro del curso, como se ve en la imagen 7.3, dentro de esta se encuentran las calificaciones dadas por los otros dos o tres estudiantes del MOOC, tal como se aprecia en la imagen 7.4, y finalmente, dentro de la carpeta de cada calificador se encuentra un archivo HTML que contiene el mismo archivo del estudiante, con la única diferencia es que este trae la calificación y menciona quien lo califico y a quien califico.

En el MOOC participaron más de 10.000 personas, por lo cual la base de datos es bastante grande, teniendo en cuenta que la calidad de los mismos no es la mejor, puesto que la información almacenada esta enfocada en la visualización desde un navegador web, debido a esto entro los archivos se encuentran lo que se le conoce como “*archivos basura*” puesto que no aportan nada de información necesario, sino que por el contrario inflan el peso de la base de datos, entre estos archivos se

[00000013] medievalspain-001 Peer Assessment [3] work and evaluations v

[00000016] medievalspain-001 Peer Assessment [7] work and evaluations v

[00000013] medievalspain-001 Peer Assessment [3] work and evaluations .

[00000015] medievalspain-001 Peer Assessment [6] work and evaluations .

[00000016] medievalspain-001 Peer Assessment [7] work and evaluations .

Figura 7.2: Carpetas con todas las actividades del curso

submitter1031894	submitter1032728	submitter1047915	submitter1050845	submitter1058023
submitter1069047	submitter1074778	submitter1076792	submitter1083261	submitter114142
submitter114658	submitter1149937	submitter1158427	submitter1182415	submitter1199025
submitter120044	submitter1205115	submitter1207451	submitter1225444	submitter1225579
submitter1237933	submitter1242586	submitter1248228	submitter1267918	submitter1296755
submitter1304212	submitter1321680	submitter1353085	submitter1364151	submitter1366895
submitter1383004	submitter1384767	submitter1393284	submitter1414856	submitter1419057
submitter1421258	submitter1426602	submitter1428236	submitter1437391	submitter1441812

Figura 7.3: Carpetas de los estudiantes de cada actividad

encuentran archivos CSS.

Además de contar con “*archivos basura*” las transcripciones se encuentran llenas de etiquetas HTML además de contar con caracteres **unicode** cuando dicho carácter no se encuentra dentro de la codificación ASCII estándar, esto tal y como se puede apreciar en la imagen 7.5, de tal manera que para poder realizar el trabajo de minería es necesario realizar primero una limpieza de los datos y dejarlos de manera ordenada, de tal forma que sea posible realizar la construcción del documento.

Para poder realizar una limpieza del documento y filtrar cada transcripción es necesario comprender primero la estructura de las transcripciones, como ya se ha

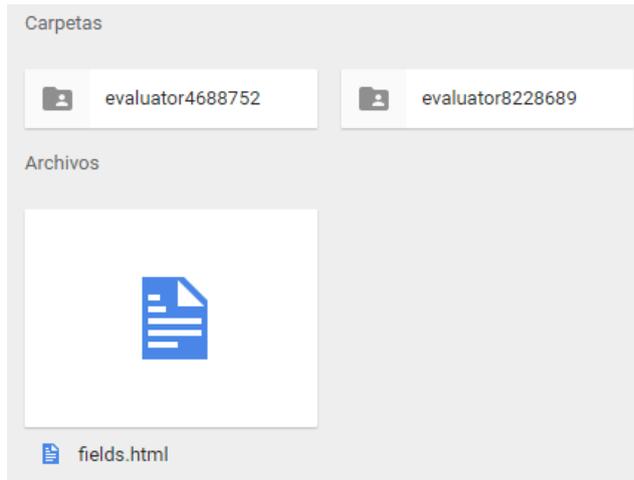


Figura 7.4: La actividad del estudiante con los calificadores de la misma

```

<!DOCTYPE html>
<html lang="en">
<head>
  <meta charset="utf-8">
  <title>Submission 1782 from Anon (course_user_id: 1076792, session_user_id: 955c526538ef899518e6409cb5b1008ae2d93944)</title>
  <link href="../../export.css" rel="stylesheet">
</head>
<body>
  <div class="field-name" id="1c880c80df8a113fd"><b>Assignment Statement:</b><span style="font-size: 14.444446563721px;"><b>By submitting this assignment, I affirm that I will abide by the Revealing Cooperation and Conflict Project's agreement to not reproduce or distribute any images of manuscripts.</span><br><br><b><i>The student will type the following statement in the answer box below:</i></b><br><b><i>I will not reproduce or distribute any images of manuscripts.</i></b><br><b><i>Your response will not impact your ability to earn sufficient credit in the course to earn a Statement of Accomplishment. However, if you type in the statement you will earn additional points.</i></b></div>
  <div class="field-value">"I will not reproduce or distribute any images of manuscripts"<br><br><b>Group 6<br></b><br><b>Manuscript Image B5H20<br></b><br><b>Diego Alonso y Gonzalo Fernandez<br></b><br><b>Vestino del dicho lugar con unacbr />cuba de madera buena de tener<br></b><br><b>Vino con una azada e un asa<br></b><br><b>don e la qual dicha villa e cuba<br></b><br><b>e azada e azadon deo al dicho<br></b><br><b>caballo Don Diego Blasquez Dean<br></b><br><b>la qual dicha villa e cuba e asa<br></b><br><b>e azadon arrendo desde hoy<br></b><br><b>del dicho caballo falta en to<br></b><br><b>dos los años e dias de su vida del<br></b><br><b>dicho caballo Alonso Jimenez<br></b><br><b>Group 6<br></b><br><b>Manuscript Image B5H21<br></b><br><b>recreciere; sobre lo qual amoy<br></b><br><b>las partes otorgaron dos contratos<br></b><br><b>ambos de una forma ante Pedro<br></b><br><b>Gonzalez Racionero Notario pu<br></b><br><b>Apostolico testigos que fueron<br></b><br><b>presentes Gonzalo Martinez Fer<br></b><br><b>tiguero e Juan Fernandez cleri<br></b><br><b>go dela Magdalena y Aparicio<br></b><br><b>Fernandez Clarigo de San Pedro<br></b><br><b>que estaban presentes capellanes<br></b><br><b>dela dicha Yglesia = Petrus Gonza<br></b><br><b>riez, Porcionaris : Notario Appoo [Apostolico]<br></b><br><b>Group 6<br></b><br><b>Manuscript Image B5H22<br></b><br><b>raices e muebles que los dichos<br></b><br><b>señores cabildo e Benefiados han<br></b><br><b>ben la Villa de Troxillo e en Xara<br></b><br><b>Aldea e termino dela dicha Vi<br></b><br><b>lla; los quales dichos bienes tien<br></b><br><b>arrendados del dicho cabildo ha<br></b><br><b>cin Alonso, clarigo de la Yglesia<br></b><br><b>de Santiago, dela dicha Villa, e de<br></b><br><b>Logro san delindados so ciertos linda<br></b><br><b>pros que son estos que aqui dira e<br></b><br><b>la dicho Villa de Troxillo unas ca<br></b><br><b>ss en par dela venta dela dichas</div>
  <div class="field-name" id="d8792e8f26e92e"><p><span style="font-size: 11pt;"><b>Transcribe Your Week 12 Bundle and Submit it Here - Due September 5, 2014</b></span></p><p>Please type your transcription and submit it using the assignment link (hyperlink).<br><b>Remember - For full credit for the week's assignment, you must transcribe at least 3 selections (images).</b><br><a href="https://class.coursera.org/medievalspain-001/wiki/Week_11%3A_Transcription_Project_Page" target="blank" title="Link: https://class.coursera.org/medievalspain-001/wiki/Week_11%3A_Transcription_Project_Page">Week 12 Manuscripts are located here.</a><br><b>You may transcribe additional selections (up to 17 more images) for extra credit and special recognition in the Revealing Cooperation and Conflict Project.</b><br><b>You can choose any three selections to transcribe. Choose those selections that are most appropriate for your skill level.</b><br><b>Required Transcriptions:</b><br><b>Please type in your transcription of the selected manuscript images. For each page you should complete the follow parts:</b><br><b>Required Part One: On the first line, type in your Group Number.</b><br><b>(Your peer reviewer will need this to locate the image you transcribed.)</b><br><b>For example, if your last name is "Garcia", then you would type in "Group 8".</b><br><b>Required Part Two: On the second line, type in your image number.</b><br><b>For example, "Manuscript Image B1D23" (Your peer reviewer will need this to locate the image you transcribed.)</b><br><b>Required Part Three: Transcribe at least Three (3) Selections (Images) - choose any Three (3) Images.</b><br><b>Do your best! We are not expecting perfection. We are hoping that you will be able to transcribe at least 50 percent of what you see on the page.</b><br><b>Start your transcription with the first full line of readable text. End your transcription with the last full line of readable text. (In some cases, your image will have pieces of sentences.)</b><br><b>Type in the exact letters you see. Please do not spell out abbreviations.</b><br><b>Type in lines exactly as you see them.</b><br><b>Please do not add any additional punctuation. Do type in any punctuation that is on the page.</b><br><b>If you cannot read an individual letter or number, then you should type a single period symbol "." to indicate you are not certain what letter/number is reported.</b><br><b>If you cannot read multiple letters or numbers, please use a period symbol "." for each letter you cannot read. If you cannot read an entire word, please type in 5 period symbols "....."</b><br><b>If you wish to earn extra credit on this assignment, transcribe as many of the remaining manuscript images in your assigned bundle. You should type in your extra transcriptions below your required transcriptions.</span></p>
  <div class="field-value">Group 6<br><br><b>Manuscript Image B5H23<br></b><br><b>to por parte del cabildo dela dicha<br></b><br><b>Yglesia le fuera dicho que el dicho<br></b><br><b>Cabildo tenia ciertas casas arren<br></b><br><b>dadas en la Villa de troxillo e e<br></b><br><b>sus Aldeas e terminos que pertene<br></b><br><b>an ala Su Mesa Capitular del otro<br></b><br><b>cabildo; las quales decian que quer<br></b><br><b>an dar a omo perpetuamente po<br></b><br><b>derlo precio en cada un año por qu<br></b><br><b>anto entendian que era necesario de

```

Figura 7.5: Transcripciones digitalizadas "sucias"

mencionado en capítulos pasados, cada transcripción esta dividida en párrafos y cada párrafo cuenta con un código que lo identifica dentro del documento. El código está compuesto entre 4 a 6 caracteres donde el primer carácter es **'B'**, seguido de un carácter numérico, el tercer carácter pasa a ser alfabético mayúsculo, el cuarto carácter es de tipo numérico, el quinto y sexto carácter son opcionales y son también de tipo numérico, es decir, el código sigue el siguiente patrón: $B\#[A-Z]\#\#\#$

Todas las actividades del curso que se encuentran relacionadas se pasan a una base de datos en hojas de cálculo; en esta hoja de cálculo se encuentran los códigos de los estudiantes, las transcripciones realizadas y otros datos como el compromiso que adquirieron los estudiantes al momento de realizar la transcripción. Dichas transcripciones cuentan con el mismo problema antes mostrado en la imagen 7.5, se encuentran llenos de etiquetas HTML, caracteres unicode, caracteres de escape para las tabulaciones, espacios, etc. una gran cantidad de espacios entre palabras, códigos HTML para la representación de un espacio sencillo, entre otras cosas.

7.2.2. Limpieza de datos

Para la limpieza de las transcripciones y poder generar el documento para su posterior análisis se usó **python 3** y se tomó la base de datos en la hoja de cálculo.

Sabiendo que en el idioma no se encuentran los caracteres '<' ni '>' y además estos forman parte de las etiquetas de código HTML se procede con su eliminación de todos los textos de la siguiente forma:

```

1 def deleteTag(s):
2     startsTag = s.find('<'); endsTag = s.find('>')
3     if startsTag == -1 or endsTag == -1: return None
4     elif len(s) == endsTag: return s[:startsTag]
5     else: return s[:startsTag] + ' ' + s[endsTag+1:]
6
7 def deleteHTMLTags(s):
8     ok = True
9     while ok:
10        aux = deleteTag(s)
11        if aux is None: ok = False
12        else: s = aux
13    return s.strip()

```

De forma similar se realiza la eliminación de los demás elementos que no pertenecen a las transcripciones: Seguidamente a la limpieza de las transcripciones es necesario identificar cada una, para ello es necesario primero identificar cual es el código de las transcripciones, para así saber cual es la transcripción:

```

1 def findCode(s):
2     startCode = 'B'
3     code = ''
4     sIndexCode = s.find(startCode)
5
6     # If 'B' not exist
7     if sIndexCode == -1: return code
8     if s[sIndexCode+1].isdigit(): # Verify B#
9         # Verify B#[A-Z]#
10        if s[sIndexCode+2].isalpha() \
11            and s[sIndexCode+3].isdigit():
12            code = s[sIndexCode:sIndexCode+4]
13            # Verify B#[A-Z]##
14            if len(s) > sIndexCode+4 \
15                and s[sIndexCode+4].isdigit():
16                code = s[sIndexCode:sIndexCode+5]
17                # Verify B#[A-Z]###
18                if len(s) > sIndexCode+5 \
19                    and s[sIndexCode+5].isdigit():
20                    code = s[sIndexCode:sIndexCode+6]
21        else: code = findCode(s[sIndexCode + 1:])
22    return code.strip()

```

Junto con el código anterior se van generando las transcripciones; estas se almacenan en tuplas, tal que el primer elemento de la tupla sea el código de la transcripción y el segundo elemento sea la transcripción que tiene dicho código, este se hace de manera recursiva con la finalidad de tener todas las transcripciones existentes en una cadena:

```

1 def extractTranscriptions(s, transcriptions=[]):
2     code = findCode(s)
3
4     if code != '':
5         indexCode = s.find(code)
6         # new s without code
7         s = s[indexCode+len(code):].strip()
8         code2 = findCode(s)
9

```

```

10     if code2 != '':
11         indexCode2 = s.find(code2)
12         aux = s[:indexCode2]
13         transcriptions.append((code, aux.strip()))
14         # new s without previous manuscript
15         s = s[indexCode2:]
16     else:
17         transcriptions.append((code, s.strip()))
18 else:
19     return transcriptions
20
21 return extractTranscriptions(s, transcriptions)

```

Finalmente y para evitar duplicados en las transcripciones, los duplicados se deben a que varios estudiantes presentaron las mismas transcripciones, estas se almacenan en una lista para posteriormente crear un archivo en base a esta de la siguiente forma:

```

1 t = []
2 ...
3 aux = extractTranscriptions(dataClean(s, elements2del))
4 t += [e for e in aux if e not in t]
5     ...

