



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Departamento:

Departamento de Ingeniería e Investigaciones Tecnológicas

Programa de acreditación:

PROINCE

Programa de Investigación¹:

Código del Proyecto:

C241

Título del proyecto

Implementación de un Sistema Web de Recuperación de la Información Orientado a Documentación Jurídica con el Proceso de Indexación Semántica Latente Paralelizado

PIDC:

Elija un elemento.

PII:

Elija un elemento.

Director:

SPOSITTO, Osvaldo Mario

Codirector:

RYCKEBOER, Hugo

Integrantes:

LEDESMA, Viviana

BOSSERO, Julio César

GARGANO, Cecilia

MATTEO, Lorena

MORENO, Edgardo

PROCOPIO, Gastón

SAIZAR, Victoria

MACIAS, Patricio

CONTI, Laura

Asesor- Especialista:

GARCÍA, Sergio

PEREZ VILLAR, Gustavo

Alumnos de grado: (Aclarar si tiene Beca UNLaM/CIN)

OJEDA, Juan

QUINTANA, Fabio

Resolución Rectoral de acreditación: N°

445/21

Fecha de inicio:

01/01/2021

Fecha de finalización:

31/12/2022

¹ Los Programas de Investigación de la UNLaM están acreditados con resolución rectoral, según lo indica la Resolución HCS N° 014/15 sobre Lineamientos generales para el establecimiento, desarrollo y gestión de Programas de Investigación a desarrollarse en la Universidad Nacional de La Matanza. Consultar en el departamento académico correspondiente la inscripción del proyecto en un Programa acreditado.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

A. Desarrollo del proyecto (adjuntar el protocolo)

A.1. Grado de ejecución de los objetivos inicialmente planteados, modificaciones o ampliaciones u obstáculos encontrados para su realización (desarrolle en no más de dos (2) páginas)

Los objetivos planteados para el proyecto de investigación fueron los siguientes:

- Desarrollar e implementar un front-end Web del SRI basado en el prototipo desarrollado previamente por el propio equipo en el proyecto C151.
- Paralelizar el proceso Indexación Semántica Latente (ISL) implementando una arquitectura híbrida (CPU-GPU).
- Construir un corpus de documentos jurídicos.
- Evaluar el tiempo de respuesta y la pertinencia de los documentos recuperados.

Durante la primera etapa del proyecto se llevaron adelante una serie de subtarear de investigación que sirven de apoyo a las tareas planificadas de armado del corpus y de análisis del resultado del proceso de lematización. Si bien en dichas etapas es necesaria la intervención manual por parte de los expertos, se buscó unificar términos similares en los documentos jurídicos a fin de reducir la dimensionalidad (cantidad de términos) del corpus, simplificando así las tareas manuales de revisión por parte de los usuarios. Para ello se aplicaron diversas técnicas automáticas, como ser aplicación de Expresiones Regulares (ER), distancia de Hamming y de Levenshtein (para encontrar similitud de términos), funciones de deduplicación y limpieza de datos, entre otras.

Respecto al proceso de ISL, se profundizó en la utilización de ER para búsqueda y reemplazo de cadenas de textos dentro de textos más extensos. Una ER es una secuencia de caracteres que define un patrón de búsqueda sobre un texto. Así también se revisaron trabajos respecto a la utilización del reconocimiento de Entidades Nombradas (EN), para ser empleadas juntamente con las ER. Se trabajó en una propuesta orientada a la incorporación de datos en formato fecha y de dichas EN (Leyes, Acordadas, Decretos, Artículos, etc.), utilizando la librería para ER que trae C# (REGEX). Todo esto de cara a la especialización del Sistema de Recuperación de Información para un contexto jurídico.

Con relación a lo anterior, esta parte del trabajo ha quedado parcialmente volcado en un artículo que se redactó cuyo título es *“Propuesta para la construcción de un Corpus Jurídico utilizando Expresiones Regulares”*, que fue aceptado para su publicación en el congreso CACIC 2021. Este tema resultó de mucho interés y fue seleccionado para su inclusión en un capítulo del libro *“Computer Science – CACIC 2021”* de la serie *Communications in Computer and Information Science* (CCIS) de la editorial Springer. El mismo, titulado *“Lexical Analysis Using Regular Expressions for Information Retrieval from a Legal Corpus”*, fué publicado en 2022.

En esta misma línea, con el fin de reducir ese costo de intervención manual y, para mejorar la performance en la búsqueda exhaustiva de patrones realizada inicialmente mediante el uso de ER, se buscó aplicar técnicas complementarias que podrían ayudar a reducir la dimensionalidad. Para ello se realizó un estudio para la búsqueda del mejor umbral de coincidencia que surge de aplicar medidas de similitud léxica a los términos resultantes del proceso de indización y organización del corpus. Aunque este procedimiento no exime de la necesidad de contar con el experto humano, puede ser



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

de gran ayuda para minimizar el esfuerzo implicado en su trabajo, debido a que permite acotar el volumen de términos en los que debe centrarse para elegir aquel que mejor represente a la EN. Los principales resultados de este estudio se reflejan en el artículo *“Determinación del umbral inferior de coincidencia aplicando medidas de edición a términos jurídicos”*, publicado a la revista REDDI, en diciembre de 2022.

Por otra parte, ampliando lo planificado inicialmente se transcribió la lógica del algoritmo de Snowball utilizado en el proyecto anterior (2014) del lenguaje C# a C para mayor portabilidad. Se construyeron varias funciones de String no previstas por el lenguaje C, como la obtención de cadenas de caracteres y la conversión de acentos en vocales. Se prepararon dos lotes de prueba con 27.266 y 1.113.014 términos respectivamente. A estos lotes, se los pasó por el proceso de Lematización que ofrece el sitio de <https://snowballstem.org/>. Sumado a esto, se corrigieron lemas en los tiempos verbales. Para ello fue necesario modificar el algoritmo de Snowball, de este modo, una vez que el proceso obtiene el lema, este es buscado en un lote de verbos almacenados, de encontrarse, es reemplazado por el lema correcto. Resultados iniciales de las pruebas realizadas durante esta actividad fueron publicadas en el trabajo *“Implementación de un lematizador para la lengua española”* presentado en CONAISI 2021. Se terminó de lematizar el segundo lote de palabras, este se está incorporando al programa para realizar distintas modificaciones en el orden que se ejecutan los pasos. Adicionalmente, se realizó un estudio preliminar, en el que se investigó la localización de documentos en espacios métricos utilizando el algoritmo K-means. Se realizaron experimentos con distintas configuraciones de dimensionalidad y normas de distancia. Una ampliación de esta actividad se ha publicado en el artículo *“Resultados preliminares de una técnica de localización de documentos en espacios métricos utilizando K-means”*, presentado en el congreso CONAISI 2022.

Con respecto al armado del corpus documental jurídico, se gestionó las correspondientes autorizaciones y la Suprema Corte de Justicia de la Provincia de Buenos Aires, proveyó un archivo de 23 Gigabyte que incluía más de 300 mil documentos del fuero civil y comercial, separados por distintas “etiquetas”. Para procesar este archivo, se desarrolló un programa en C# que permite segmentar y armar a los documentos que conformarán el corpus jurídico.

Además, se desarrolló el SRI web que incluye configurar la carpeta donde se encuentran los archivos a indexar. Una vez configurada, se inicia el proceso de indexación, cuya duración depende del tamaño del corpus. Luego, relacionado a las búsquedas, se ingresan las palabras clave a buscar, el sistema utiliza la última indexación realizada para encontrar los documentos que coincidan con las mismas. El sistema devuelve los resultados en un listado y ofrece la posibilidad de verlos o descargarlos.