```

Adicionalmente como existen varios elementos que se deben de eliminar de las transcripciones para limpiarlas completamente, y estos elementos no fueron contemplados directamente en el código, es necesario la utilización de un archivo dedicado a esto, donde se listan todos los elementos a eliminar de las transcripciones, este, en primera instancia contiene:

- I will not reproduce or distribute any images of manuscripts.
- \.
- \"
- \,

En el repositorio en GitHub se puede tener acceso al código completo usado para esta limpieza, además del archivo adicional necesario para la eliminación de elementos “*basura*”, el código se encuentra completamente documentado y con ejemplos,

la dirección URL del repositorio es <https://github.com/escuela-ing/RCCP>

Finalmente, el documento obtenido, después de haber realizado el proceso de la limpieza se presenta tal y como en la imagen 7.6, aunque aún presenta pequeños fragmentos de “suciedad”, esta claro que ya es completamente legible y es posible comenzar a trabajar con el mismo.

Codes	Transcriptions
0 B2T7	ren al dicho Tesorero, si el dicho Cabildoy Beneficiados lo contrario feciesen, é loque dicho es, non compliesen, é ambaslas dichas partes otorgar
1 B2T8	moneda que agora corre, ó dela moneda que corriere al tiempo delas paga aqui en la dicha ciudad en pazé en salbo a su costa por di de SantaMa
2 B2T9	el suyo quales yo el dicho Notario lesnotare á vista de Letrados. Testigos PedroFernandez é Rui Gonzalez Racioneros dela dicha Yglesia, é Alons
3 B2T10	ni por menos, ni por el tanto. É ambaslas dichas partes otorgaron dos contratos en forma. Testigos Pedro Fernandezé Rui Gonzalez, é Monso Go
4 B2T11	Yglesia = Petrus Gonzalez PorcionariusNotario Apostolico En la Ciudad de Plasencia viernes diez y to ocho dias de Noviembre año del nasArren
5 B2T12	(Blank page)Group 10 (M. Zidovec)Manuscript Image
6 B2T13	La autoridad ordinaria arrendo del dño.Cabildo el Corral y meson que está todo caido que dicen el Meson de ayuso en el arrabal desta dicha Ciude
7 B2T14	C i S Fasta aqui havia enido é tenia en rentaSancho Ortiz de A...ñiga, Canonigo deladicha Yglesia; los cuales bienes en Molino moliente y corrien
8 B2T15	Obligó a si y a sus bienes y a todas Sentencias de Santa Yglesia é fizo juramento de decir y aclarar todos losdichos vienes é de non encobrir del
9 B1D66	Algunos Beneficiados dela dicha Iglesia prerenidian haber los tales oficiosdisien do que les pertenescen e otrosBeneficia dos tienen la grande opir
10 B1D71	la dicha Iglesia sobre sus Dignidadex personargos canongias y Trebendas, y Raciones y Beneficios Eccos. Que losdhos Beneficiados sienen y p
11 B1D86	ses e temporales presentes e fusunos 85 e otorganon dos contraros firmes por mi el dicho Gutierre Gonz-No.º para cadaalmo delas dichas partes
12 B3P59	[First line not visible] ra de juicio y por ese mesmo fecho in curran en Sentencia de excommunion de la qual no puedan haver absolucion sin prim
13 B3P60	dellos que lo non guardasen é por su sen tencia definitiba rescivirla por si mes mo en escritos, lo pronuncio y mandó declanó y confirmó diciendo
14 B3P51	[first line missing] Dean y Cabillo; para lo qual todo y cada cosa dello obligaron á ello y á todos sus vienes havidos y por ha ver muebles y raices
15 B3N3	en una linde traviesa, é en un mojon q,e está cerca della, é cerca de unas Encimas é fasta aqui es linderro la dicha tierra del dicho Gonzalo Berdu
16 B3N7	. Gonzalez; é dela otra parte casas de hijos de MartIn Sanchez, é dela otra parte la dicha Calle, é el traslado de este testamento, tienelo Gil Martí
17 B3N5	la figuera heredad de fijo de Esteban Sa chez, é por parte de ayuso de dicho camino, é dela otra parte contra Albalat here dad de Gonzalo Berduq

Figura 7.6: Documento obtenido del proceso de la limpieza

7.2.3. Flujos de trabajo

EL primer paso a realizar ya una vez se cuenta con el documento limpio, es realizar un flujo en KNIME con la finalidad de terminar el filtro de palabras y caracteres “basura”, para esto, el flujo realizado es un **Tag Cloud**, tal como se puede observar en la imagen 7.7 y en la imagen 7.8, el proceso realizado posterior a la construcción del flujo, consiste en realizar una observación al resultado del mismo e identificar las palabras que “no sirven”, junto con los nombres de las diferentes personas que se puedan haber encontrado, y cada vez que se encontraban, el flujo se volvía a hacer, pero esta vez se le añadían los filtros ya antes mencionados, esto con la finalidad de obtener la mayor cantidad de nombres posible.

7.3. Correlaciones

Una vez se cuenta con los diccionarios es posible realizar una búsqueda de las correlaciones existentes entre A y B , siendo A y B diccionarios.

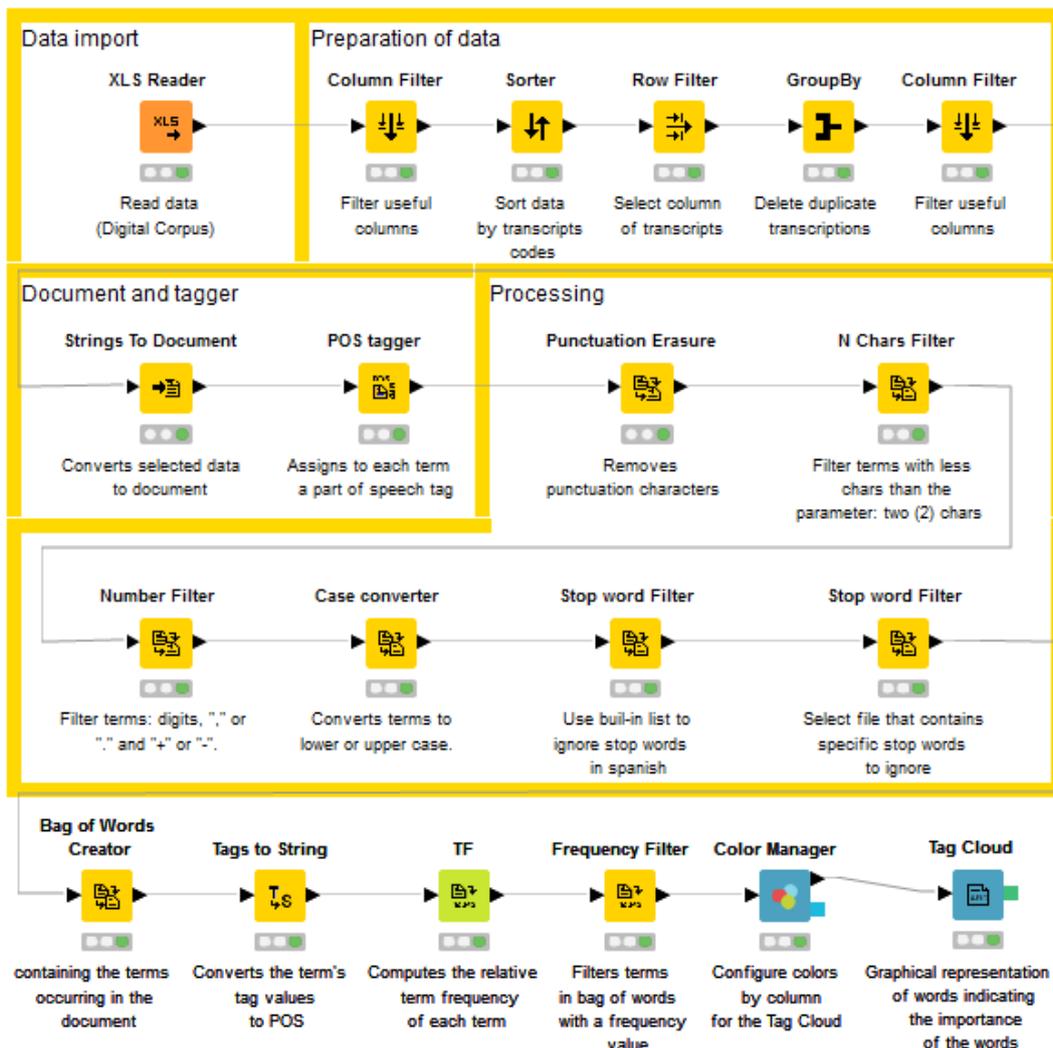


Figura 7.7: Flujo en KNIME de Tag Cloud para limpieza y extracción

Las correlaciones dadas en este punto son dependientes del orden de entrada de los diccionarios, es decir, la correlación planteada se encuentra dada por la siguiente formula matemática:

Si $A \neq B$ entonces

$$A \rightarrow B \neq B \rightarrow A$$

Si $A = B$ entonces

$$A \rightarrow B = B \rightarrow A$$

Esto teniendo en cuenta que tanto A como B representan el conjunto de elementos que componen cada diccionario, en la practica para este tipo de relaciones, en la cual se cuentan la cantidad de los elementos de B que se encuentran en la misma transcripción que al menos un elemento de A es mediante el siguiente código.



Figura 7.8: Tag Cloud para limpieza y extracción

```

1 for e in transVal.iteritems():
2     s = str(e[1])
3     for ed1 in ld1:
4         if s.find(ed1) != -1:
5             for ed2 in ld2:
6                 try: correlations[ed1][ed2] += s.count(ed2)
7                 except:
8                     try: correlations[ed1][ed2] = 0
9                     except: correlations[ed1] = {ed2 : 0}

```

En el código anterior, *e* representa una transcripción, *ed1* representa un elemento del primer diccionario ingresado y *ed2* representa un elemento del segundo diccionario.

Capítulo 8

Conclusiones

Al realizar el proyecto Minería de texto histórica - colaboración al proyecto ‘Revealing Cooperation and Conflict Project’ fue posible resaltar el hecho de que a pesar que existen muchos ámbitos de estudio y de investigación, todos ellos no tienen porqué desarrollarse por separado. Es este el caso en el que desde la informática fue posible colaborar en el desarrollo de un proyecto humanístico de tal manera que se fomentó participación y como ya se mencionó, un dialogo fluido entre ambas disciplinas. Hay dos cosas importantes a rescatar, en primer lugar la profundización que se ha hecho para la rama de la minería de texto histórica y más específicamente con la producción de los diccionarios que apoyan directamente la investigación de Dr. Martínez-Dávila pues dicha lista de palabras claves y descubrimiento de correlaciones entre las mismas permite, en la medida y forma de su uso, entre otras cosas, verificar o tener más certeza sobre las propuestas y descubrimientos que se han hecho.

En segundo lugar es posible afirmar que teniendo los textos históricos digitalizados listos para su análisis, por medio de una metodología que permita conocer el corpus, adaptarlo según la información necesaria, manipularlo de tal manera que solo la información relevante quede disponible para el investigador, haciendo tratamientos basados en el lenguaje y en palabras clave, utilizando técnicas estadísticas y matemáticas, para finalmente obtener resultados gráficos, si agiliza el proceso que el experto debe llevar a cabo para descubrir información. Lo anterior se ve apoyado en el hecho de que con hacer uso de la metodología con el corpus de Actas Capitulares de la Catedral de Plasencia es posible identificar lugares, nombres, apellidos, palabras de la época, abreviaciones de términos, entre otros, que permitirán ir forjando una idea del texto que se está utilizando sin la necesidad de descubrirlos por medio de la lectura detenida.

Después de realizar todo el análisis usando la metodología queda en manos del profesional interesado, ya sea historiador, paleógrafo o geógrafo, utilizar los resultados obtenidos de manera que tenga el poder de saber que información va a tener en cuenta y cual información no es útil para su trabajo.

También se concluye que efectivamente el uso de técnicas de minería de texto sobre documentos históricos se ve afectado por el lenguaje antiguo en que están escritos los mismos, las técnicas se basan en el uso de lenguajes modernos, en este caso, difiriendo bastante de los de la fuente. Para hacer minería de texto histórica hay que tener muy presente que será necesario conocer aquel lenguaje antiguo del que se esté dependiendo. Para el uso de la metodología realizada fue necesaria la creación manual de listas de palabras a ser ignoradas al momento de analizar el corpus pues no hacían parte del lenguaje y desviaban los resultados hacía incongruencias e incluso alteraciones de la información.

Teniendo en cuenta la naturaleza del corpus, el proceso de preparación y limpieza de los datos fue complejo debido al formato en el que fueron entregados los mismos. No solo influyó el hecho de que se tenía una gran cantidad de datos desordenados pues el libro de las Actas Capitulares de la Catedral de Plasencia no estaba digitalizado como tal sino se tenían fragmentos digitalizados provenientes de los resultados del MOOC que realizó Dr. Roger Louis Martínez-Dávila, también influyó el hecho de que las transcripciones no venían totalmente limpias y listas para su uso, incluían gran cantidad de código HTML filtrado entre las mismas lo cual fue un gran problema a la hora de evidenciar la real información ya que si se incluía el texto de esta manera sobre la metodología realizada en la herramienta KNIME, sería imposible obtener resultados correctos pues la máquina entendería que aquellos códigos también hacen parte de la terminología del texto y lo incluiría en el análisis como cualquier otra cadena de texto.

Aparte de lo anterior, otro problema con respecto a la información suministrada fue que, no incluía un patrón claro que permitiera desarrollar fácilmente un algoritmo para limpiar rápidamente el texto sino que fue necesario descubrir la mayor cantidad de patrones que seguía la serie de transcripciones para poder lograr limpiar y organizar las mismas, el desarrollo del algoritmo tampoco fue sencillo y requirió incluso transformación de caracteres y texto a los símbolos del lenguaje español.

Apéndice A

Diccionarios

Se presentan los siguientes diccionarios de palabras clave, descubiertas a partir de Actas Capitulares de la Catedral de Plasencia acorde con los objetivos específicos propuestos para el proyecto:

- Diccionario de nombres
- Diccionario de roles
- Diccionario de lugares

Con respecto al diccionario de palabras claves que incluye términos relacionados con los roles de la época, se presenta también un diccionario de roles en aspectos generales, que no incluye especificaciones demasiado profundas encontradas dentro de la información.

A.1. Diccionario de Nombres

A continuación se muestra el Diccionario de nombres que surge del análisis de las Actas Capitulares de la Catedral de Plasencia, es posible encontrar los nombres de los personajes con las ocurrencias frecuentes (en sus diferentes variaciones).

- | | |
|----------------------------|----------------------------|
| 1. Abaen Zapatero | 6. Albaro de San Pedro |
| 2. Abraen | 7. Albar Sanchez |
| 3. Abraen Zapatero | 8. Albar Sanchez de Toledo |
| 4. Adorraesmen | Eino del Rey |
| 5. Alban Sanchez de Foledo | 9. Alcalde |

-
- | | |
|-------------------------------------|---|
| 10. alíed Arradamen | 35. Alfonso Maxnin |
| 11. Alfgonso Sanchez | 36. Alfonso Sanches de Anuncio |
| 12. Alfonnes Canonicus | 37. Alfonso Sanchez |
| 13. Alfonsies Ferrandez | 38. Alfonso Sanchez de Amusco |
| 14. Alfonso de Garganta la Olla | 39. Alfonso Sanchez Molinero |
| 15. Alfonso de Organ | 40. Alfonso Sanchez Montero |
| 16. Alfonso Emo | 41. Alfonso Til |
| 17. Alfonso Feltez | 42. Alfonsus |
| 18. Alfonso Fernandez | 43. Alfonsus (Alfonso) |
| 19. Alfonso Ferrandez | 44. Alfonzo Ferrandez |
| 20. Alfonso Ferrandez de Logroño | 45. Alfonzo Gomez |
| 21. Alfonso Ferrandez de Sogrono | 46. Ali Arradamen |
| 22. Alfonso Garcia | 47. Ali Moro |
| 23. Alfonso Garcia Fesoreno | 48. Alonso Fellez |
| 24. Alfonso Gomez | 49. Alonso Ferrandez Panaigua |
| 25. Alfonso Gomez Cabrero | 50. Alonso Ferrandez Paniagua Caballero |
| 26. Alfonso Gonzalez | 51. Alonso Gonzalez |
| 27. Alfonso Gonzalez Criado | 52. Alonso Gonzalez de Amusco |
| 28. Alfonso Gonzalez de Amasco | 53. Alonso Gonzalez de Arranco |
| 29. Alfonso Gonzalez de Amusco | 54. Alonso Gonzalos |
| 30. Alfonso Gonzalez de Medina | 55. Alonso Gutierrez |
| 31. Alfonso Jimenez | 56. Alonso Martinez |
| 32. Alfonso Martin | 57. Alonso Sanchez |
| 33. Alfonso Martinez | 58. Alonso Sanchez del Montalban |
| 34. Alfonso Martinez dela Corraliza | 59. Alvar Blazquez |

-
- | | |
|---|---------------------------------------|
| 60. Alvar Garcia de Grimaldo | 84. Arediano de traxillo |
| 61. Alvaro de Salazar | 85. Bachillen |
| 62. Alvaro de San Pedro | 86. Bachiller Rui Garcia
Canonigos |
| 63. Alvarus Decanus Placentinus
Alfonsus | 87. Bano gomez |
| 64. Amat Moro Bexarano | 88. Bano Gomez |
| 65. Amat Moro Teredor | 89. Bano Gomez Racioneros |
| 66. Andreas Perez | 90. Barco Ferrandez |
| 67. Andres Domingez | 91. Barco Gomez de Saabedar |
| 68. Andres Dominguez | 92. Barrolome San Chez |
| 69. Andres Domintuez Bachiller | 93. Barrantolome Sanchez |
| 70. Andres Gonzalez | 94. Bartolomea |
| 71. Andres Martin | 95. Bartolome Sanchez |
| 72. Andres Perez | 96. Bartolomé Sánchez |
| 73. Andrez Gonzalez | 97. Basco Gomez |
| 74. Andrés Pérez | 98. Basco Gomez de Almaraz |
| 75. Antonio Grae | 99. Basco Gomez Racionero |
| 76. Antonio Martinez | 100. Basco Gonzalez |
| 77. AntonioMartinez | 101. Bascon Gomez |
| 78. Antonio Martinez Capellan | 102. Basio Gómez |
| 79. Antonius Martinus | 103. Beatriz |
| 80. Anton Perez | 104. Beatriz Solen |
| 81. Aparicio Martin | 105. Beatriz Soler |
| 82. Arcediano de Plasencia | 106. Belasan |
| 83. Arcediano de Trasillo | 107. Belasan Ortiz Porcionarius |
| | 108. Belascus |
| | 109. Belasio Ferrandez de Madrigal |

-
- | | |
|---|-----------------------------------|
| 110. Benita Benito Perez | 134. Demetia |
| 111. Benito Martin Perez | 135. Deneria |
| 112. Benito Perez | 136. Didacus Martíednez |
| 113. Benito Sanchez | 137. Diego Alfonso |
| 114. Benito Sanchez Osorio | 138. Diego Alfonso Molinero |
| 115. Blanco Perez | 139. Diego Bermejo |
| 116. Blasco Ferrandez | 140. Diego Blasco |
| 117. Blasco Gomez | 141. Diego Blascp |
| 118. Blasco Gomez de Alma | 142. Diego de Matos |
| 119. Blasco Gomez de Almaraz | 143. Diego de Riorsonsillo |
| 120. Blasco Perez | 144. Diego Esteban |
| 121. Capellan | 145. Diego Esteban de Xaariz |
| 122. CAROLUS IV | 146. Diego Ferrandez |
| 123. Christobal Sanchez | 147. Diego Ferrandez dela Coralla |
| 124. Christobal Sanchez Canonigo | 148. Diego Ferrandez Subchantre |
| 125. Christobal Sanchez Conomigo | 149. Diego Ferrandez Troton |
| 126. Clemeinte | 150. Diego Garcia |
| 127. Cofradia de Santi-Espiritus | 151. Diego Garcia Bexenano |
| 128. condera | 152. Diego Garcia Bexerano |
| 129. Cristóbal Sánchez | 153. Diego Gómez |
| 130. Dean Cabillo | 154. Diego Gomez |
| 131. Dean Don Diego Blazquez | 155. Diego Gomez de Almanaz |
| 132. Dean Don Juan Sanchez
y Sacristanes | 156. Diego Gonzalez Compañenos |
| 133. Dean y Cabillo | 157. Diego Gonzalez de Carvajal |
| | 158. Diego Marcos |
| | 159. Diego Marrin Sabrador |

-
- | | |
|--|---|
| 160. Diego Martíednez | 183. Dn. Alvaro de Salazar |
| 161. Diego Martin | 184. Dn Gil Martinez Arcediano
de Traxillo |
| 162. Diego Martinez | 185. Dn Gonzalo Garcia de Carvajal |
| 163. Diego Martinez del Barco | 186. Dn. Gonzalo Gutierrez |
| 164. Diego Martinez Racionero | 187. Dn. Martin Fernandez
Arcediano |
| 165. Diego Muñoz | 188. Dn Martin Ferrandez Bachiner |
| 166. Diego Nuñez, | 189. Dn. Miguel Sanchez |
| 167. Diego Nuñez | 190. Dn Miguel Sanchez Arcediano |
| 168. Diego Obispo de Plasencia | 191. Dn.Til Martinez |
| 169. Diego Perez | 192. Doña Benita |
| 170. Diego Perez de Granada | 193. Doña Gracia |
| 171. Diego Perez Torreno | 194. Doña Leonor |
| 172. Diego Perez Torrero | 195. Doña Mari-Perez |
| 173. Diego Pimentel Machacon de
Deleitosa | 196. Doña Nuña |
| 174. diego Rodriguez de Carvajal | 197. Doña Pasquala |
| 175. Diego Rois | 198. Doña Plata |
| 176. Diego Sanchez | 199. Doña Sol |
| 177. Dn Albaro de Morray | 200. Doña Sol muger de Pasaron |
| 178. Dn. Alfonso Garcia | 201. Doña Ximena |
| 179. Dn. Alfonso Garcia Arcediano
de Troxillo | 202. Doctor Don |
| 180. Dn. Allaro | 203. Doctor Don Jil Martinez
de Soria |
| 181. Dn Alvaro | 204. Doctor Garcia Lopez |
| 182. Dn Alvaro de Morroy | 205. Doctor Juan Fernandez |

-
- | | |
|--|--|
| 206. Domingo Martin | 229. (Don) Garcia Lopez deCarvajal |
| 207. Dona Bartolomea | 230. Don Gonzalo de Astuniga |
| 208. Dona Beatriz | 231. Don Gonzalo Gutierrez dela
Calleja Chansre |
| 209. Dona Benita | 232. Don Gonzalo Obispo |
| 210. Don Abraen | 233. Don Juan Inez Chantre |
| 211. Dona Gracia | 234. Don Juan Sanchez Chantre |
| 212. Dona Leonor | 235. Don Marcos |
| 213. Don Alfonso Garcia | 236. Don Martin Fernandez
de Sonia |
| 214. Don Alfonso Garcia Arcediano
de Fraxillo | 237. Don Martin Ferran |
| 215. Don Alfonso Garcia Fesoxero | 238. Don Martin Ferrandez |
| 216. Don Aloaro de Salazar | 239. Don Martino Ferrandez |
| 217. DonAlonso Rodriguez de
Alabienda | 240. Don Migan |
| 218. Don Alvaro de Salazan | 241. Don Miguel Inez |
| 219. Don Alvaro de Salazar Dean | 242. Don Miguel Sanchez |
| 220. Dona Pasquala | 243. Don Millan |
| 221. Don Arradamen | 244. Don Pedro Ferrandez |
| 222. Don Arradamen Moro | 245. Don Pedro Obispo |
| 223. Dona Teresa | 246. Don Rodrigo de Carvafal |
| 224. Doñin Bartolomea | 247. Don Rodrigo de Carvajal |
| 225. don Clemeinte | 248. Don Ruarcos |
| 226. Don Clemeinte | 249. Don Rui Garcia de Salamanca |
| 227. Don Clemente dela Figuera | 250. Don Yaco Albeha |
| 228. Don Diego Blazqz | 251. Don Yusaf |
| | 252. Duran González |
| | 253. el Arcediano Don Timon |

-
- | | |
|-------------------------------------|--|
| 254. el conde | 279. Ferran Alfonso Bachiller |
| 255. Eluego | 280. Ferran Alfonso Clerigo de San Esteban |
| 256. Elvira | 281. Ferran Alfonso de Garganta la Olla |
| 257. Ervira | 282. Ferran Alvarez |
| 258. Estaban Sanchez | 283. Ferran deLogroño, |
| 259. Esteban Fernandez | 284. Ferrandez Bravo |
| 260. Esteban Hernandez el Bote | 285. Ferrandez Cabillo E Aldonso |
| 261. Esteban Hernandez Jil Martinez | 286. Ferrandez Canonigo |
| 262. Esteban Perez | 287. Ferrandez del Barco |
| 263. Esteban Sanchez | 288. Ferrandez Mojon Viejo |
| 264. Estevan Sanchez | 289. Ferrando Gomez |
| 265. Eyo Alfonso Ferrandez | 290. Ferran Dominguez |
| 266. Facen Herrador | 291. Ferran Dominguez de Salamanca |
| 267. Falabera Berracol | 292. Ferran Garcia |
| 268. Fancino Hil el Viglo | 293. Ferran Garcia del Parco de Castano |
| 269. Fancisco Fernandez de Foritzo | 294. Ferran Garcia del Parco del Castaño |
| 270. Fatigos Arias Salado | 295. Ferran Gonzalez |
| 271. Fernandas Garcia | 296. Ferran Gonzalez de Villanueva |
| 272. Fernandez Lassre | 297. Ferran Gonzalez Racionero |
| 273. Fernando Garcia | 298. Ferran Martinez |
| 274. Fernán Martínez | 299. Ferran Martinez Bachiller |
| 275. Ferran | 300. Ferran Martinez Racionero |
| 276. Ferran Albarez | |
| 277. Ferran Albarez de Montalban | |
| 278. Ferran Alfonso | |