En términos de implementación, se utilizó un algoritmo de paralelización para una arquitectura híbrida CPU-GPU. Sin embargo, debido a retrasos en la entrega de la documentación necesaria para construir el corpus por parte de la Corte Suprema, no se pudieron realizar pruebas exhaustivas para evaluar la eficiencia, el tiempo de respuesta y la relevancia de los documentos recuperados. Como resultado, no se cumplió el objetivo e) establecido inicialmente durante el período de vigencia del proyecto, no obstante ello estas pruebas se realizarán en el segundo semestre del año en curso y los resultados serán presentados en la WICC o CACIC 2024.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

B. Principales resultados de la investigación

B.1. Publicaciones en revistas (informar cada producción por separado)

Artículo 1:	
Autores	<i>Matteo, Lorena; Ledesma Viviana; Sposito Osvaldo</i>
Título del artículo	<i>Determinación del umbral inferior de coincidencia aplicando medidas de edición a términos jurídicos</i>
N° de fascículo	2
N° de Volumen	7
Revista	<i>REDDI</i>
Año	2022
Institución editora de la revista	<i>ULaM - DIIT</i>
País de procedencia de institución editora	<i>Argentina</i>
Arbitraje	SI
ISSN:	2525-1333
URL de descarga del artículo	https://reddi.unlam.edu.ar/index.php/ReDDi/article/view/188
N° DOI	https://doi.org/10.54789/reddi.7.2.4

B.2. Libros

Libro 1	
Autores	
Título del Libro	
Año	
Editorial	
Lugar de impresión	
Arbitraje	Elija un elemento.
ISBN:	
URL de descarga del libro	
N° DOI	



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

B.3. Capítulos de libros

B.3.1	
Autores	Spositto, Osvaldo; Bossero, Julio; Moreno, Edgardo; Ledesma, Viviana; Matteo, Lorena
Título del Capítulo	<i>Lexical Analysis Using Regular Expressions for Information Retrieval from a Legal Corpus</i>
Título del Libro	Computer Science-CACIC 2021 Publicado en Springer Nature Switzerland
Año	2022
Editores del libro/Compiladores	P. Pesado and G. Gil (Eds.): CACIC 2021
Lugar de impresión	<i>Suiza</i>
Arbitraje	SI
ISBN:	978-3-031-05902-5
URL de descarga del capítulo	https://link.springer.com/chapter/10.1007/978-3-031-05903-2_21
N° DOI	

B.4. Trabajos presentados a congresos y/o seminarios

B.4.1	
Autores	Spositto, Osvaldo; Ryckeboer, Hugo; Ledesma, Viviana; Procopio, Gastón; Matteo, Lorena; Gargano, Cecilia; Bossero, Julio; Moreno, Edgardo; Saizar, Victoria; Macias, Patricio; Ojeda, Juan; Quintana, Fabio; Conti, Laura; García, Sergio; Pérez Villar, Gustavo
Título	<i>Propuesta para la construcción de un Corpus Jurídico utilizando Expresiones Regulares</i>
Año	2021
Evento	XXVII Congreso Argentino de Ciencias de la Computación (CACIC 2021)
Lugar de realización	Virtual
Fecha de presentación de la ponencia	4 al 8 de octubre de 2021
Entidad que organiza	Facultad de Ciencias Exactas de la Universidad Nacional de Salta
URL de descarga del trabajo (especificar solo si es la descarga del trabajo; formatos pdf, e-pub, etc.)	https://cacic2021.unsa.edu.ar/wp-content/uploads/2021/11/LIBRO-DE-ACTAS-CACIC-2021-SALTA.pdf



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

B.4.2	
Autores	Bossero, Julio, Sposito, Osvaldo; Ledesma, Viviana Ryckeboer, Hugo; Conti, Laura; García, Sergio; Moreno, Edgardo; Matteo, Lorena; Saizar, Victoria; Macias, Patricio; Quintana, Fabio; Perez Villar, Gustavo; Gargano, Cecilia; Procopio, Gaston
Título	<i>Implementación de un lematizador para la lengua española</i>
Año	2021
Evento	9º Congreso Nacional de Ingeniería Informática / Sistemas de Información (CoNaIISI 2021)
Lugar de realización	Virtual
Fecha de presentación de la ponencia	05 de noviembre de 2021
Entidad que organiza	Universidad Tecnológica Nacional Facultad Regional Mendoza
URL de descarga del trabajo (especificar solo si es la descarga del trabajo; formatos pdf, e-pub, etc.)	https://www4.frm.utn.edu.ar/conaiisi/

B.4.3	
Autores	Sposito, Osvaldo; Ryckeboer, Hugo; Bossero, Julio; Moreno, Edgardo; Ledesma, Viviana; Procopio, Gastón; Matteo, Lorena; Gargano, Cecilia; Saizar, Victoria; Macias, Patricio; Quintana, Fabio; Ojeda, Juan; Conti, Laura; García, Sergio; Pérez Villar, Gustavo
Título	<i>Adecuación de un sistema de recuperación de información para su utilización en un contexto jurídico</i>
Año	2022
Evento	XXIV Workshop de Investigadores en Ciencias de la Computación (WICC 2022)
Lugar de realización	Virtual
Fecha de presentación de la ponencia	abril de 2022
Entidad que organiza	Universidad Champagnat. Mendoza
URL de descarga del trabajo (especificar solo si es la descarga del trabajo; formatos pdf, e-pub, etc.)	http://sedici.unlp.edu.ar/handle/10915/144389



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

B.4.4	
Autores	Sposito, Osvaldo; Ryckeboer, Hugo; Bossero, Julio; Moreno, Edgardo; Ledesma, Viviana; Procopio, Gastón; Matteo, Lorena; Gargano, Cecilia; Saizar, Victoria; Macias, Patricio; Quintana, Fabio; Ojeda, Juan; Conti, Laura; García, Sergio; Pérez Villar, Gustavo
Título	<i>Resultados preliminares de una técnica de localización de documentos en espacios métricos utilizando K-means.</i>
Año	2022
Evento	10º Congreso Nacional de Ingeniería Informática / Sistemas de Información (CoNaISI 2022)
Lugar de realización	Facultad Regional Concepción del Uruguay de la Universidad Tecnológica Nacional, Entre Ríos.
Fecha de presentación de la ponencia	noviembre de 2022
Entidad que organiza	Red de Carreras de Ingeniería Informática / Sistemas de Información -RIISIC- perteneciente al CONFEDI
URL de descarga del trabajo (especificar solo si es la descarga del trabajo; formatos pdf, e-pub, etc.)	https://rtyc.utn.edu.ar/index.php/ajea/article/view/1146/1059

B.5. Otras publicaciones

Autores	
Año	
Título	
Medio de Publicación	

C. Otros resultados. Indicar aquellos resultados pasibles de ser protegidos a través de instrumentos de propiedad intelectual, como patentes, derechos de autor, derechos de obtentor, etc. y desarrollos que no pueden ser protegidos por instrumentos de propiedad intelectual, como las tecnologías organizacionales y otros. Complete un cuadro por cada uno de estos dos tipos de productos.

C.1. Títulos de propiedad intelectual. Indicar: Tipo (marcas, patentes, modelos y diseños, la transferencia tecnológica) de desarrollo o producto, Titular, Fecha de solicitud, Fecha de otorgamiento

Tipo	Titular	Fecha de Solicitud	Fecha de Emisión



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

C.2. Otros desarrollos no pasibles de ser protegidos por títulos de propiedad intelectual. Indicar: Producto y Descripción.

Producto	Descripción

D. Formación de recursos humanos. Trabajos finales de graduación, tesis de grado y posgrado. Completar un cuadro por cada uno de los trabajos generados en el marco del proyecto.

D.1. Tesis de grado

Director (apellido y nombre)	y	Autor (apellido y nombre)	Institución	Calificación	Fecha /En curso	Título de la tesis

D.2 Trabajo Final de Especialización

Director (apellido y nombre)	y	Autor (apellido y nombre)	Institución	Calificación	Fecha /En curso	Título del Trabajo Final

D.2. Tesis de posgrado: Maestría

Director (apellido y nombre)	y	Tesista (apellido y nombre)	Institución	Calificación	Fecha /En curso	Título de la tesis
Bossero Julio		Casuccelli Mauro	UNLaM		En curso	Estudio comparativo de DBSCAN, KMEANS con redes neuronales en un Sistema de Recuperación de Información

D.3. Tesis de posgrado: Doctorado

Director (apellido y nombre)	y	Tesista (apellido y nombre)	Institución	Calificación	Fecha /En curso	Título de la tesis
Palma María	Luis	Conti Laura	UNLaM		En curso	Implementación de la Inteligencia Artificial y su Regulación en los Procesos de Gestión en la Ejecución Penal en la Provincia de Buenos Aires



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

D.4. Trabajos de Posdoctorado

Director (apellido y nombre)	Posdoctorando (apellido y nombre)	Institución	Calificación	Fecha /En curso	Título del trabajo	Publicación

E. Otros recursos humanos en formación: estudiantes/ investigadores (grado/posgrado/ posdoctorado)

Apellido y nombre del Recurso Humano	Tipo	Institución	Período (desde/hasta)	Actividad asignada ²
CONTI, Laura	Estudiante de Doctorado	UNLaM	1/1/2021 – 31/12/2022	- Colaboración en el armado del corpus documental. - Pruebas del SRI
GARCÍA, Sergio	Estudiante de Doctorado	UNLaM	1/1/2021 – 31/12/2022	- Colaboración en el armado del corpus documental. - Pruebas del SRI
QUINTANA, Fabio	Estudiante de Grado	UNLaM	1/1/2021 – 31/12/2022	- Implementación de la paralelización de la ISL - Desarrollo de SRI web
OJEDA Juan	Estudiante de Grado	UNLaM	1/1/2021 – 31/12/2022	- Implementación de la paralelización de la ISL - Desarrollo de SRI web

F. Vinculación³: Indicar conformación de redes, intercambio científico, etc. con otros grupos de investigación; con el ámbito productivo o con entidades públicas. Desarrolle en no más de dos (2) páginas.

- Este proyecto de investigación se conforma por un equipo de trabajo multidisciplinario. Como se mencionó previamente, se ha trabajado en colaboración con responsables del Juzgado de Ejecución Penal Nro. 2 de Morón, a cargo de la Dra. Laura Conti. Así también, se cuenta con la participación del Prosecretario de la Subsecretaría de Tecnología Informática de la Suprema Corte de Justicia de Bs. As. Ambos, por su parte, aportarán los documentos pertinentes para el armado del corpus jurídico que servirá de base para las pruebas del SRI. Se espera que los resultados de esta investigación sean de

² Descripción de la/s actividad/es a cargo (máximo 30 palabras)

³ Entendemos por acciones de “vinculación” aquellas que tienen por objetivo dar respuesta a problemas, generando la creación de productos o servicios innovadores y confeccionados “a medida” de sus contrapartes.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

interés y puedan ser utilizados en futuros desarrollos para la Suprema Corte de Justicia de la Provincia de Buenos Aires.

- Se estableció contacto y se realizaron reuniones de intercambio con un equipo de investigadores de la Facultad de Ciencias Jurídicas de la Universidad Nacional de la Plata. El equipo sigue una línea de investigación sobre Derecho y Tecnología llamado GECSI (Grupo de Estudios de la Complejidad en la Sociedad de la Información). La lectura de distintos artículos que hemos publicado despertó el interés de GECSI en este proyecto, no solo para un intercambio recíproco de conocimientos, sino también pensando en organizar y llevar adelante a futuro algunas actividades académicas conjuntas, lo cual puede resultar sumamente enriquecedor para ambos equipos.
- El 11 de octubre de 2022 se llevó adelante una reunión de intercambio con el Ministerio de Justicia de Perú. Los participantes por parte de nuestro equipo de investigación fueron: Osvaldo Sposito, Viviana Ledesma, Laura Conti y Gustavo Pérez Villar. Por la otra parte, el Juez Supremo, Magistrado Héctor Lama More, quien lidera el Centro de Investigaciones del Poder Judicial de Perú junto a algunos de sus colaboradores, entre ellos, el Gerente de Informática del ministerio. Fue una reunión muy productiva, se dieron a conocer los avances que se están realizando en Perú con relación a la incorporación de nuevas tecnologías en los procesos judiciales y algunos obstáculos con los que se han encontrado. Por nuestra parte, se explicó el estado de situación de la justicia digital, en especial en la Provincia de Buenos Aires, además se comentaron las líneas de investigación en las que está trabajando el equipo, los avances alcanzados en el proyecto Experticia y los beneficios potenciales que se esperan a partir de su implementación. El Magistrado manifestó su interés en avanzar con este tipo de intercambios y conocer más de nuestro trabajo de cara a evaluar la posibilidad de su aplicación en la justicia de Perú.
- Se estableció contacto con el Laboratorio de Inteligencia Artificial para la Fiscalía de Estado (FEPBA IALab) de la Provincia de Buenos Aires, el 20 de abril de 2023 fuimos convocados a una reunión de intercambio de experiencias. Participaron de la reunión, por parte de la fiscalía, Mariano Cervellini y Miguel Carbone y, de nuestro equipo, Osvaldo Sposito y Viviana Ledesma. En su caso, ellos están trabajando en el desarrollo de Velox, un prototipo para la gestión interna de la fiscalía, comentaron las técnicas de IA y de recuperación de información que están aplicando. Mostraron interés en colaborar con nuestro equipo de investigación debido a las publicaciones relacionadas con el SRI y la Experticia que han estado siguiendo. Siendo que se trata de un laboratorio recientemente creado en la Fiscalía de Estado les gustaría contar para sus proyectos con nuestra experiencia y colaboración. Las líneas de comunicación han quedado abiertas para avanzar en esta relación de colaboración recíproca a futuro.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

G. Otra información. Incluir toda otra información que se considere pertinente.

Actividades de Difusión en Eventos Científicos:

- Presentación Video: Ledesma y Bossero. Título de Artículo: *“Propuesta para la construcción de un Corpus Jurídico utilizando Expresiones Regulares”*. Evento: XXVII Congreso Argentino de Ciencias de la Computación (CACIC 2021). Organizado por: Facultad de Ciencias Exactas de la Universidad Nacional de Salta. Fecha: octubre de 2021.
- Expositor: Bossero. Título de Artículo *“Implementación de un lematizador para la lengua española”*. Evento: CONAISI 2021, 9º Congreso Nacional de Ingeniería Informática / Sistemas de Información. Organizado por: Universidad Tecnológica Nacional Facultad Regional Mendoza. Fecha: noviembre de 2021.
- Expositor: Bossero. Título del trabajo presentado: *Implementación de un lematizador para la lengua española*. Evento: CONAISI 2022. Organizado Facultad Regional Concepción del Uruguay de la UTN. Fecha: noviembre de 2022.
- Presentación Video: Ledesma y Bossero participaron del XXIV Workshop de Investigadores en Ciencias de la Computación – WICC 2022 – con el artículo *“Adecuación de un Sistema de Recuperación de Información para su Utilización en un Contexto Jurídico”* y su correspondiente video y poster. Organizado por la Universidad Champagnat. Fecha: abril de 2022.
- Ledesma, Procopio y Pérez Villar participaron como panelistas en las 51 JAIIO Jornadas Argentinas de Informática. Conferencia de cierre del SID - Simposio Argentino de Informática y Derecho. Título de la conferencia: *“EXPERTICIA y la necesidad de adaptar la gestión judicial a la evolución tecnológica”*. Organizado por la Sociedad Argentina de Informática (SADIO). Fecha: octubre de 2022.
- Expositor: Pérez Villar. Título de la conferencia: *Innovación y mejora del servicio público de justicia en Argentina*. Evento: III Congreso Internacional Expediente Judicial Electrónico del Poder Judicial del Perú. Organizado por la Comisión de Trabajo del Expediente Judicial Electrónico (EJE). Fecha: diciembre 2022.

Otras Actividades de Difusión:

- Parte de los resultados de esta investigación son difundidos en el curso de posgrado *“Capacitación en Técnicas de Litigación Digital y Oral para el Fuero Penal”*. El mismo es organizado por el Colegio de Abogados del Departamento Judicial Morón, tiene una duración de 10 semanas. Modalidad: Virtual. Laura Conti y Sergio García participan como docentes.
- Conti participó como disertante en la Jornada de actualización: *La gestión judicial: Nuevos Desafíos*. Organizada por FUNDEJUS (Fundación de Estudios para la Justicia) y la Asociación de Magistrados y Funcionarios del Departamento Judicial de Morón. Fecha: noviembre de 2022.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

- Pérez Villar y Conti fueron disertantes en el evento: *Aspectos prácticos, tecnológicos y normativos del expediente judicial digital de la Provincia de Buenos Aires. Sistemas de gestión en uso. Notificaciones, presentaciones y oficios electrónicos*. Organizada por la Comisión de Derecho Procesal Digital CAM y la Asociación de Magistrados/as y Funcionarios/as de Morón. Fecha: noviembre de 2022.

Formación de Recursos Humanos:

- El alumno Fabio Quintana, finalizó su carrera de Ingeniería en Informática con la aprobación del proyecto final de carrera referido a un sistema para supervisión en tiempo real de la actividad física fin de evitar lesiones por malos movimientos o posturales, recibiendo el título correspondiente en marzo de 2022.
- Los integrantes del proyecto han realizado los siguientes cursos o asistido a jornadas de capacitación durante el transcurso del proyecto:

Ledesma:

- Panel: “Nueva normalidad: ¿Tu equipo legal tiene lo que necesita para ser exitoso?”. Modalidad virtual. Organizado por la empresa Thomson Reuters. Duración: 2 hs. Fecha: 7 de julio de 2021.
- Jornada sobre Procesamiento del Lenguaje Natural: “Algoritmos que entienden el lenguaje: Aspectos computacionales y aplicaciones sociales”. Modalidad virtual. Organizado por el Departamento de Ciencias Básicas de la Universidad Nacional de Luján. Duración: 3 hs. Fecha: 17 de agosto de 2021.
- Curso: “Introducción a UX”. Organizado por: Education IT. Duración: 12 hs. Fecha de finalización: octubre de 2021.
- Curso: “UI: Interfaz de Usuario”. Organizado por: Education IT. Duración: 30 hs. Fecha de finalización: noviembre de 2021.
- Jornada: 51 JAIIO. SID 2022 - Simposio Argentino de Informática y Derecho. Organizada por SADIO. Fecha 17 al 27 de octubre 2022.