- | | |
|---|---|
| 301. Ferran Martinez Sobchantre
Gonzalo de Salamanca | 323. Foribus (Martinzede Villarba
Canonigos) |
| 302. Ferran Perez | 324. Forivio Ferrandez |
| 303. Ferran Pérez | 325. Forivio Ferrandez Esno |
| 304. Ferran Rodrigues | 326. Francisco Ferrandez |
| 305. Ferran Rodriguez | 327. Fran Martinez Canonigor |
| 306. Ferran Sanchez | 328. Fray |
| 307. Ferran Sanchez de Tarandilla | 329. Gabriel Sanchez |
| 308. Ferran Ximenez el mozo | 330. García Alvarez de Toledo |
| 309. Ferran Ximenez el Mozo | 331. García Gonzalez |
| 310. Ferran Yniguez | 332. Garcia Alfonso |
| 311. Ferrigo Martin Fernandez de
Logroño | 333. Garcia de Castrobende |
| 312. Ferrigos | 334. Garcia de Castroberde |
| 313. Ferrigos Martin | 335. Garcia de Plasencia |
| 314. Ferron Martinez Lohantre | 336. Garcia Feranrarius Placentinus |
| 315. Festigos Juan Ferrandez dela
Magalena | 337. Garcia Fernandez |
| 316. Festigos Sancho Ortiz de
Astañiga | 338. Garcia Fernandz de miranda |
| 317. Foribio Ferrandez | 339. Garcia Ferrandez |
| 318. Foribio Sanchez | 340. Garcia Gonzalez |
| 319. Foribio Sanchez del Barco Racio | 341. Garcia Gonzalez de Herrea |
| 320. Foribio Sanchez y Garcia Lopez | 342. Garcia Lopez |
| 321. Foribus | 343. Garcia Lopez de Carvafal |
| 322. Foribus Martinez de Villarba | 344. Garcia Lopez de Carvajal |
| | 345. Garcia Lopez Diego Martinez |
| | 346. Garcia Lopez Jastre |
| | 347. Garcia Lopez Jaure |
| | 348. Garcia Lovo |

-
- | | |
|-------------------------------------|---|
| 349. Garcia Marquez | 374. Gonzalo Bendugo |
| 350. Garcias Ferrandez | 375. Gonzalo Berduga |
| 351. Garcpia Fernandez | 376. Gonzalo Berdugo |
| 352. Gil Esteban | 377. Gonzalo Blazquez |
| 353. Gil Fernandez | 378. Gonzalo de Astonga |
| 354. Gil Martinez | 379. Gonzalo de Ballejo |
| 355. Gil Martinez de Soria | 380. Gonzalo de Salamanca |
| 356. Gil Martínez | 381. Gonzalo Ferrandez |
| 357. Gómez Fernando | 382. Gonzalo Ferrandez de Sevilla |
| 358. Gomez Fernandez | 383. Gonzalo fijo de Blasco Sanchez |
| 359. Gomez Fernandez de Albalad | 384. Gonzalo García de Carvajal |
| 360. Gomez Fernandez de Albalade | 385. Gonzalo Garcia |
| 361. Gomez Ferrandez | 386. Gonzalo Gutierre |
| 362. Gomez Ferrandez canonigo | 387. Gonzalo Gutierrez |
| 363. Gomez Ferrandez de Albalád | 388. Gonzalo Gutierrez dela
Callefa Chasmtram |
| 364. Gomez Garcia | 389. Gonzalo Gutierrez de la
Callejas Tesorero |
| 365. Gomez Gerrandez | 390. Gonzalo Gutierrez della Calleja |
| 366. Gomez Gonzalez | 391. Gonzalo Martin |
| 367. Gonazlo Bendigo | 392. Gonzalo Martin de Albalad |
| 368. Gonzalbus (Gonzales) Gutierrez | 393. Gonzalo Martinez |
| 369. Gonzalbus Gutierrez | 394. Gonzalo MartinezPerriguero |
| 370. Gonzalez | 395. Gonzalo Martinez Persiguero
y Aparicio |
| 371. Gonzalez Porcionarius | 396. Gonzalo Martinez Pertiguero |
| 372. Gonzalo Alfonso | |
| 373. Gonzalo Alfonso Penniguero | |

-
- | | |
|--|------------------------------|
| 397. Gonzalo Martinez Poriguero y Albano | 421. Jil Esteban |
| 398. Gonzalo Martinez Portiguero | 422. Jil Fernandez |
| 399. Gonzalo Matas | 423. Jil Ferrandez |
| 400. Gonzalo Monso | 424. Jil Gutierrez |
| 401. Gonzalo Monto Portigueno | 425. Jil Gutierrez Nacionero |
| 402. Gonzalo Perez dela Camana | 426. Jil Gutiertez |
| 403. Gonzalo Perez dela Camara | 427. Jil Martinez |
| 404. Gonzalo Ruiz | 428. Joanes |
| 405. Gonzalo Ruiz Capellanes | 429. Joanes Ferrandez |
| 406. Gonzalo Sanchez | 430. Joanes (Juan) |
| 407. Gonzalo Xil Ferrus | 431. Juan |
| 408. Gonzalo Yanez | 432. Juana Gonzalez |
| 409. Gregorio Martinez | 433. Juan Alfonso |
| 410. Gunierre Gonzales | 434. Juan Alfonso Zapatero |
| 411. Guriox de Gonzalez | 435. Juan Alonso |
| 412. Gutierre Gonzalez | 436. Juan Alonso de Fiasillo |
| 413. Gutierre Gonzalez del Barco | 437. Juan Clemente Racionero |
| 414. Gutierrez Ferrandez | 438. Juan de Alva |
| 415. Gutierrez Gonzalez | 439. Juan de Carvajal |
| 416. Gutierroz Gonzalez | 440. Juan de Guadalfajara |
| 417. Gutierr.z Gonzalez | 441. Juan del Barco |
| 418. Hamados Alfonn | 442. Juan de Logroño |
| 419. Iague Sancho de Albalad | 443. Juan de Obiedo |
| 420. Jean Criado | 444. Juan de Perea |
| | 445. Juan de San Juan |
| | 446. Juan Duran |

-
- | | |
|---|--------------------------------------|
| 447. Juanes Canonicus | 470. Juan Martín Merino |
| 448. Juan Feliz Cierrigo de San Nicolas | 471. Juan Mateos |
| 449. Juan Fernandez | 472. Juan Mateos Capellan |
| 450. Juan Fernandez de la Corchuela | 473. Juan Mateos Clerigo de Santiago |
| 451. Juan Ferrandez | 474. Juan Nisñez de Villalobos |
| 452. Juan Ferrandez | 475. Juan Nuñez |
| 453. JuanFerrandez | 476. Juan Nunez |
| 454. Juan Ferrandez Capellanes | 477. Juan Paneagua |
| 455. Juan Ferrandez de Betamos | 478. Juan Paneagua |
| 456. Juan Ferrandez de Betanzos | 479. Juan Perez |
| 457. Juan Ferrandez de Cabrenos | 480. Juan Perez de Buenabentura |
| 458. Juan Ferrandez de Cabreros | 481. Juan Rodríguez de Fuentevero |
| 459. Juan Ferrandez de Velvis Clerigo | 482. Juan Rodriguez |
| 460. Juan Firrandez | 483. Juan Rodriguez de Sevilla |
| 461. Juan Garcíeda | 484. Juan Rodriguez de Sevilla |
| 462. Juan Garcia | 485. Juan Rodriguezez |
| 463. Juan Gomez | 486. Juan Ruiz |
| 464. Juan Gomez Bofon | 487. Juan Ruzz deCamargo |
| 465. Juan Gonzalez Capellan | 488. Juan Sacristan |
| 466. Juan Gutierrez | 489. Juan Sanchez |
| 467. Juan Julian | 490. Juan Sanchez de Avila |
| 468. Juan Martin | 491. Juan Sanchez de Segovia |
| 469. Juan Martinez | 492. Juan Sanchez Jil |
| | 493. Juan Sanchez Notario |
| | 494. Juan Sanchez Racioneros |

-
- | | |
|--|--------------------------------|
| 495. Juan Sanchez Vicario | 518. Marcos Sanchez (Ballon) |
| 496. Juan San Pedro Gonzalez
Racionero | 519. Maria Alfonso |
| 497. Juan Simon | 520. Maria Basio |
| 498. Juan Sobrino de Diego
Martinez del Barco | 521. Maria Blanco |
| 499. Juan Timon | 522. Maria Blasio la Rebellada |
| 500. Juez | 523. Maria Blasu la Habellada |
| 501. Leyer Arcediano | 524. Maria de Candelaria |
| 502. Llorencio Perez | 525. Maria de Candeleta |
| 503. Llorencio Perez | 526. Maria Ferrandez |
| 504. Lope de Ruvian | 527. Maria Gonzalez |
| 505. Lope Ortiz de Montoya | 528. Maria Maria Martin |
| 506. Ludovicus Porcionarius | 529. Maria Martin |
| 507. Lugan | 530. Maria Sanchez |
| 508. Luis Alfonso | 531. Maria Sanchez su muger |
| 509. Luis Alfonso de Sevilla | 532. Mari-Diego (La Bóona) |
| 510. Luis Alonso de Sebilla | 533. Mari-Perez |
| 511. Luis Ferrandez | 534. Mari Sanchez |
| 512. Luis Ferrandez Bachillen | 535. Marta Ferrandez |
| 513. Luis Gonzalez | 536. Martin Blasco |
| 514. Luis Gonzalez de Turones | 537. Martin de San Esteban |
| 515. Luis Sanchez Vicario | 538. Martin Diego |
| 516. Mansion Perez | 539. Martin Diego Corcho |
| 517. Maras Sanchez Ballon | 540. Martin Diego Corcho |
| | 541. Martin Dominguez |
| | 542. Martinez del Barco |

-
- | | |
|-------------------------------------|------------------------------------|
| 543. Martinez de Villarba Canonigos | 568. Miguel Sanchez |
| 544. Martin Fernandez | 569. Miguel Sanchez de Asetuna |
| 545. Martin Ferrandez | 570. Miguel Sero |
| 546. Martin Francisco Carbonero | 571. Miguel Soté |
| 547. Martin Gonzalez de Albalad | 572. Miguel Yague |
| 548. Martin Perez | 573. Monar Juan Garcia |
| 549. Martin Sanchez | 574. Monso Gonzalez |
| 550. Martin Yañez | 575. Nicolas de Castro |
| 551. Martin Yanez | 576. Nicolas Fernandez |
| 552. Martín Blasco | 577. Nicolas Ferrandez |
| 553. Martín Sanchez | 578. Nicolas Ferrandez de Sandobal |
| 554. Mateo Sanchez Ballestero | 579. Nicolaus Fernandez |
| 555. Mateo Sanchez (Ballon) | 580. Nicolaus (Nicolas) Fernandez |
| 556. Mateo Sanchez Ballon | 581. Nicolavo |
| 557. Mayordomo del Obispo | 582. Notario publico |
| 558. Mayordomos | 583. Nuño Alfonso |
| 559. Mencia Sanchez | 584. Obispo de Plasencia |
| 560. Menga Munos | 585. oficios decinales |
| 561. Menga Muñoz | 586. Parecs Gonzles |
| 562. Mera Capiralar | 587. Pedo Gonzalez |
| 563. Meton Perribado | 588. Pedro Cabildo |
| 564. Miguel de Froxillo | 589. Pedro Chamizo |
| 565. Miguel Lopez | 590. Pedro de Alfaro |
| 566. Miguel Lopez de Buendia | 591. Pedro de Trejo |
| 567. Miguel Martinez | 592. Pedro de Valladolid |

- | | |
|---|-------------------------------------|
| 593. Pedro de Valladolid de avia fajo | 616. Persigueso |
| 594. Pedro Feirandez | 617. Pesrus Ferrandez |
| 595. Pedro Fernandez | 618. Pesrus (Pedro) Ferrandez |
| 596. Pedro Ferradez | 619. Pestus Gonzalez |
| 597. Pedro Ferrandez | 620. Petrus Fernandez |
| 598. Pedro Ferrandez del Hoyo | 621. Petrus Ferrandez |
| 599. Pedro Ferrandez de Logroño | 622. Petrus Ferrandez Portionarius |
| 600. Pedro Ferrandez de Soria Racionero de la dha | 623. Petrus Gonzales |
| 601. Pedro Ganzalez Rocionero | 624. Petrus Gonzales Poraisanius |
| 602. Pedro Garcia Sobrado | 625. Petrus Gonzalez |
| 603. Pedro Gonsalez Racionero | 626. Petrus Gonzalez |
| 604. Pedro Gonzales | 627. Petrus Gonzalez Poriconarius |
| 605. Pedro Gonzales Racionero | 628. Petrus Gonzalo |
| 606. Pedro Gonzalez | 629. Petsus Forrandez |
| 607. Pedro Gonzalezo | 630. Plata |
| 608. Pedro Gonzalez Racionero | 631. Porcionarius |
| 609. Pedro Gutierrez | 632. Ramin Nuñez |
| 610. Pedro Jil fijo de Alfonso Jil de Granada | 633. Ramir Nu |
| 611. Pedro Juan el Ballon | 634. Ramir Nuñez |
| 612. Pedro Juan Ferran | 635. residentes en la dicha Yglesia |
| 613. Pedro Lopez | 636. Rey e Reyna |
| 614. Pedro Martinez | 637. Roder |
| 615. Pedro Sanchez | 638. Rodericcus |
| | 639. Rodericus |
| | 640. Rodericus Archidia |
| | 641. Rodericus Breala Canonicus |