Bossero:

- Jornada sobre Procesamiento del Lenguaje Natural: “Algoritmos que entienden el lenguaje: Aspectos computacionales y aplicaciones sociales”. Modalidad virtual. Organizado por el Departamento de Ciencias Básicas de la Universidad Nacional de Luján. Duración: 3 hs. Fecha: 17 de agosto de 2021.
- Congreso. CACIC 2021. Organizado por Universidad Nacional de Salta. Fecha: 4 al 8 de octubre de 2021.
- Congreso. CONAISI 2021. Organizado por Universidad Tecnológica Nacional Facultad Regional Mendoza. Fecha: 4 y 5 de noviembre de 2021.
- Workshop: WICC 2022. Organizado por Universidad de Champagnat, Mendoza. Fecha: abril 2022.
- Congreso. CACIC 2022. Organizado por Universidad Nacional de La Rioja. Fecha: 3 al 6 de octubre de 2022.
- Congreso. CONAISI 2022. Organizado por Facultad Regional Concepción del Uruguay de la Universidad Tecnológica Nacional. Fecha: 4 de noviembre de 2022.
- Curso: “Responsive Web Design & Bootstrap”. Organizado por: Education IT. Duración: 12 hs. Fecha de finalización: julio de 2022.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Quintana:

- Curso- “Competencias y Desarrollo del Talentos en la Nube para la Comunidad UNLaM”. Organizado por UNLaM. Duración: 30 hs. Fecha de finalización: febrero 2021.
- Curso- “Developing MVC 5 Web Applications”. Organizado por Education IT. Duración: XX Fecha de finalización: marzo de 2021.
- Curso- “Vue JS. Organizado por Education IT”. Duración: 15 hs. Fecha de finalización: diciembre de 2021.
- Curso- “Node. JS y Mongo DB”. Organizado por Education IT. Duración: 18 hs. Fecha de finalización: enero de 2022.

Matteo:

- Webinar- “Phyton”. Organizado por: Education IT. Duración: 2 hs. Fecha: 29 de marzo de 2021.
- Curso- “Formación en Oratoria”. Organizado por UNLaM, Escuela de Posgrado. Duración: 24 hs. Fecha de finalización: abril 2021.
- Webinar- “Herramientas de evaluación en plataforma MleL”. Organizado por UNLaM. Duración: 1 hora.
- Taller- “Buenas prácticas docentes en espacios virtuales de enseñanza”. Organizado por UNLaM, Dirección de Pedagogía Universitaria. Duración: 2 hs. Fecha: 24 de junio de 2021.
- Jornada- “Actualización en Desarrollo Sostenible para Emprendedores”. Organizado por UNLaM, Secretaría de Investigaciones del DIIT. Duración: 3 hs. Fecha: 8 de julio de 2021.
- Taller- “Sentidos y sentires de las tutorías en la virtualidad”. Organizado por UNLaM, Dirección de Pedagogía Universitaria. Duración: 3 hs. Fecha: 29 de septiembre de 2021.
- Simposio- “Aulas híbridas y bimodalidad en la Educación Superior”. Organizado por UNLaM, Dirección de Pedagogía Universitaria. Duración: 2 hs. Fecha: 28 de octubre de 2021.
- Congreso. CACIC 2021. Organizado por Universidad Nacional de Salta. Fecha: 4 al 8 de octubre de 2021.
- Taller- “Estrategias de búsqueda y recuperación de información científica en bases de datos”. Organizado por UNLaM, Biblioteca, Leopoldo Marechal. Duración: 3 hs. Fecha: 12 de noviembre de 2021.
- Curso de Capacitación: “Buenas prácticas de consumo y producción de la información científica y académica”. Organizado por: Biblioteca Leopoldo Marechal de la UNLaM. Duración: 2 encuentros. Fecha: noviembre 2022.

Moreno:

- Jornada sobre Procesamiento del Lenguaje Natural: “Algoritmos que entienden el lenguaje: Aspectos computacionales y aplicaciones sociales”. Modalidad virtual. Organizado por el Departamento de Ciencias Básicas de la Universidad Nacional de Luján. Duración: 3 hs. Fecha: 17 de agosto de 2021.
- Curso: “Programación .NET con C# .NET”. Organizado por: Education IT. Duración: 40 hs. Fecha de finalización: mayo de 2022.

Gargano:

- Curso- “Phyton Programming”. Organizado por: Education IT. Duración: 18 hs. Fecha de finalización: noviembre de 2021.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

- Curso- “Phyton para Análisis de Datos”. Organizado por: Education IT. Duración: 18 hs. Fecha de finalización: febrero de 2022.

Saizar:

- Curso: “ReactJS Developer”. Organizado por: Education IT. Duración: 36 hs. Fecha de finalización: julio de 2022.
- Curso: “Web API. Net Core”. Organizado por: Education IT. Duración: 21 hs. Fecha de finalización: julio de 2022.

Conti:

- Curso AI0101SP: Inteligencia Artificial para todos: Domina los fundamentos. Organizado por IBM mediante edX. Duración 8 hs. Fecha de finalización: febrero de 2022.
- Curso Superior en Derecho. Inteligencia Artificial y Derecho. Organizado por la Fundación General de la Universidad de Salamanca (España), y avalado por la Comunidad Europea. Duración: 120 hs. Fecha de Finalización: noviembre de 2022.
- Además de lo detallado previamente, todos los integrantes del equipo realizaron la capacitación obligatoria en género y violencia de género establecida en la Ley Micaela (conforme a Ley 27.499).

Direcciones y Tutorías de alumnos de grado y posgrado:

- Bossero: Director de Tesis de Maestría del Ing. Mauro Casucelli. Título: “Estudio comparativo de DBSCAN, KMEANS con redes neuronales en un Sistema de Recuperación de Información”. Maestría en Informática, Escuela de Posgrado, Universidad Nacional de La Matanza. Inicio: agosto 2018. En desarrollo.

Otras Actividades Científicas y Tecnológicas:

- Sposito, Ledesma, Procopio, Conti, García y Perez Villar - Participaron en la organización de una jornada titulada “Experticia. Un camino hacia la Inteligencia Artificial en la justicia”, realizada en forma conjunta por la Universidad Nacional de La Matanza y el Colegio de Magistrados y Funcionarios de la Provincia de Buenos Aires. Fue llevada a cabo el 31 de agosto de 2021 a través de la Plataforma Zoom hubo alrededor de 150 conexiones y además se transmitió por YouTube, con más de 500 vistas. El evento fue declarado de interés por la Suprema Corte de Justicia.

H. Cuerpo de anexos:

- Anexo I: Copia de cada uno de los trabajos mencionados en los puntos B, C y D, y certificaciones cuando corresponda.⁴
- Anexo II:
 - FPI-013: Evaluación de alumnos integrantes. (si corresponde)
 - FPI-014: Comprobante de liquidación y rendición de viáticos. (si corresponde)
 - FPI-015: Rendición de gastos del proyecto de investigación acompañado de las hojas foliadas con los comprobantes de gastos.

⁴ En caso de libros, podrá presentarse una fotocopia de la primera hoja significativa o su equivalente y el índice.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

- FPI-035: Formulario de reasignación de fondos en Presupuesto.
- Nota justificando baja de integrantes del equipo de investigación.

Firma y aclaración
del director del proyecto.

Lugar y fecha: San Justo, 30 de mayo de 2023

- Cargar este formulario junto con los documentos correspondientes **exclusivamente** al Anexo I en SI-GEVA UNLaM. Realizar la presentación impresa de los mismos junto con los restantes Anexos en la Secretaría de Investigación de la unidad académica correspondiente. **Límite de entrega: 28 de febrero de 2020.**



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

ANEXO I

COPIA DE ARTÍCULOS



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLAM



Revista Digital del Departamento de
Ingeniería e Investigaciones
Tecnológicas de la Universidad
Nacional de la Matanza
ISSN: 2525-1333
Vol.: 7 - Nro. 2 (DICIEMBRE 2022)



Artículo original

Determinación del umbral inferior de coincidencia aplicando medidas de edición a términos jurídicos

Determination of the lower similarity threshold applying measures of edit distance to legal terms

Lorena Matteo⁽¹⁾, Viviana Ledesma⁽²⁾, Osvaldo Spósito⁽³⁾

⁽¹⁾ Universidad Nacional de La Matanza
lmatteo@unlam.edu.ar

⁽²⁾ Universidad Nacional de La Matanza
vledesma@unlam.edu.ar

⁽³⁾ Universidad Nacional de La Matanza
sposito@unlam.edu.ar

Resumen:

Aplicar técnicas que ayuden a reducir el espacio de búsqueda en tareas de consultas a corpus jurídicos documentales es sumamente importante debido al volumen y diversidad de datos involucrados. Utilizando medidas de similitud léxica, en particular, aquellas basadas en cadenas de caracteres, es posible encontrar el umbral que determine el límite inferior aceptable del porcentaje de coincidencia de los términos que representan el mismo concepto. De este modo se minimiza la tarea manual de los expertos de dominio, ayudándolos a focalizarse en la revisión/validación de la similitud de aquellos términos que estén dentro de ese umbral de coincidencia. Seleccionando el término más representativo de cada concepto es posible reducir la matriz término-documento, punto de entrada para la búsqueda de información dentro del corpus.