-
- | | |
|------------------------------|----------------------------------|
| 642. Rodericus (Rodrigo) | 667. Sanelu Gomez |
| 643. Rodericus(Rodrigo) | 668. San Esteban Petrus Gonzalez |
| 644. Rodrigo Alfonso | 669. San Juan |
| 645. Rodrigo Alfonzo | 670. San Juan de Turio |
| 646. Roman Gondillo | 671. Santa Maria |
| 647. Rui Garcia | 672. Santo Perez |
| 648. Rui Garcia de Salamanca | 673. Senor Cabildo |
| 649. Rui Gomez | 674. Senor el Rey |
| 650. Rui Gonzalez | 675. Señor de Oropesa |
| 651. Ruiz de Camargo | 676. Señor el Conde de Astuñiga |
| 652. Ruy Gonzalez Racionero | 677. Sol |
| 653. Sadovicces | 678. Sope Diaz |
| 654. Sadovicces (Sandobal) | 679. Sra Pata |
| 655. Salvador Jesuchristo | 680. Su Señoría Eoblogo |
| 656. Sanchez Ballon | 681. Teresa Fernandez |
| 657. Sancho | 682. Teresa Lope |
| 658. Sancho de Albalad | 683. Teresa Lopez Martinez |
| 659. Sancho Ertiz | 684. Terran Marrniz |
| 660. Sancho Ertiz de Zuñiga | 685. Til Fernandez |
| 661. Sancho Gomez | 686. Till Garcia Juana Martinez |
| 662. Sancho Martinez | 687. Tome Gil de Juacos |
| 663. Sancho Ortiz | 688. Tome Gil de Quacos |
| 664. Sancho Ortiz Caronigos | 689. Toribio Fernandez |
| 665. Sancho Pasqual | 690. Toribio Ferrandez |
| 666. Sancho Sanchez | 691. Toribio Sanchez |
| | 692. Torivio Ferrandez |

- | | |
|--------------------------|-----------------------|
| 693. Torivio Sanchez | 700. Ybañez Sancho |
| 694. Trian de Carvasol | 701. Ynes Gonzalez |
| 695. ullí Moro | 702. Ysabel Alonso |
| 696. Vuclaus | 703. Yusaf |
| 697. Ximenez de Troxillo | 704. Yusefe Arañon |
| 698. Yague Sanchez | 705. Yusefe Champus |
| 699. Yague Sancho | 706. Zebrian Pimentel |

A.2. Diccionario de Lugares

A continuación se muestra el Diccionario de Lugares que surge del análisis de las Actas Capitulares de la Catedral de Plasencia, es posible encontrar las denominaciones de los lugares con las ocurrencias frecuentes (en sus diferentes variaciones).

- | | |
|--|-----------------------------------|
| 1. Albal | 14. Alveda del Yoglar |
| 2. Albalad | 15. Amasco |
| 3. Albaladejo | 16. Amat |
| 4. Albalat | 17. Amat Moro |
| 5. Aldeanueba | 18. Amusco |
| 6. Aldeanueva | 19. Aragon |
| 7. Alion de la Erguijuela de Arrañuelo | 20. Arcadia |
| 8. Alion dela Moeda del Yuglar | 21. Arranuelo |
| 9. Alion de Saucedilla | 22. arroyo Barbadon |
| 10. Almaraz | 23. arroyo de Barbadon |
| 11. Almonte | 24. Arroyo de Barbadon |
| 12. altozano de los frailes | 25. arroyo de la Cañada que dicen |
| 13. Alvalar | 26. arroyo de la Habaza |
| | 27. arroyo de la Pardala |

-
- | | |
|----------------------------------|-------------------------------------|
| 28. Arroyo de la Pardala | 53. Caballerias |
| 29. arroyo de lavin | 54. Cabrerros |
| 30. arroyodel fojarastan | 55. Calamoco |
| 31. arroyo del Tamujan | 56. Calle de Carretas |
| 32. arroyo del Tamujar | 57. calle de Diego Gomez de Almanaz |
| 33. arroyo de Pajarejos | 58. Calle de Dn Marcos |
| 34. arroyo de Valde-Miguel | 59. Calle de Don Marcos |
| 35. arroyo de Valde-Miguel Diego | 60. calle de hijos de Diego Gomez |
| 36. arroyo que viene ala fuente | 61. calle de Garcia |
| 37. Ayuntamientos | 62. Calle de Gracia |
| 38. Bara | 63. calle de la Gracia |
| 39. Barco | 64. Calle de la Rua |
| 40. Bartolomé Sanchez Serradilla | 65. calle de la Zapateria |
| 41. Bejar | 66. Calle de la Zapateria |
| 42. Benero de Doña Mayor | 67. calle del Concejo |
| 43. Bentosilla | 68. calle del Rey |
| 44. Berrocal | 69. Calle del Rey |
| 45. Berrocal de Garcia Lopez | 70. Calle del Sol |
| 46. Bexan | 71. Calle del Sol cerca de la Plaza |
| 47. Bexar | 72. calle de Santa María |
| 48. Boadilla | 73. calle de Santa Marída |
| 49. Bodega | 74. Calle de Santa Maria |
| 50. Bueso | 75. Calle de Talavera |
| 51. cañada de los Cebollares | 76. calle deTroxillo |
| 52. cañada de Ventosilla | 77. Calle de Troxillo |
| | 78. calle de Truxillo |

-
- | | |
|--|---|
| 79. Calle de zapateria | 103. canada delos Ganados |
| 80. Calle de Zapateria | 104. capella de Sant Pablo |
| 81. Calle de Zapteria | 105. capilla de San Pablo |
| 82. Calleja Fesorero | 106. Capilla de San Pablo |
| 83. calle mayor que bá al Portigo | 107. Capilla de San Pablo |
| 84. calle primera | 108. Capilla de Santa Catalina |
| 85. Calle publica de Concejo | 109. Capilla de Sant Paulo |
| 86. Calle publica del Rey | 110. Carvajal |
| 87. calle que dicen de Don Marcos | 111. Casa del Dean |
| 88. calle Santa Maria | 112. Casa de Mari-Domingo |
| 89. calles públicas del Rey | 113. casa en el arrabal de la dicha Villa |
| 90. Calle tras Santa Maria | 114. Casar de Elvira |
| 91. Calzones | 115. casares del Deanazgo |
| 92. camino a Mirabel | 116. casas dela Ensinilla |
| 93. camino de Coria a Plasencia | 117. Casas dela Ensinilla |
| 94. camino de Galisteo | 118. casas del Cabillo dela Universidad de-
los Clerigos |
| 95. Camino de la plaza | 119. casas de Santa Maria del Campo |
| 96. Camino del Carril | 120. Cerraldo |
| 97. camino de Plasencia | 121. Cerro del Padron |
| 98. camino de Plasencia a Coria | 122. cerro de Valde-Miguel Diego |
| 99. Camino Judeno | 123. Chintes |
| 100. camino que ba de Xaraicejo
a Plasencia | 124. Chistes |
| 101. campo del Calamoco | 125. Ciudad cerca dela Dejera |
| 102. Campo de Santa Maria | 126. Ciudad de Truxillo |
| | 127. Ciudad Real |
| | 128. Cofradia de Santi-Espiritus |

-
- | | |
|--|--|
| 129. Collado | 151. el camino que bá de Plasencia al Tanrin |
| 130. colmenas | 152. el cauce lin |
| 131. Coria | 153. el cerro Camino de las Casas |
| 132. Corral de cerrar Ganados | 154. el Gamonal |
| 133. corrales | 155. el Parral |
| 134. corte de Roma | 156. El Pueblo de Xadricejo |
| 135. Dehesa del Berrocal | 157. el Puerto del Caballo |
| 136. Dehesa del canchal | 158. el terreno de Doña Mayor |
| 137. Dehesa del Canchal | 159. Enguijuela de Arrañuelo |
| 138. Dehesa de los Cebollares | 160. Ensitrilla |
| 139. Dehesa de Meajadas | 161. Ergüijuela |
| 140. Dehesa de Mehafadas | 162. Erguijuela |
| 141. Dehesa de Santa Maria del Campo | 163. Erquijuela |
| 142. Deheza Santa Maria del Campo | 164. Ferrigos |
| 143. Delirosa | 165. Fesoreria |
| 144. Iglesia de Plasencia | 166. Fesorero |
| 145. Iglesia de San Esteban | 167. Florencia |
| 146. el arroyo dela fuente delos Vallesteros | 168. Froxillo |
| 147. el arroyo de los Maruteros | 169. Fuente de Ybañe Sancho |
| 148. el arroyo de Pajarejos | 170. fuero de Rivera |
| 149. el arroyo Guadaperal | 171. Galisteo |
| 150. el Cadozo de Dona Pasquala | 172. Garganta de Degüella Cabras |
| | 173. Granada |
| | 174. Guadalfajara |
| | 175. guijo |
| | 176. huerta del obispado |

-
- | | |
|---|---|
| 177. huertas | 200. la Perdiguera |
| 178. huerto de Zebrian Pimentel | 201. la Peñuela |
| 179. Iglesia de San Juan del Arrabal | 202. la puerta del Castillo |
| 180. Iglesia de San Martin | 203. las casas de Santa Maria del Campo |
| 181. Iglesia de San Martín | 204. Latacorno |
| 182. Iglesia de San Nicolás | 205. la torre de piedra del Concejo |
| 183. Iglesia de Santiago | 206. la villa de Plasencia |
| 184. Juacos | 207. la Villa de Plasencia |
| 185. La bodega | 208. linderosde |
| 186. laCalle de D.n Marcos | 209. linderos dela una parte el de Rio de Almonte |
| 187. La calle de Troxillo | 210. Logrono |
| 188. la calle de troxillo arroyo del tamusjan | 211. Logroño |
| 189. la Calle Real | 212. Logrosio |
| 190. la Carniceria | 213. los canchos |
| 191. la Casa dela Pardala | 214. los Sierros |
| 192. La clousstra | 215. Lugarde Garces |
| 193. La Delirosa heredamiento de Basco Gomez de Almaraz | 216. Maerrnots |
| 194. la dicha | 217. Magdalena |
| 195. la fuente de Ybañe Sancho | 218. Majuelo |
| 196. lagares | 219. Malpartida |
| 197. La Habaza | 220. Maluense |
| 198. la Panaderia | 221. Mardigal |
| 199. La Pardala | 222. Medellin |
| | 223. Mirabel |
| | 224. Moeda del Juglar |

-
- | | |
|----------------------------------|--------------------------|
| 225. mojon | 250. pueblo de Meafadas |
| 226. Molinos del Segura | 251. Pueblo de Meafadas |
| 227. Monasterio de San Yldefonso | 252. Pueblo de Meajadas |
| 228. Monroy | 253. Pueblo San Esteban |
| 229. Montalban | 254. Pueboo deXaraicejo |
| 230. Montanches | 255. puerta del Castell |
| 231. Monte | 256. puerta del Castillo |
| 232. monte de la Perdiguera | 257. puerta de Talabera |
| 233. Orellana | 258. puerto de Castaño |
| 234. Osada | 259. Puerto del Caballo |
| 235. Paente de Nieblas | 260. Puerto del Castano |
| 236. Pajarejos | 261. Puerto de Mirabese |
| 237. Palacios | 262. Puerto de Mirabete |
| 238. peñascal gran de de gijos | 263. Quacos |
| 239. Perdiguera | 264. Reportillo |
| 240. Pesebres | 265. Reyno |
| 241. Piedra | 266. Ribera de Garces |
| 242. Plascencia | 267. Riobermejo |
| 243. Plasencia | 268. Rio Bermejo |
| 244. Plasencia | 269. Riobermejo Aldea |
| 245. Plaza de Plasencia | 270. rio de Almon |
| 246. Plazos | 271. rio de Almonte |
| 247. Portezuelo | 272. Rio de Fejo |
| 248. Portigo | 273. rio de Tajo |
| 249. Pozo llamado Ollalla | 274. Rio de Tajo |
| | 275. Rio de Tejo |

-
- | | |
|--|--|
| 276. Rio Tajo | 300. Segovia |
| 277. Rio Tejo | 301. Segura |
| 278. Riotortillo | 302. Sevilla |
| 279. rio Xerete | 303. Sienna |
| 280. rio Xerete (Jerte) | 304. Sierro |
| 281. Romango fallo | 305. Soria |
| 282. Río zortillo | 306. Tajo |
| 283. Salamanca | 307. Tajo cerca dela Rodeznera |
| 284. San Esteban | 308. Tajo Jarrin |
| 285. SanJil | 309. Talaban |
| 286. San Juan | 310. Talabera |
| 287. San Juan de Turis | 311. Tanrin |
| 288. San Martin | 312. Tarrín |
| 289. San Pablo | 313. teuocillo |
| 290. San Pedro | 314. tierra de herederos del Esteban Sanchez |
| 291. Santa Iglesia de Roma | 315. Tierras de San Lazaro |
| 292. Santa Maria | 316. Toledo |
| 293. Santa Maria del Campo | 317. torre de piedra del Concejo |
| 294. Santa Maria de Troxillo | 318. Torre de Vigo |
| 295. Santa Mariala Catedral dela dicha | 319. Tozo |
| 296. Santa Yglesia de Roma | 320. Trofillo |
| 297. Santiago | 321. Troxillo |
| 298. Santiago del Arrabal | 322. Trujillo |
| 299. Saucedilla | 323. Truxillo |
| | 324. Vade-Miguel |
| | 325. Valdefinete |