En este artículo se explica el procedimiento para encontrar el umbral de coincidencia que surge al aplicar medidas de similitud léxica a ciertos grupos de términos que representan distintos escenarios jurídicos. Estas medidas son las distancias de edición de Hamming y de Levenshtein.

Los resultados muestran que el umbral puede variar según cada escenario o medida, ayudando a los expertos a centrarse en el análisis de aquellos términos cuyo porcentaje de similitud esté dentro del umbral propuesto.

Abstract:

Applying techniques that help reduce search time in query tasks to documentary legal corpus is of great importance due to the volume and diversity of data involved. Using measures of lexical similarity, based on character strings, it is possible to find the threshold that determines the acceptable lower limit of the coincidence percentage of terms that represent the same concept. In this way, the manual task of domain experts is minimized, helping to focus on the review/validation of the similarity of those terms that are within that matching threshold. By selecting the most representative term for each concept in question, it is possible to reduce the term-document matrix, the entry point for searching for information within the corpus.

This article explains the procedure to find the coincidence threshold that arises when applying lexical similarity measures to certain groups of terms that represent different legal scenarios. These measures are the Hamming and Levenshtein edit distances.

The results show that the threshold can vary according to each scenario/measurement, helping experts to focus on the analysis of terms whose percentage of similarity is within the proposed threshold.

Palabras Clave: *Medidas de Similitud Léxica; Umbral de Similitud; Sistema de Recuperación de Información; Hamming; Levenshtein*

Key Words: *Lexical Similarity Measures; Similarity Threshold; Information Retrieval System; Hamming; Levenshtein*

Colaboradores: *Julio Bossero, Edgardo Moreno*

I. CONTEXTO

Este artículo se enmarca en una línea de investigación, relacionada al estudio de los Sistemas de Recuperación de Información (SRI) realizada por investigadores del Departamento de Ingeniería e Investigaciones Tecnológicas y del Departamento de Derecho y Ciencia Política de la Universidad Nacional de La Matanza. Particularmente se asocia al proyecto PROINCE, código C241, *“Implementación de un Sistema Web de Recuperación de la Información Orientado a Documentación Jurídica con el Proceso de Indexación Semántica Latente Paralelizado”*, con vigencia 2021-2022.

II. INTRODUCCIÓN

En el dominio judicial, la jurisprudencia es un factor importante como fuente de derecho; porque sus conclusiones crean una pauta para la aplicación de la ley ante situaciones jurídicas similares. Cada año el poder judicial argentino produce una gran cantidad de decisiones que se guardan en diversas formas, como ser dictámenes o expedientes, haciendo que esta fuente documental sea cada vez más voluminosa, lo que impulsa a los profesionales de la justicia a dedicar más tiempo a la búsqueda de documentos relevantes. Esto conduce a la aplicación de técnicas sofisticadas para reducir el tiempo de búsqueda y mejorar la pertinencia de los documentos recuperados.

En tal contexto, como se mencionó previamente, este grupo de investigación se encuentra trabajando en la especialización de un SRI para su utilización en un contexto jurídico. El principal objetivo es que dicho sistema permita, a partir de una consulta, recuperar documentos con características similares y útiles para la

resolución de un problema legal. A su vez, se pretende diseñar y crear un corpus de referencia jurídica.

Como es sabido, es de suma importancia contar con la participación de los expertos de dominio para ir validando los términos que forman parte del corpus, muchas veces efectuando controles manuales, lo cual implica un esfuerzo considerable.

A fin de reducir ese costo de intervención manual y, para mejorar la performance en la búsqueda exhaustiva de patrones realizada inicialmente mediante el uso de expresiones regulares [1], es que surge la necesidad de aplicar técnicas complementarias que ayuden a reducir la dimensionalidad o cantidad de términos de la matriz término-documento. Dicha matriz es el punto de entrada en la búsqueda de información dentro un corpus, según se explicará más adelante.

Por tanto, si bien el procedimiento y acciones descriptos en el presente artículo surgen en principio con el objetivo de reducir los términos de la matriz de búsqueda de documentos jurídicos, esto puede aplicarse para encontrar un umbral de similitud óptimo entre cualquier conjunto de términos, sea de la índole que fuera. Esto ayudará a los expertos de dominio a centrarse en el análisis manual de aquellos términos cuyo porcentaje de coincidencia se encuentre dentro del umbral sugerido.

III. SISTEMAS DE RECUPERACIÓN DE INFORMACIÓN

Un SRI, puede describirse como un conjunto de ítems de información o corpus de documentos, un conjunto de peticiones y un mecanismo que determine qué ítems satisfacen las peticiones de los usuarios. En otras palabras,

devuelve una lista ordenada o rankeada de documentos supuestamente relevantes para la consulta [2].

Se han ideado diferentes modelos basados en distintos paradigmas para la representación de un SRI, así como

para calcular el grado de similitud entre los elementos de información para responder determinada consulta [3] [4] [5].



Figura 1. Proceso de búsqueda en un SRI. Fuente: Elaboración propia.

Hay tres modelos, que se consideran clásicos y son los más utilizados:

- *Booleano*: basado en la teoría de conjuntos y en el álgebra de Boole. Se crea un conjunto con los elementos de la consulta y otro con los documentos, posteriormente se mide la correspondencia.
- *Vectorial*: se apoya en la idea de la importancia de un término con respecto a un documento, así como que los documentos y las consultas se pueden representar como un vector en un espacio de alta dimensionalidad. De esta manera, la consulta y los términos del documento se representan mediante dos vectores, midiéndose el grado de similitud entre ambos.
- *Probabilístico*: se calcula la probabilidad en que el documento responde a la consulta. Frecuentemente se usa retroalimentación, mediante interacción con el usuario para que

indique qué documentos son más relevantes, para así reformular la consulta.

El trabajo de investigación en curso se enmarca en un modelo vectorial. Como se grafica en la Figura 1, la colección o corpus documental se representa en una matriz de término-documento. En la intersección de un término y un documento se almacena un valor numérico para denotar la importancia de tal término en el documento. Así, cada documento puede ser visto como un vector que pertenece a un espacio *n-dimensional*, donde *n* es la cantidad de términos que componen el vocabulario del corpus. En teoría, los documentos que contengan términos similares estarán cercanos entre sí sobre tal espacio. Una consulta se considera un documento más y se la mapea sobre el espacio de documentos. Entonces, a partir de una consulta dada es posible devolver una lista de documentos ordenados por distancia con los más relevantes primero. En cualquier dominio de conocimiento, aquellos términos con significado pueden servir como descriptores para una representación lógica del contenido de documentos, así

como para las consultas en el proceso de recuperación de información [6]. Por lo tanto, una fase muy importante en un SRI es la de preparación de los documentos, esto implica que, en la fase de entrada, se deba realizar la indización y organización de la información. Según Tolosa y Bordignon, en [7] afirman que dicho proceso se puede dividir en las siguientes etapas:

- Análisis lexicográfico, se extraen las palabras y se normalizan.
- Reducción (Tokenización) de palabras vacías o de alta frecuencia.
- Lematización, se reducen palabras morfológicamente parecidas a una forma base o raíz, con la finalidad de aumentar la eficiencia de un SRI.
- Selección de los términos a indexar. Se extraen aquellas palabras simples o compuestas que mejor representan el contenido de los documentos.
- Asignación de pesos o ponderación de los términos que componen los índices de cada documento.

El trabajo que se está presentando en el presente artículo se circunscribe al proceso antes mencionado. El SRI desarrollado por este grupo de investigación, adopta inicialmente una de las representaciones más extendidas, sobre todo por su simpleza, la matriz término-documento, también llamada 'bolsa de palabras'. Es decir, se forma un vector con la frecuencia de los términos del texto, con lo cual, los documentos se caracterizan por las palabras que contienen [8].

IV. REDUCCIÓN DE DIMENSIONALIDAD DE LA MATRIZ TÉRMINO-DOCUMENTO

Las matrices conseguidas con la bolsa de palabras tienen una gran cantidad de variables o dimensiones, por no estar normalizadas, lo cual es poco útil para trabajar. Por ello, se busca una reducción de dimensionalidad, esto es llevar a una mínima cantidad posible, el número total de dimensiones que existen en el modelo del espacio vectorial.

A partir de dicha representación lógica del corpus, mediante el proceso de indización se lleva a cabo la construcción de estructuras de datos o índices a fin de brindar posteriormente soporte para la recuperación de los documentos.