-
- | | |
|--|---|
| 326. Valdejinete | 349. Villa de Galvisco |
| 327. Valde Milana | 350. Villa de Troxillo |
| 328. Valdoliba | 351. Villanba |
| 329. Valle de Doña Sol | 352. Villarbos |
| 330. Valle de Dona Sol | 353. Villarejo |
| 331. Valle de los Regueros | 354. Vina del Hospital |
| 332. Valle de los Requieros | 355. Xaar |
| 333. Valle de Milana | 356. Xaariz |
| 334. Vallejinete | 357. Xaraiz |
| 335. Vallestero | 358. Xarcaido |
| 336. Viña de Alfonso Alvarez | 359. Xerete (Jerte) |
| 337. Viña dela Sierra | 360. Yglesia Cardenal |
| 338. Viña del Caballo | 361. Yglesia Catedral |
| 339. Viña del Hombliguillo | 362. Yglesia Catedral de Santa Maria de Plasencia |
| 340. Viña del Hospital | 363. Yglesia de Plasencia |
| 341. Viña de los Clerigos de Santa Maria | 364. Yglesia de San Esteban |
| 342. Viña de Rodrigo Diaz | 365. Yglesia de San Eueban |
| 343. Viña la Blanca | 366. Yglesia de San Juan del Arrabal |
| 344. viña la Salgada | 367. Yglesia de San Pablo |
| 345. viñas | 368. Yglesia de Santa Maria |
| 346. Villa de Bexar | 369. Yglesia de Santa Maria |
| 347. Villa de Galinco | 370. Yglesia de San Vicente |
| 348. Villa de Galisteo | 371. Yusafe |

A.3. Diccionario de Roles

A continuación se muestra el Diccionario de Roles que surge del análisis de las Actas Capitulares de la Catedral de Plasencia, es posible encontrar las denominaciones de los roles con las ocurrencias frecuentes (en sus diferentes variaciones).

- | | |
|--|--|
| 1. Administracion | 18. Bachiller |
| 2. Albar Sanchez como su Fiador | 19. Bachiller en Leyes |
| 3. Alcalde | 20. Bano Gomez Racionero |
| 4. Alfonso Arias Alcalde | 21. Basco Gomez Racionero |
| 5. Alfonso Ferrandez de Logro que son de los doce caballeros | 22. Beneficiado dela dicha Yglesia |
| 6. Alfonso Ferrandez Racionero | 23. Beneficiados dela dicha Yglesia |
| 7. Alfonso Martinez Criado de Gonzalo Ruiz | 24. Bicario de Soria |
| 8. Alfonsus Ferrandez: Porcionarius | 25. Caballeria |
| 9. Algeiacil | 26. Cabildo y Beneficiados |
| 10. Alguacil de qualquier ciudad o villa Eclesiastico | 27. Cabillo dela Eglesia Catedral de Plasencia |
| 11. Alguacil de qualquier ciudad o villa Seglar | 28. Canongia: Petrus Ferrandez |
| 12. Alonso Gonzalez de Amusco Racionero dela dicha Yglesia | 29. Canonicus = Alfonsus |
| 13. Andres Perez Tesorero dela dicha Yglesia | 30. Canonicus = Foribus |
| 14. Arcipreste Racionero | 31. Canonicus = Joanes |
| 15. Arediano de Plasencia e de Bexar | 32. Canonigos |
| 16. Arrendador | 33. Canonigos y Racioneros dela dicha Yglesia |
| 17. Arresidador | 34. Capellan Clerigo de Fragon |
| | 35. Capellanos |
| | 36. Chantre = Alfonsus |
| | 37. Christobal Sanchez Canonigo |

- | | |
|--|---|
| 38. Clerigo de Santiago del Arrabab | 58. entregador de qualquier ciudad o villa Eclesiastico |
| 39. concejil | |
| 40. concejo que llaman Realenco | 59. entregador de qualquier ciudad o villa Seglar |
| 41. condera | 60. Escrivano |
| 42. Criado | 61. Escuderos |
| 43. Dean | 62. Escuderos |
| 44. debdor | 63. Esno publico en Talabera |
| 45. Decanus Placentinus = Rodericus Archidia | 64. Ferran Alfonso Clerigo de San Esteban |
| 46. Deudor | 65. Ferran Martinez Racioneros |
| 47. doctor | 66. Ferran Rodriguez e Juana Gonzalez su muger |
| 48. Doctor en Decreros | 67. Ferran Ximenez el Mozo |
| 49. Doeton = Nicolaus Fernandez | 68. Fesarerarius = Roder |
| 50. Dona Benita e de Benito Perez hermano del dicho Alfonso Martin | 69. Fiador |
| 51. Don Alfonso Garcia Arediano de traxillo | 70. fijo |
| 52. Don Gonzalo Gutierrez dela Calleja Chansre | 71. Foribus Martinez de Villarba Canonogos |
| 53. Egidius Archidiaconus deTruxillo | 72. Garcia Ferrandez como principal deldon y Arrendador |
| 54. el conde | 73. Gerran Martinez de Boadilla Nortario publico Apostolico |
| 55. el Doctor Garcia Lopez de Carvajal | 74. GilMartínez Clerigo de Albaláde |
| 56. el Mayordomo del Dean y Cabildo | 75. Gonzalo Gutierrez dela Calleja Tesorero |
| 57. El obispo Don Pedro | 76. Gonzalo Ruiz Clerigode Santiago del Arrabal |

- | | |
|---|---|
| 77. Gutierre Gonzalez del Barco
es Notario publico | 95. los Pobladores del Pueblo
de Meajadas |
| 78. Herederos | 96. Maestros |
| 79. Hermano | 97. Mayor-domo |
| 80. Juan Ferrandez de Betamos
Doctor en Decreros | 98. Mayordomo dela dicha Yglesia |
| 81. Juan Mateos Clerigo de Santiago | 99. mayordomos en la dicha ciudad |
| 82. Juez de qualquier ciudad o
villa Eclesiastico | 100. Merino de qualquier ciudad o villa
Eclesiastico |
| 83. Juez de qualquier ciudad o
villa Seglar | 101. Merino de qualquier ciudad o villa Se-
glar |
| 84. Jurado de qualquier ciudad o
villa Eclesiastico | 102. Mozos del coro dela dicha Yglesia |
| 85. Jurado de qualquier ciudad o
villa Seglar | 103. muger |
| 86. jurisdicion Eclesiastica | 104. Nicolas Ferrandez Clerigo de Quacos |
| 87. Jurisdicion Eclesiastica | 105. Notario |
| 88. La autoridad ordinaria | 106. Notario de nuestro Señor el Eleito |
| 89. Labrador dela dicha Viña | 107. Notario publico |
| 90. la corte de Senor el Rey de
qualquier Ciudad o Villa | 108. Obispado |
| 91. Licenciado en Leyes | 109. obispado eda dicha cuidad de Plasen-
ciado |
| 92. Licenciado en Leyes
Arcediano de Plasensia e de
Bexar | 110. Obispo de Plasencia |
| 93. lluenio Senor el Rey | 111. oficial |
| 94. los dichos Senores | 112. oficios decinales |
| | 113. otras personas singulares |
| | 114. pagador |
| | 115. Pagador |
| | 116. Pedro de Alfaro Criado de
Andres Perez |

- | | |
|---|---|
| 117. Pedro Ferrandez Racionero dela dicha Yglesia | 135. residentes en la dicha Yglesia |
| 118. Pedro Gonzalez Notario | 136. Rexidores |
| 119. Pedro Gonzalez Racionerode la dicha Yglesia Notario Apostolico | 137. Rui Garcia Canonigo en la dha Yglesia Cardenal |
| 120. Pedro Gonzalez Racionero Notario Apostolico de Yermo de Basco | 138. Rui Garcia de Salamanca Bachiller en Leyes |
| 121. Pedro Obispo | 139. Señor Provisor |
| 122. pobladores del Pueblo de Meafadas | 140. Señor Rui Garcia Vicario |
| 123. Porcionarius Notario Apostolico-En la Ciudad de Plasencia | 141. sobrino |
| 124. Porcionarius Pedro Ferradez | 142. Statuto |
| 125. Porcionarun = Pesrus Ferrandez | 143. Su Senoria |
| 126. Porcionarun Plasentinus = Sadovicces | 144. Tendero |
| 127. Porcionus | 145. Tesorero |
| 128. Primo | 146. testamentarios |
| 129. Provisor | 147. Testigos |
| 130. Provisor | 148. ullí Moro Carpintero |
| 131. publico Apostolico y testigos | 149. Vecinos |
| 132. Racionero deladicha Yglesia = Pedro Martinez | 150. vecinos de Medellin |
| 133. Racionero Juan Nuñez | 151. vecinos de Plasencia |
| 134. RacioneroNotario Apostolico | 152. vecinos de Talabera |
| | 153. Venerables Senores Don Alvaro de Salazan Dean, e Don Rodrigo de Carvajal |
| | 154. Vicario |
| | 155. Villalovos Canonigo de la dicha Yglesia |

A.4. Diccionario de Roles - general de la época

A continuación se muestra el Diccionario de roles general de la época que surge del análisis de las Actas Capitulares de la Catedral de Plasencia, es posible encontrar las denominaciones de los roles con las ocurrencias frecuentes (en sus diferentes variaciones).

- | | |
|--|---|
| 1. Administracion | 21. Canonigos y Racioneros dela dicha Yglesia |
| 2. Alcalde | 22. Capellan Clerigo de Fragon |
| 3. Algeiacil | 23. Capellanos |
| 4. Alguacil Eclesiastico | 24. Carpintero |
| 5. Alguacil Seglar | 25. Chantre |
| 6. Arcipreste Racionero | 26. Clerigo |
| 7. Arediano | 27. Clerigo de Albalá |
| 8. Arrendador | 28. Clerigo de Quacos |
| 9. Arresidador | 29. Clerigo de San Esteban |
| 10. Bachiller | 30. Clerigo de Santiago |
| 11. Bachiller en Leyes | 31. concejil |
| 12. Beneficiado dela dicha Yglesia | 32. concejo que llaman Realenco |
| 13. Bicario de Soria | 33. condesa |
| 14. Caballeria | 34. Criado |
| 15. caballeros | 35. Dean |
| 16. Cabildo y Beneficiados | 36. debdor |
| 17. Cabillo dela Eglesia Catedral de Plasencia | 37. Decanus Placentinus |
| 18. Canonicus | 38. Deudor |
| 19. Canonigo de la dicha Yglesia | 39. doctor |
| 20. Canonigos | 40. Doeton |
| | 41. el conde |

- | | |
|---|---|
| 42. el Mayordomo del Dean y Cabildo | 65. Merino Eclesiastico |
| 43. entregador Eclesiastico | 66. Merino Seglar |
| 44. entregador Seglar | 67. Mozos del coro dela dicha Yglesia |
| 45. Escuderos | 68. muger |
| 46. Esno publico en Talavera | 69. Nortario publico Apostolico |
| 47. Fiador | 70. Notario |
| 48. fijo | 71. Notario Apostolico |
| 49. Gonzalo Ruiz Clerigode Santiago del Arrabal | 72. Notario de nuestro Señor el Eleito |
| 50. Herederos | 73. Notario publico |
| 51. Juez Eclesiastico | 74. obispado eda dicha ciudad de Plasenciadado |
| 52. Juez Seglar | 75. Obispo de Plasencia |
| 53. Jurado Eclesiastico | 76. oficial |
| 54. Jurado Seglar | 77. oficios decinales |
| 55. Jurisdiccion Eclesiastica | 78. otras personas singulares |
| 56. Labrador dela dicha Viña | 79. pagador |
| 57. la corte de Senor el Rey | 80. Pagador |
| 58. Licenciado en Leyes | 81. Pobladores |
| 59. lluenio Senor el Rey | 82. pobladores del Pueblo de Meafadas |
| 60. los dichos Senores | 83. Porcionarius |
| 61. los Pobladores del Pueblo de Meajadas | 84. Porcionarius Notario Apostolico-En la Ciudad de Plasencia |
| 62. Maestros | 85. Porcionarun Plasentinus |
| 63. Mayor-domo | 86. Porcionus |
| 64. Mayordomos | 87. Primo |

- | | |
|------------------------------------|----------------------------------|
| 88. Provisor | 99. Tesorero |
| 89. publico Apostolico y testigos | 100. Tesorero dela dicha Yglesia |
| 90. Racionero dela dicha Yglesia | 101. testamentarios |
| 91. Racionero deladicha Yglesia | 102. Testigos |
| 92. RacioneroNotario Apostolico | 103. Vecinos |
| 93. residentes en la dicha Yglesia | 104. vecinos de Medellin |
| 94. Rexidores | 105. vecinos de Plasencia |
| 95. Señor Provisor | 106. vecinos de Plasencia |
| 96. Statuto | 107. vecinos de Talabera |
| 97. Su Senoria | 108. Venerables Senores |
| 98. Tendero | 109. Vicario |

Apéndice B

Código Python de limpieza de las transcripciones

El siguiente código escrito en **python 3** es el usado para la limpieza y separación de las transcripciones, de tal manera que sea posible realizar todos los trabajos siguientes:

```
1  #!/usr/bin/env python3
2  # -*- coding: utf-8 -*-
3  """
4  Created on Tue Nov 1 09:59:39 2016
5
6  @author: Juan Sebastian Martinez Serna,
7           Diana Maria del Pilar Socha Diaz
8  """
9
10 import pandas as pd
11 import ast
12
13 # s = "ferdand\u00E9"
14 # print s.decode('unicode-escape')
15 # >>> fernandé
16
17 def deleteTag(s):
18     '''
19     Delete the first HTML tag of the string,
20     all tags starts with '<' and ends with '>'
```

```

21
22     PARAMETERS
23     -----
24     s : STRING
25         string to delete the first HTML tag
26
27     RETURNS
28     -----
29     str : string without the first HTML tag
30     None: if 's' no contains a HTML tag
31
32     EXAMPLES
33     -----
34     in["Hello<tag>world"]
35     out["Hello world"]
36
37     in["Hello <tag> again <tag2>"]
38     out["Hello  again <tag2>"]
39
40     in["Hello without HTML tags"]
41     out[None]
42     '''
43     startsTag = s.find('<'); endsTag = s.find('>')
44     if startsTag == -1 or endsTag == -1: return None
45     elif len(s) == endsTag: return s[:startsTag]
46     else: return s[:startsTag] + ' ' + s[endsTag+1:]
47
48 def deleteHTMLTags(s):
49     '''
50     Delete all HTML tags
51
52     PARAMETERS
53     -----
54     s : STRING
55         string to delete all HTML tags
56
57     RETURNS

```

```

58     -----
59     str : string without HTML tags
60
61     EXAMPLES
62     -----
63     in["Hello<tag>world"]
64     out["Hello world"]
65
66     in["Hello <tag> again <tag2>"]
67     out["Hello  again"]
68
69     in["Hello without HTML tags"]
70     out["Hello without HTML tags"]
71     '''
72     ok = True
73     while ok:
74         aux = deleteTag(s)
75         if aux is None: ok = False
76         else: s = aux
77
78     return s.strip()
79
80
81 def changeCodeToSpace(s):
82     '''
83     Change all HTML codes '&nbsp;' for a single
84     space ' ', if the string has no a code, do
85     nothing, i.e. returns the same string
86
87     PARAMETERS
88     -----
89     s : STRING
90         string to delete all HTML codes '&nbsp;'
91
92     RETURNS
93     -----
94     str : string without HTML codes '&nbsp;'

```

```

95
96     EXAMPLES
97     -----
98     in["Hello&nbsp;world"]
99     out["Hello world"]
100
101     in["Hello &nbsp; again &nbsp;"]
102     out["Hello  again"]
103
104     in["Hello without HTML codes"]
105     out["Hello without HTML codes"]
106     '''
107     spaceCode = '&nbsp;'
108     return s.replace(spaceCode, ' ').strip()
109
110
111 def findCode(s):
112     '''
113     Find and return the first code of manuscripts.
114     CODE Struct -> B#[A-Z]###
115
116     PARAMETERS
117     -----
118     s : STRING
119         string to find code
120
121     RETURNS
122     -----
123     str : string with the first code
124
125     EXAMPLES
126     -----
127     in["Hello B2C59 world"]
128     out["B2C59"]
129
130     in["Hello B5N100 again B8U31"]
131     out["B5N100"]

```

```

132
133     in["Hello without codes"]
134     out[""]
135     '''
136     startCode = 'B'
137     code = ''
138     s = s.find(startCode)
139
140     if s == -1: return code # If 'B' not exist
141     if s[s+1].isdigit(): # Verify B#
142         # Verify B#[A-Z]#
143         if s[s+2].isalpha() and s[s+3].isdigit():
144             code = s[s:s+4]
145             # Verify B#[A-Z]##
146             if len(s) > s+4 and s[s+4].isdigit():
147                 code = s[s:s+5]
148                 # Verify B#[A-Z]###
149                 if len(s) > s+5 and s[s+5].isdigit():
150                     code = s[s:s+6]
151     else:
152         code = findCode(s[s + 1:])
153
154     return code.strip()
155
156
157 def deleteDoubleSpace(s):
158     '''
159     Delete all double space from the string 's'
160     and put a single space
161
162     PARAMETERS
163     -----
164     s : STRING
165     string to delete all double space
166
167     RETURNS
168     -----

```

```

169     str : string without any double space
170
171     EXAMPLES
172     -----
173     in["Hello world"]
174     out["Hello world"]
175
176     in["Hello  again "]
177     out["Hello again"]
178
179     in["Hello without double space"]
180     out["Hello without double space"]
181     '''
182     while s.find('  ') != -1: s = s.replace('  ', ' ')
183     return s.strip()
184
185
186 def deleteNegativeSymbol(s):
187     '''
188     Find and remove all negative symbol
189     with or without a space
190
191     PARAMETERS
192     -----
193     s : STRING
194         string to delete all negative symbol
195         with or without a space
196
197     RETURNS
198     -----
199     str : string without any negative symbol
200
201     EXAMPLES
202     -----
203     in["Hello- world"]
204     out["Helloworld"]
205

```

```

206     in["Hello-again "]
207     out["Helloagain"]
208
209     in["Hello without negative symbol"]
210     out["Hello without negative symbol"]
211     '''
212     s = s.replace('- ', '').replace('-', '')
213     return s.replace('_', '').strip()
214
215
216 def extractTranscriptions(s, transcriptions=[]):
217     '''
218     Build a list of tuples with 2 items by tuple
219     from string 's', the first item is the code of
220     transcription and the second item is the
221     transcription
222
223     PARAMETERS
224     -----
225     s : STRING
226         string that contains the transcriptions
227         and its codes
228     transcriptions : LIST of TUPLES
229         have a tuple with two elements, the
230         first is the code, and the second
231         is the transcription
232
233     RETURNS
234     -----
235     l : a list that contains the transcriptions
236         with its codes
237
238     EXAMPLES
239     -----
240     in["asd B3C4 asdoaijfia"]
241     out[[('B3C4', 'asdoaijfia')]]
242

```

```

243     in["B3F5 asfsdf B2U3 sadsd"]
244     out[[('B3F5','asdsdf'), ('B2U3','safd')]]
245
246     in["String without a code"]
247     out[[]]
248     '''
249     code = findCode(s)
250
251     if code != '':
252         indexCode = s.find(code)
253         # new s without code
254         s = s[indexCode+len(code):].strip()
255         code2 = findCode(s)
256
257         if code2 != '':
258             indexCode2 = s.find(code2)
259             aux = s[:indexCode2]
260             transcriptions.append((code, aux.strip()))
261             # new s without previous msnuscript
262             s = s[indexCode2:]
263         else:
264             transcriptions.append((code, s.strip()))
265     else:
266         return transcriptions
267
268     return extractTranscriptions(s, transcriptions)
269
270
271 def loadExcel(path, sheetname='Culled Data'):
272     '''
273     Load a Excel file
274
275     PARAMETERS
276     -----
277     path: STRING
278         string with the Excel path to load
279     sheetname: STRING

```

```

280         the sheetname to load
281
282     RETURNS
283     -----
284     xl : DataFrame
285         A DataFrame that contains all
286         values from excel file
287     '''
288     xl = pd.ExcelFile(path).parse(sheetname=sheetname)
289     return pd.DataFrame(xl)
290
291
292 def loadCSV(path):
293     '''
294     Load a Excel file
295
296     PARAMETERS
297     -----
298     path: STRING
299         string with the Excel path to load
300     sheetname: STRING
301         the sheetname to load
302
303     RETURNS
304     -----
305     xl : DataFrame
306         A DataFrame that contains all
307         values from excel file
308     '''
309     cvs = pd.read_csv(path, encoding='utf-8')
310     return pd.DataFrame(cvs)
311
312
313 def saveCSV(df, path, name='Transcriptions.csv'):
314     '''
315     Create a CSV file with the transcriptions
316     and its codes

```

```

317
318     PARAMETERS
319     -----
320     df : DataFrame
321         contains the transcriptions with
322         its codes to save
323     path : STRING
324         the path where to save the file
325     name : STRING
326         the file name
327     '''
328     df.to_csv(path + name)
329
330
331 def createDataFrame(l, colCode='Codes',
332                    colTranscriptions='Transcriptions'):
333     '''
334     Create a DataFrame from a list of tuples
335     that contains the transcription with its
336     respective code
337
338     PARAMETERS
339     -----
340     l : LIST of TUPLES
341         contains the transcription with its
342         respective code
343     colCode : STRING
344         column name for codes
345     colTranscriptions : STRING
346         column name for transcriptions
347
348     RETURNS
349     -----
350     df : DataFrame
351         The respective DataFrame with
352         names and values by column
353     '''

```

```

354     columnCodes = []
355     columnTrans = []
356
357     for (cod, trans) in l:
358         columnCodes.append(cod)
359         columnTrans.append(trans)
360
361     df = pd.DataFrame()
362     df[colCode] = columnCodes
363     df[colTranscriptions] = columnTrans
364
365     return df
366
367
368 def deleteTabs(s):
369     '''
370     Delete all tabs from the string and
371     replaced by a single space
372
373     PARAMETERS
374     -----
375     s : STRING
376         the string to remove all tabs
377
378     RETURNS
379     -----
380     s : STRING
381         the string without any tab
382
383     EXAMPLES
384     -----
385     in['Hello\t\tWorld\t']
386     out['Hello World']
387
388     in['\tHello \t\t\tWorld']
389     out['Hello    world']
390

```

```

391     in['Hello again']
392     out['Hello again']
393     '''
394     return s.replace('\t', ' ')
395
396
397 def dataClean(s, e=[]):
398     '''
399     Clean the string, i.e. Remove HTML codes,
400     double space and negative symbols
401     and delete all elements indicates
402
403     PARAMETERS
404     -----
405     s : STRING
406         string without clean
407     e : LIST
408         list of elements to remove of the string
409
410     RETURNS
411     -----
412     s : STRING
413         a clean string
414
415     EXAMPLES
416     -----
417     in["Hola <asd> wo- rld"]
418     out["Hola world"]
419
420     in["Heloo&nbsp;my&nbsp;<ds>&nbsp; <sfe> world"]
421     out["Heloo my world"]
422
423     in["Hello again again"]
424     out["Hello again again"]
425     '''
426     for rmv in e: s = s.replace(rmv, ' ')
427

```

```

428     s = deleteTabs(s)
429     s = changeCodeToSpace(s)
430     s = deleteDoubleSpace(s)
431     s = deleteNegativeSymbol(s)
432     s = deleteHTMLTags(s)
433     if s.find(' ') != -1 : s = deleteDoubleSpace(s)
434
435     return s
436
437     #=====
438
439 def main():
440
441     pathLoad = input('Excel file : ')
442     sheetName = input('Sheet name : ')
443     colName = input('Column name to work : ')
444     pathSave = input('Path to save work files : ')
445     path2Del = input('Path to text file to remove elements: ')
446
447     if sheetName == '': xls = loadExcel(pathLoad)
448     else: xls = loadExcel(pathLoad, sheetName)
449
450     li = list(xls[colName])
451     t = []
452
453     listFailed = []
454
455     with open(path2Del, 'r') as f:
456
457         elements2del = f.readlines()
458
459         for s in li:
460             try:
461                 s = str(s).replace('"', '')
462                 s = ast.literal_eval('"' + s + '"')
463                 aux = extractTranscriptions(
464                     dataClean(s, elements2del))

```

```
465         t += [e for e in aux if e not in t]
466     except:
467         listFailed.append(s)
468
469     df = createDataFrame(t)
470     saveCSV(df, pathSave)
471
472     if len(listFailed) != 0:
473         saveCSV(pd.DataFrame(listFailed),
474                pathSave, 'Failed.csv')
475
476 main()
```

Apéndice C

Código Python para las correlaciones

El siguiente código escrito en **python 3** es el usado para la generación de todas las correlaciones existentes según el orden de entrada de los diccionarios

```
1  #!/usr/bin/env python3
2  # -*- coding: utf-8 -*-
3  """
4  Created on Sun Jan 09 21:02:37 2017
5
6  @author: Diana Maria del Pilar Socha Diaz
7           Juan Sebastian Martinez Serna
8  """
9  import pandas as pd
10 import matplotlib.pyplot as plt
11 import numpy as np
12
13 def loadExcel(path, sheetname='Transcriptions'):
14     '''
15     Load a Excel file
16     PARAMETERS
17     -----
18     path: STRING
19         string with the Excel path to load
20     sheetname: STRING
21         the sheetname to load
```

```

22     RETURNS
23     -----
24     xl : DataFrame
25         A DataFrame that contains all values from excel file
26     '''
27     xl = pd.ExcelFile(path).parse(sheetname=sheetname)
28     return pd.DataFrame(xl)
29
30 def saveCSV(df, path, name='cor.csv'):
31     '''
32     Create a CSV file with the cor
33
34     PARAMETERS
35     -----
36     df : DataFrame
37         contains the transcriptions with its codes to save
38     path : STRING
39         the path where to save the file
40     name : STRING
41         the file name
42     '''
43     df.to_csv(path + name)
44
45 def main():
46
47     pathLoad = input('Excel file : ')
48     sheetName = input('Sheet name : ')
49     dict1 = input('Dictionary 1 : ')
50     dict2 = input('Dictionary 2 : ')
51     colName = input('Column name : ')
52     pathSave = input('CSV to save : ')
53
54     trans = loadExcel(pathLoad, sheetName)
55
56     with open(dict1, 'r', encoding='latin-1') as d1:
57         with open(dict2, 'r', encoding='latin-1') as d2:
58             ld1 = d1.readlines()