Con lo anterior presente, este equipo ha propuesto, como parte de esta investigación, un algoritmo para la búsqueda y reemplazo de Entidades Nombradas (EN) utilizando Expresiones Regulares (ER). Una ER es una secuencia de caracteres que forma un patrón de búsqueda. Una EN, según [9], "*es una palabra o secuencias de palabras que se identifican como nombre de persona, organización, lugar, fecha, tiempo, porcentaje o cantidad...*". Mayor detalle de esta propuesta se incluyó en [1], donde se analizó implementar en el proceso de indización de términos de un corpus jurídico, la identificación de fechas y de referencias a EN, tales como Expediente N°, Resolución N°, Artículo N° de la Ley XXX, que remiten a la norma jurídica vigente y son ampliamente utilizadas en distintos documentos judiciales.

En dicho trabajo se concluye que la aplicación de ER para encontrar EN tiene la como ventaja que:

- una vez hallada la expresión correcta, las entidades que durante la búsqueda exhaustiva

coincidan exactamente con dicho patrón serán todas las existentes en el corpus. Esto tiene mayor importancia dado que los textos legales son muy estructurados y las entidades aparecen con cierta regularidad, por otra parte,

- son fáciles de implementar ya que no necesitan más que codificar la expresión del patrón en sí, y no requieren, por ejemplo, del entrenamiento de un modelo para su reconocimiento.

Como desventaja, se sabe que estas se limitan a encontrar los patrones predefinidos, por lo cual, no es posible encontrar otra EN que no coincida con alguna de las ER existentes.

Por esta razón y considerando que el SRI debe procesar lenguaje natural, es que para ir un paso más adelante, se encaró la tarea de comparar los términos entre sí, resultando de interés detectar no sólo las coincidencias exactas entre dos términos, sino también disponer de una medida de aproximación o similitud entre estos para los casos en que la coincidencia no sea exacta. Se puso en foco la detección de términos jurídicos similares, los cuales surgen como resultado del proceso de indización y organización de la información del SRI, de este modo se pretende reducir el esfuerzo de seleccionar manualmente los términos a indexar.

Las palabras pueden ser similares léxica o semánticamente. La similitud léxica toma en cuenta si las palabras tienen secuencias de caracteres semejantes [10]. Por otro lado, las palabras tienen similitud semántica si significan lo mismo en un contexto dado, aunque léxicamente sean distintas.

Las funciones de similitud léxica han sido investigadas por décadas, existen diversos métodos o propuestas para

la resolución del cálculo de la similitud de este tipo, cada una tiene sus peculiaridades según la aplicación que se le deba dar [3] [11]. Según Elmagarmid y otros [12], las distintas propuestas podrían dividirse en dos grupos: las basadas en cadenas de caracteres (distancia de edición, Brecha Afin, Smith-Waterman, Hamming, Levenshtein y Jaro, entre otras) y las basadas en tokens o secuencias de palabras (por ejemplo, Similitud de Monge-Elkan y Similitud coseno TF-IDF).

El análisis que se está presentando en este artículo se enfoca en la similitud léxica basada en cadenas de caracteres, dentro de este grupo, en la distancia de edición. Esta se define como la cantidad mínima de cambios requeridos para transformar la cadena origen en la cadena destino, en donde las operaciones permitidas se eligen de un conjunto fijo como ser la eliminación, inserción y sustitución. Como se adelantó, en este trabajo se presentan parcialmente los resultados obtenidos al comparar dos de las métricas más utilizadas en esta categoría, la distancia de Hamming (HAM) y la distancia de Levenshtein (LEV), con el objetivo de reducir la dimensionalidad de la matriz término-documento respecto de aquellos términos coincidentes. Para lograrlo, se busca encontrar un umbral de similitud aceptable que permita asumir que dos términos son representaciones de la misma EN. Ese umbral surge de comparar el porcentaje de similitud, basado en dos métricas de Precisión y Recall, ampliamente utilizadas en este tipo de ensayos como se efectuó en [16]. Estas ayudan a determinar la efectividad de las técnicas de detección de similitud de cadenas. De este modo, los expertos de dominio pueden centrarse en el análisis de aquellos términos cuyo porcentaje de similitud

esté dentro del umbral propuesto, a mayor sea su valor, mayor similitud entre los términos

IV. DISEÑO DEL EXPERIMENTO PARA LA DETERMINACIÓN DEL UMBRAL

En esta sección se explica el método aplicado para encontrar el umbral de similitud de cada grupo de términos jurídicos, creados para tal fin, en base a la efectividad resultante de las medidas de edición de caracteres.

- *Paso 1: creación de grupos de términos para representar distintos escenarios jurídicos.*

Para llevar adelante este trabajo se ha partido de una lista de 11.155 términos, es decir EN, resultantes del proceso de indización y organización de la información del SRI. La lista original contiene 3 campos: clave, término y ocurrencia en el corpus.

Con el objetivo de reducir esa lista de términos se ha recurrido a las técnicas de detección de similitud de cadenas. A modo de ensayo, se utilizó un procedimiento basado en experimentos, para ello, tal como se refleja en la Tabla 1, se armaron 5 grupos de EN significativas.

Como se mencionó anteriormente, las funciones de similitud elegidas para abordar este trabajo fueron HAM y LEV. La comparación se realizó mediante las métricas de evaluación de efectividad: precisión y recall, buscando determinar la eficacia de las funciones ante cada

escenario, representado por cada grupo de entidades nombradas, Grupo EN_x, donde x identifica el caso de estudio.

Tabla 1.
Composición de experimentos por grupos de EN

Caso Estudio	Grupo EN	Cantidad Términos	Concepto
1	Grupo EN1	12	Relación con EN "Legal"
2	Grupo EN2	8	Relación con EN "Oficial"
3	Grupo EN3	16	Relación con EN "Expediente"
4	Grupo EN4	9	Relación con EN "Mediación"
5	Grupo EN5	15	Relación con EN "Fechas y Otras"
Total EN		60	

- *Paso 2: clasificación manual de similitud entre los términos de cada Grupo de EN_x.*

Para aplicar las métricas de evaluación de efectividad mencionadas es necesario que los expertos de dominio clasifiquen previamente las coincidencias reales entre cada par de términos incluidos en cada uno de los grupos de EN. Para ello se armaron matrices, donde las EN de cada grupo se colocaron en las filas y se repitieron en las columnas. Un ejemplo de ello se puede visualizar en la Figura 2, donde se muestra la clasificación de similitud para el grupo EN₂. En la intersección de cada término el experto debió realizar una clasificación manual de las coincidencias en reales/verdaderas y falsas, asignando el valor 1, cuando los considere similares o 0 en caso contrario.

EXPERIMENTO CLASIFICACION MANUAL

Terminos GrupoEN2	boletinoficial	filosoficoreligi	ofici	oficial	oficializ	oficialy	oficin	suboficial
boletinoficial	1	0	0	0	0	0	0	0
filosoficoreligi	0	1	0	0	0	0	0	0
ofici	0	0	1	1	1	1	1	0
oficial	0	0	1	1	1	1	0	0
oficializ	0	0	1	1	1	1	0	0
oficialy	0	0	1	1	1	1	0	0
oficin	0	0	1	0	0	0	1	0
suboficial	0	0	0	0	0	0	0	1

Figura 2. Clasificación Manual de Similitud entre los términos del Grupo EN₂. Fuente: Elaboración propia.

Esta clasificación fue útil para comparar el resultado conseguido más tarde con la aplicación de las funciones de HAM y LEV a cada grupo, siendo dicho resultado el porcentaje de coincidencia de cada término de la matriz de similitud. De esta forma es posible evaluar la efectividad de los porcentajes de similitud, encontrando el límite inferior del umbral de coincidencia. El beneficio de esto radica en que cuando los expertos deban analizar el corpus completo, puedan enfocarse en el análisis de términos cuyo porcentaje de similitud esté dentro del umbral propuesto, reduciendo de este modo su carga de trabajo.

• *Paso 3: Cálculo de la distancia de HAM*

Esta métrica se basa en [13], es igual a la cantidad de posiciones en las que difieren ambas cadenas, y sólo permite la sustitución. Se obtiene haciendo un conteo del número de posiciones en las que los caracteres de las

cadenas comparadas difieren, siendo 0 el valor resultante cuando hay coincidencia total entre las cadenas y, distinto de 0 en caso contrario. Es útil para comparar dos cadenas de caracteres de igual longitud. Es una de las métricas más simples en la que se considera el orden de los elementos.

Con lo anterior presente, el estudio realizado requirió que en un inicio las EN a comparar se ordenaran alfabéticamente. Además, se agregaron espacios en blanco a aquellas EN de la cadena de menor longitud para equiparar la cantidad de caracteres, respetando de este modo la restricción de HAM.

Se implementó una función para el cálculo, los resultados obtenidos a partir de la misma se expresaron en porcentajes de coincidencia, a modo de ejemplo, en la Figura 3 se puede observar los valores resultantes correspondientes al grupo EN₂.

Terminos GrupoEN2	boletinoficial	filosoficoreligi	ofici	oficial	oficializ	oficialy	oficin	suboficial
boletinoficial	100,0	6,0	0,0	0,0	0,0	0,0	0,0	7,0
filosoficoreligi	6,0	100,0	0,0	0,0	6,0	0,0	0,0	12,0
ofici	0,0	0,0	100,0	71,0	56,0	62,0	83,0	0,0
oficial	0,0	0,0	71,0	100,0	78,0	88,0	71,0	0,0
oficializ	0,0	6,0	56,0	78,0	100,0	78,0	56,0	10,0
oficialy	0,0	0,0	62,0	88,0	78,0	100,0	62,0	0,0
oficin	0,0	0,0	83,0	71,0	56,0	62,0	100,0	0,0
suboficial	7,0	12,0	0,0	0,0	10,0	0,0	0,0	100,0

Figura 3. Porcentaje de Similitud entre términos del Grupo EN₂ usando HAM. Fuente: Elaboración propia.

Para facilitar la visualización durante el análisis de estos ensayos se utilizaron colores tipo semáforo para diferenciar los porcentajes de coincidencia: siendo la gama de verdes, según su intensidad, los más cercanos al 100%.

- *Paso 4: Cálculo de la distancia de LEV*

Esta distancia o índice también pertenece a las distancias de edición, siendo el resultado de este algoritmo dinámico la cantidad mínima de operaciones que se requiere para convertir un término en otro; entendiéndose por operaciones de edición a la inserción, eliminación o sustitución de caracteres dentro de esa EN, según se explica en [14]. Mientras mayor sea la distancia de LEV, mayor será la diferencia entre los dos términos; por ende, y al igual que en HAM, una distancia de valor igual a 0 indica que los dos términos son idénticos. Para el estudio, del mismo modo que se hizo con HAM, se implementó la

función para el cálculo de LEV, en la Figura 4 se pueden observar los porcentajes resultantes para el grupo EN₂.

Tal lo mencionado en [15], esta técnica se destaca por su capacidad de detección de errores tipográficos típicos, en dicho artículo se encuentran categorizados como situaciones problemáticas, a saber: errores ortográficos y tipográficos, abreviaturas: truncamiento de uno o más términos, términos faltantes, eliminación de uno o más términos, prefijos/sufijos sin valor semántico, términos en desorden, espacios en blanco. Al trabajar con un corpus asociado a un contexto jurídico estas situaciones podrían ser corrientes, por lo que detectar la similitud entre términos con estas características es parte del objetivo de este experimento, ya que al detectarlos el experto puede decidir cuál de esos términos mejor representa a la EN en cuestión.

Terminos GrupoEN2	boletinoficial	filosoficoreligi	ofici	oficial	oficializ	oficialy	oficin	suboficial
boletinoficial	100	25	36	50	36	43	36	50
filosoficoreligi	25	100	31	31	38	31	31	31
ofici	36	31	100	71	56	62	83	50
oficial	50	31	71	100	78	88	71	70
oficializ	36	38	56	78	100	78	56	50
oficialy	43	31	62	88	78	100	62	60
oficin	36	31	83	71	56	62	100	50
suboficial	50	31	50	70	50	60	50	100

Figura 4. Porcentaje de Similitud entre términos del Grupo EN₂ usando LEV. Fuente: Elaboración propia.

• *Paso 5: Obtención de medidas de Precisión y Recall*

A fin de comparar la eficacia en la detección de coincidencias utilizando las dos funciones comparadas, se aplicaron las métricas, Precisión y Recall, que permiten encontrar el limite inferior del umbral de coincidencia ya mencionado.

Acá entra en juego la clasificación manual efectuada por el experto de dominio mencionada en el Paso 2 de este apartado.

Precisión trata de responder la pregunta: ¿Qué proporción de los términos identificados como coincidentes son realmente correctos?

Es la relación entre el número de términos coincidentes identificados correctamente y el número total de términos coincidentes que ha identificado la función (de HAM o de LEV).

$$Precisión = \frac{\text{coincidentes identificados correctamente}}{\text{número coincidentes identificados}}$$

Recall, por su parte, trata de responder la pregunta: ¿Qué proporción de los términos coincidentes reales se identifica correctamente?

Es la relación entre el número de términos coincidentes identificados correctamente y el número de coincidentes que realmente hay en el grupo EN_x.

$$Recall = \frac{\text{coincidentes identificados correctamente}}{\text{número coincidentes reales}}$$

Estas medidas se calculan para cada rango de porcentajes, etiquetándolos como se ve en las Figuras 5 y 6.

PrecisiónUmb ralMen60	PrecisiónUmb ralMay60	PrecisiónUmb ralMay70	PrecisiónUmb ralMay80	PrecisiónUmb ralMay90	PrecisiónUmb ral100
--------------------------	--------------------------	--------------------------	--------------------------	--------------------------	------------------------

Figura 5. Precisión para los Rangos de Umbrales de 0% a 100%.

Fuente: Elaboración propia.

RecallUmbral Men60	RecallUmbral May60	RecallUmbral May70	RecallUmbral May80	RecallUmbral May90	RecallUmbral 100
-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	---------------------

Figura 6. Recall para los Rangos de Umbrales de 0% a 100%.

Fuente: Elaboración propia.

De acuerdo con los valores obtenidos, como se puede ver en la Figura 7, se descarta la columna del umbral menores al 60%, columnas "*Precisión y Recall UmbralMen60*" dado que se estaría generalizando demasiado los términos del corpus, asumiendo esas coincidencias como válidas cuando en realidad no lo son. Detenerse en ello no sería útil para los expertos dado que revisarían términos sin relación alguna y, por ende, términos que no podrían eliminarse del listado. Cabe recordar que el objetivo principal de este trabajo es facilitar las tareas reducción de la dimensionalidad de la matriz término-documento. Por otra parte, luego de los resultados obtenidos, los cuales

seguirán en estudio, también se descartan las columnas “Precisión y Recall UmbralMay90” dado que no se encontraron términos en ese rango de similitud. Finalmente, se descartan los resultados del umbral igual al 100%, columna “Precisión y Recall Umbral100”, ya que en dicha columna se ubican todos los términos que pertenecen a la diagonal principal de la matriz de coincidencias, es decir el cruce de cada término consigo mismo. Por tanto, los umbrales a analizar serán los comprendidos entre 60 y 99%, siempre observando los términos en orden alfabético.

• Paso 6: Consolidación de Resultados

A fin de visualizar los resultados de manera más clara y concisa, tal como se puede ver en las Figuras 8 y 9, se confeccionó un tablero que consolida los resultados de las métricas de efectividad resultantes para los umbrales seleccionados. Se incluye los promedios para cada una de las distancias de HAM y LEV por grupo EN_x. De esta forma es posible analizar a simple vista aquellos grupos EN_x cuyos porcentajes de similitud sean los mayores dentro de los umbrales seleccionados, ya que esos grupos contendrán términos relevantes para las tareas de revisión y reducción de las EN

GrupoEN	Metadefinición	Término	CantSimilares Bases	PrecisiónUmbr al60%	PrecisiónUmbr alMay60	PrecisiónUmbr alMay70	PrecisiónUmbr alMay80	PrecisiónUmbr alMay90	PrecisiónUmbr al100	RecallUmbral al60%	RecallUmbral May60	RecallUmbral May70	RecallUmbral May80	RecallUmbral May90	RecallUmbral 100	
GrupoEN4	Hamming	mediar	6	25%	100%	0%	100%	0%	100%	17%	10%	0%	0%	33%	0%	17
GrupoEN4	Hamming	mediat	3	0%	0%	0%	100%	0%	100%	0%	0%	0%	67%	0%	33	
GrupoEN5	Hamming	14/9/1991	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	18/10/1893	2	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	18/10/1893	2	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	22/11/2001	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	27/2/2006	2	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	27/2/2006	2	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	arao	2	0%	0%	0%	100%	0%	100%	0%	0%	0%	50%	0%	50	
GrupoEN5	Hamming	arao	2	0%	0%	0%	100%	0%	100%	0%	0%	0%	50%	0%	50	
GrupoEN5	Hamming	aviet	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	boon	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	boonj	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	acod	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	acoc	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	acopt	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN5	Hamming	acoc	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN1	Levenshtein	alegar	2	0%	0%	0%	50%	0%	100%	0%	0%	0%	100%	0%	100	
GrupoEN1	Levenshtein	alegal	2	0%	0%	0%	100%	0%	100%	0%	0%	0%	20%	0%	20	
GrupoEN1	Levenshtein	delegacion	2	0%	0%	0%	0%	0%	100%	0%	0%	0%	50%	0%	50	
GrupoEN1	Levenshtein	ilegal	2	0%	0%	0%	0%	0%	100%	0%	0%	0%	50%	0%	50	
GrupoEN1	Levenshtein	legacion	3	0%	100%	0%	0%	0%	100%	0%	33%	0%	33%	0%	33	
GrupoEN1	Levenshtein	legal	5	0%	0%	100%	100%	0%	100%	0%	0%	33%	55%	0%	55	
GrupoEN1	Levenshtein	legaje	2	0%	0%	100%	0%	0%	100%	0%	0%	50%	0%	0%	50	
GrupoEN1	Levenshtein	legal	4	0%	0%	100%	100%	0%	100%	0%	0%	25%	50%	0%	25	
GrupoEN1	Levenshtein	legaria	3	0%	100%	100%	0%	0%	100%	0%	33%	33%	0%	0%	33	
GrupoEN1	Levenshtein	legateri	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN1	Levenshtein	ilegar	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN1	Levenshtein	supralegal	1	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	100	
GrupoEN2	Levenshtein	boletoficial	1	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0	

Figura 7. Precisión y Recall para los Rangos de Umbrales de 0% a 100%. Fuente: Elaboración propia.