```

```

59         ld2 = d2.readlines()
60
61         cor = {}
62
63         transVal = trans[colName]
64         for e in transVal.iteritems():
65             s = str(e[1])
66             for ed1 in ld1:
67                 if s.find(ed1) != -1:
68                     for ed2 in ld2:
69                         try:
70                             cor[ed1][ed2] += s.count(ed2)
71                         except:
72                             try:
73                                 cor[ed1][ed2] = 0
74                             except:
75                                 cor[ed1] = {ed2 : 0}
76
77         valores = []
78
79         for d1 in dict1:
80             row = []
81             for d2 in dict2:
82                 try: row.append(cor[d1][d2])
83                 except: True
84             valores.append(row)
85
86         df = pd.DataFrame(data=valores,
87                           columns=dict1, index=dict2)
88         saveCSV(df, pathSave)
89         print('OK')
90
91 main()

```

Siglas

D

DB Bases de datos (Databases). 25

E

ENHG Early New High German. 44

G

GIS Sistema de información geográfico (Geographic Information System). 20

I

IA Inteligencia artificial (Artificial Intelligence). 25

IE Extracción de información (Information Extraction). *Glosario:* Information Extraction

IE Information Extraction. *Glosario:* Information Extraction

IR Recuperación de información (Information Retrieval). 46, 48, *Glosario:* Search and Information Retrieval

K

KNIME Konstanz Information Miner. 57, *Glosario:* KNIME

M

MHG Middle High German. 44

MOOC Curso masivo abierto y en línea (Masive Open Online Course). 14, 17, 66

N

NHG New High German. 44

NLP Procesamiento de lenguaje natural (Natural Language Processing). *Glosario:* Natural Language Processing

NLP Natural Language Processing. *Glosario:* Natural Language Processing

O

OCR Optical Character Recognition. 47, 48, *Glosario:* OCR

OHG Old High German. 44

P

PoS Discurso de la palabra (Part of Speech). 26

R

RCCP Revealing Cooperation and Conflict Project. 6, 7, 12, 13, 16, 18, 20, 22

S

SQL Structured Query Language. 48

T

TEI Electronic Text Encoding and Interchange. 43, *Glosario:* Electronic Text Encoding and Interchange

U

UTF-8 8-bit Unicode Transformation Format. *Glosario:* UTF-8

X

XML Extensible Markup Language. 43, 58, *Glosario:* Extensible Markup Language

Glosario

A

Actas Capitulares de la Catedral de Plasencia Son los documentos donde eran almacenados todos los datos del día a día sobre las transacciones de los diferentes negocios que se realizaban, estos eran guardados por el *Cabildo de la Catedral de Plasencia*. Las actas están comprendidas en los años 1399 – 1527. 4, 7, 10, 11, 13–20, 22, 26, 66, 75–77, 92, 100, 104

C

Concept extraction Agrupación de palabras y frases en grupos semánticamente similares [11]. 24, 26

D

datos estructurados Son todos aquellos datos que se encuentran organizados y almacenados de tal manera que cumplen una estructura específica, es decir, son datos bien definidos, por ejemplo, las fechas, los números de teléfono, entre otros. 24

datos no estructurados Son todos aquellos datos que no se encuentran organizados de tal manera que no hagan uso de una estructura específica, por ejemplo, los nombres de las personas, documentos de texto, comentarios, entre otros. 24

diccionario de lugares Repertorio ordenado alfabéticamente con todos los lugares nombrados en los documentos. 23, 77

diccionario de nombres Repertorio ordenado por familias con todos los nombres de las personas encontradas en los documentos. 23, 77

diccionario de roles Repertorio ordenado por importancia, el más demandado, con todos los roles encontrados en los documentos, esto junto con los nombres de las personas que tenían dichos roles. 23, 77

Document classification Agrupación y clasificación de los documentos y/o fragmentos mediante el uso de algoritmos de clasificación de la minería de datos basados en modelos de pruebas . 24, 26

Document clustering Agrupación y categorización de documentos y/o fragmentos haciendo uso de diferentes algoritmos de clasificación por agrupamiento de la minería de datos . 24, 26

E

Electronic Text Encoding and Interchange Estandar internacional de facto que tiene como objetivo hacer más sencilla la representación en formato digital de textos y literatura cuando se trata de aquella con fines investigativos o para la educación en línea. TEI es lanzado por la Association for Computers and the Humanities en el año 1987. TEI P4 es la versión actual desarrollada para un correcto funcionamiento y soporte sobre lenguaje XML . 31

Extensible Markup Language Es un meta-lenguaje usado para la especificación de lenguajes de marcado, este permite definir etiquetas para la descripción de un conjunto de datos . 48, 49

I

Information Extraction Identificación y extracción de los diferentes hechos y relaciones encontradas dentro de los documentos de texto, el proceso consiste en generar datos estructurados a partir de los no estructurados . 24, 26

K

KNIME Plataforma de código abierto de fácil acceso orientada a posibilitar la Minería de Datos. Fuente de ayuda que dentro de sus principales funcionalidades permite encontrar información oculta en grandes volúmenes de datos además de hallar patrones de comportamiento de datos, hacer predicciones futuras y visualización . 5, 22, 37, 57, 58, 72

L

linaje Línea de descendientes o antepasados de una persona, muy importante para el continente Europeo debido a que en dicho contexto el linaje se refería además a la sucesión de propiedades, títulos, derechos, entre otros. Para la investigación, corresponde entonces también a la delegación de tareas o trabajos de una persona dentro de una sociedad, según fuera el de la línea de sus antepasados. 16

N

Natural Language Processing También conocido como lingüística computacional, es un campo del aprendizaje automatizado o aprendizaje de máquina con foco en las relaciones entre el lenguaje humano y el lenguaje de máquina . 24, 26

O

ontología En una ontología (informática) se definen formalmente relaciones, propiedades y tipos entre entidades que existen en un “corpus”. Se representa el conocimiento, se aplica sobre el mismo un método para representar formalmente los datos y finalmente se obtienen relaciones entre conceptos. Como principales objetivos está el limitar la complejidad y organizar información mas eficazmente . 32

S

Search and Information Retrieval Almacenamiento y recuperación de documentos de texto, proceso utilizado dentro de los motores de búsqueda, búsqueda de palabras claves. También es aplicado en los procesos de extracción de resúmenes de libros . 24, 26, 42, 43

U

UTF-8 Se entiende como un sistema de codificación de caracteres, la longitud de dicha codificación es variable. Es posible representar cualquier caracter Unicode siendo compatible con ASCII. UTF-8 hace uso de grupos de bytes para dicha compatibilidad pueda ser posible y aplicable en la mayoría de lenguajes del mundo . 43

W

Web mining Aplicación de las diferentes técnicas de minería de datos, minería de texto y análisis de texto en diferentes páginas de Internet . 24, 26

Bibliografía

- [1] Roger Louis Martínez-Dávila. Revealing cooperation and conflict. <http://revealingcooperationandconflict.com/the-project/>.
- [2] Dr. Roger Louis Martínez-Dávila. Explorando las humanidades digitales. http://www.rogerlouismartinez.com/?page_id=3133&lang=es.
- [3] Martin Baumeister y Bernardo Teuber. La obra de américo castro y la españa de las tres culturas. pages 82–95, 2010.
- [4] Roger Louis Martínez-Dávila. Historical background on medieval spain and plasencia. <http://revealingcooperationandconflict.com/historical-background-on-medieval-spain-and-plasencia/>.
- [5] Lucía Brage Martínez. ENTREVISTA AL DR. ROGER LOUIS MARTÍNEZ-DÁVILA. *ArtyHum, Revista de Artes y Humanidades*, pages 178–185, 2014.
- [6] Archivo Municipal de Plasencia. Serie 001 - libros de actas capitulares. <http://archivo.plasencia.es/index.php/libros-de-actas-capitulares>.
- [7] Roger Louis Martínez-Dávila. The cathedral of plasencia’s actas capitulares (the chapter acts). <http://revealingcooperationandconflict.com/about-the-actas-capitulares-the-chapter-acts/>.
- [8] The Deciphering Secrets website. Welcome to deciphering secrets. <http://decipheringsecrets.net/>.
- [9] Roger L. Martínez-Dávila. Ds: Unlocking the manuscripts of medieval spain. <https://www.decipheringsecrets.com/portfolio/ds-unlocking-the-manuscripts-of-medieval-spain/?lang=es>.

-
- [10] Ah-Hwee Tan et al. Text mining: The state of the art and the challenges. In *Proceedings of the PAKDD 1999 Workshop on Knowledge Discovery from Advanced Databases*, volume 8, pages 65–70, 1999.
- [11] Gary Miner, Dursun Delen, John Elder, Bob Nisbet, Thomas Hill, and Andrew Fast. *Practical text mining and statistical analysis for non-structured text data applications*. Academic Press, 2012.
- [12] University of New Brunswick. How google thinks. <http://media.lib.unb.ca/research/video/2Google@unb.pdf>, 2010.
- [13] Sašo Džeroski and Tomaž Erjavec. Learning to lemmatise slovene words. In *Cussens and S. Džeroski, Learning Language in Logic, Number 1925 in Lecture notes in artificial intelligence*, pages 69–88. Springer-Verlag, 2000.
- [14] Andrea Gesmundo and Tanja Samardžić. Lemmatisation as a tagging task.
- [15] Arianna Ciula, Paul Spence, and José Miguel Vieira. Expressing complex associations in medieval historical documents: the henry iii fine rolls project. In *Literary and Linguistic Computing*, volume 23, pages 311–325, 2008.
- [16] Fuminori Kimura, Takahiko Osaki, Taro Tezuka, and Akira Maeda. Visualization of relationships among historical persons from japanese historical documents. In *Literary and Linguistic Computing*, volume 28, pages 271–278, 2013.
- [17] The JUNG Framework Development Team. JUNG Java Universal Network/Graph Framework - Overview. <http://jung.sourceforge.net/>.
- [18] Andreas Hauser, Markus Heller, Elisabeth Leiss, Klaus U. Schulz, and Christiane Wanzeck. Information access to historical documents from the early new high german period, 2007.
- [19] PROEL. Lengua alemana. <http://www.proel.org/index.php?pagina=mundo/indoeuro/germanico/germanooc/aleman>.
- [20] Loes Braun, Floris Wiesman, and Ida Sprinkhuizen-Kuyper. Information retrieval from historical corpora, 2002.
- [21] Rada Mihalcea Tze-I Yang, Andrew J. Torget. Topic modeling on historical newspapers, 2011.
- [22] Andrew Kachites McCallum. Mallet: A machine learning for language toolkit, 2002. <http://mallet.cs.umass.edu>.

-
- [23] KNIME ORG. Knime analytics platform. <https://www.knime.org/knime-analytics-platform>.
- [24] RapidMiner. Rapidminer, open sourcez data science platform. <https://rapidminer.com/products>.
- [25] David Norris. Rapidminer - a potential game changer. <http://www.bloorresearch.com/analysis/rapidminer-a-potential-game-changer>, 2013.
- [26] The R Foundation. What is r? <https://www.r-project.org/about.html>.
- [27] The University of Waikato. Weka 3: Data mining software in java. <http://www.cs.waikato.ac.nz/ml/weka/index.html>.
- [28] Ching man Au Yeung. Studying how the past is remembered: Towards computational history through large scale text mining. In *In Proc. CIKM*, pages 1231–1240, 2011.
- [29] Daniel McDonald. A text mining analysis of religious texts. In *The Journal of Business Inquiry*, volume 13, pages 27–47, 2014.
- [30] Microsoft Developer Network. Conceptos de minería de datos. [https://msdn.microsoft.com/es-es/library/ms174949\(v=sql.120\).aspx](https://msdn.microsoft.com/es-es/library/ms174949(v=sql.120).aspx).
- [31] Un Yong Nahm. Text mining with information extraction. In *AAAI 2002 Spring Symposium on Mining Answers from Texts and Knowledge Bases*, pages 5–6, 60–67, 2002.
- [32] Ricardo Baeza-Yates and Berthier Ribeiro-Neto. *Modern Information Retrieval*. ACM press, 1999.
- [33] Barry de Ville. *Integrated Bussines Intelligence for e-Comerce and Knowledge Management*. Digital Press, 2001.
- [34] Universidad Carlos III de Madrid. EXPERIENCED FELLOW - Roger Louis Martínez-Dávila. <http://www.uc3m.es/ss/Satellite/UC3MInstitucional/es/FormularioTextoDosColumnas/1371215847808/>.
- [35] Inc. RStudio. Rstudio ide features. <https://www.rstudio.com/products/rstudio/features/>.
- [36] The Text Encoding Initiative Consortium. Tei: Text encoding initiative. <http://www.tei-c.org/index.xml>.

-
- [37] J. Tomás Nogales Flores. Tei: Text encoding initiative. <http://www.bib.uc3m.es/nogales/cursos/tei.html>.
- [38] Margaret Rouse. Xml (extensible markup language). <http://searchsoa.techtarget.com/definition/XML>.
- [39] Asunción Gómez-Pérez PhD, MSc, MBA; Mariano Fernández-López PhD, MSc; Oscar Corcho MSc. *Ontological Engineering with examples from the areas of Knowledge Management, e-Commerce and the Semantic Web*. Springer, first edition, 2004.
- [40] Inc. Unicode. General questions, relating to utf or encoding form - what is the definition of utf-8? http://unicode.org/faq/utf_bom.html#utf8-1.
- [41] Moodle. Utf-8. <https://docs.moodle.org/all/es/UTF-8>.
- [42] BIBLIOTECA DIGITAL GREENSTONE. Biblioteca digital greenstone del papel a la colección: Chapter 3 ocr: reconocimiento óptico de caracteres. http://www.greenstone.org/manuals/gsd12/es/html/Chapter_ocr.htm.