Precisión y Recall Hamming por Umbrales (Entre 60 y 89%)

Etiquetas de fila	Promedio de PrecisiónUmbra lMay60	Promedio de PrecisiónUmbra lMay70	Promedio de PrecisiónUmbra lMay80	Promedio de RecallUmbra lMay 60	Promedio de RecallUmbra lMay 70	Promedio de RecallUmbra lMay 80
GrupoEN1	16,67%	33,33%	29,17%	5,56%	11,81%	17,36%
GrupoEN2	18,75%	45,83%	50,00%	5,63%	18,13%	15,00%
GrupoEN3	39,27%	9,38%	9,38%	26,56%	3,65%	3,65%
GrupoEN4	50,00%	22,22%	55,56%	22,04%	7,41%	24,07%
GrupoEN5	0,00%	0,00%	13,33%	0,00%	0,00%	6,67%
Total general	23,81%	18,61%	26,67%	12,25%	6,86%	11,72%

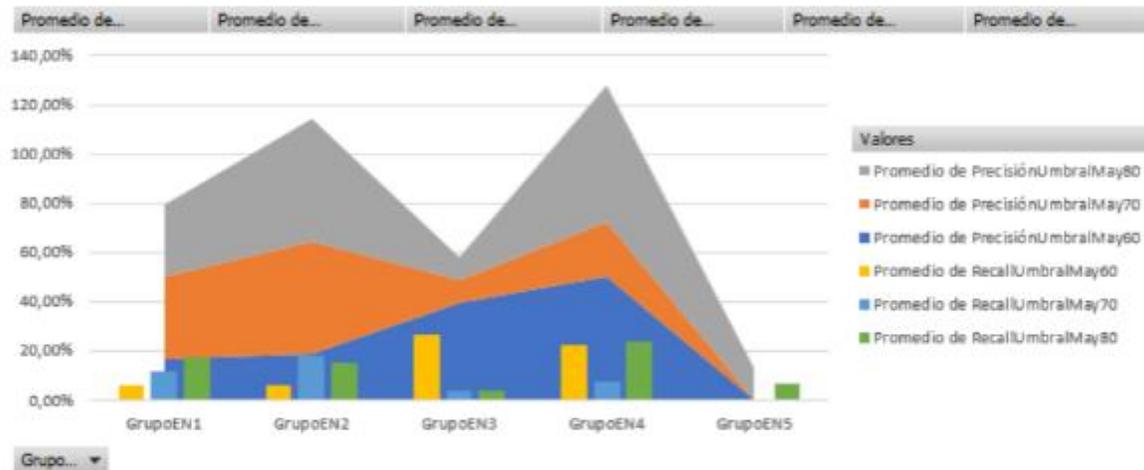


Figura 8. Tablero de control - Umbrales HAM. Fuente: Elaboración propia.

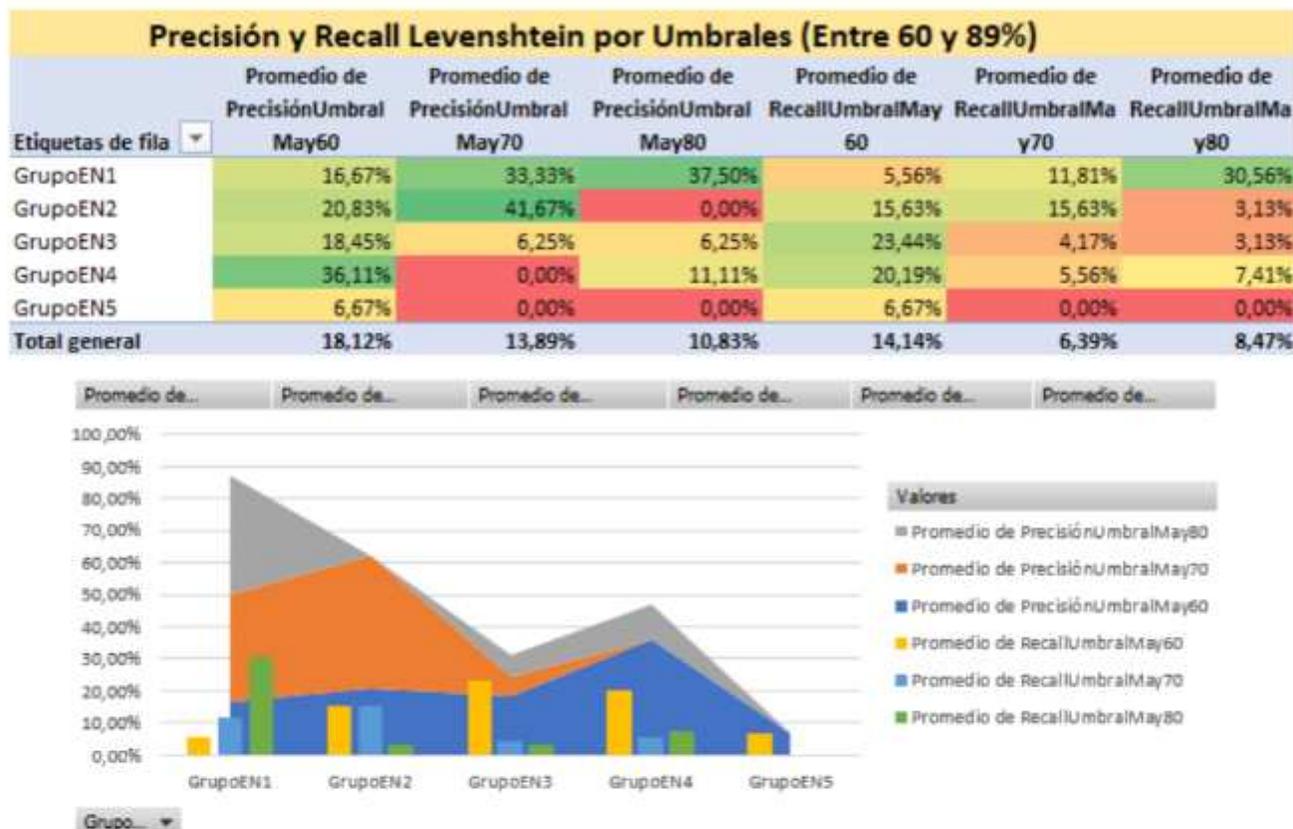


Figura 9. Tablero de control - Umbrales LEV. Fuente: Elaboración propia.

V. ANÁLISIS DE LOS RESULTADOS

Finalmente, para el análisis de los resultados del estudio realizado, se unificaron los resultados obtenidos en un tablero definitivo EN_x (ver Figura 10), lo cual permite comparar los promedios para ambas distancias de edición. Como se puede observar, la precisión de las distancias de HAM y LEV en el grupo EN₁, para el umbral mayor a 70%, es coincidente en un 33% y en aproximadamente en un 12% para el recall. En tanto, la precisión del grupo EN₂ para dicho umbral es de las mayores arrojadas por las medidas de edición. Además, el recall para ese grupo de medidas también es de los más altos. Esto denota la

relevancia de que los expertos revisen la similitud de los términos que componen tal grupo. Esto es de suma importancia recordando que esa medida de efectividad indica que proporción de los términos coincidentes reales se identificó correctamente.

Gráficamente, el análisis de resultados es mucho más visible, siendo el umbral del 80%, tanto para la precisión como para recall, el porcentaje de similitud más relevante, en especial para los grupos EN₁, EN₂ y EN₄. Basándose en estos resultados, los expertos de dominio podrán

focalizarse en las tareas de revisión y reducción de EN de dichos grupos en dicho umbral.

VI. CONCLUSIONES

A través del presente artículo se exhibieron los resultados obtenidos de un estudio llevado a cabo para la facilitar el proceso de detección de términos jurídicos similares.

La motivación que llevó a realizar esta actividad deriva de la importancia de acotar la matriz de término-documento, punto de entrada para el proceso de indexación, necesario

para la búsqueda en el contexto de un SRI. El enfoque se puso en la búsqueda del mejor umbral de coincidencia que surge de aplicar medidas de similitud léxica a los términos resultantes del proceso de indización y organización del corpus con el que se está trabajando en la actualidad.

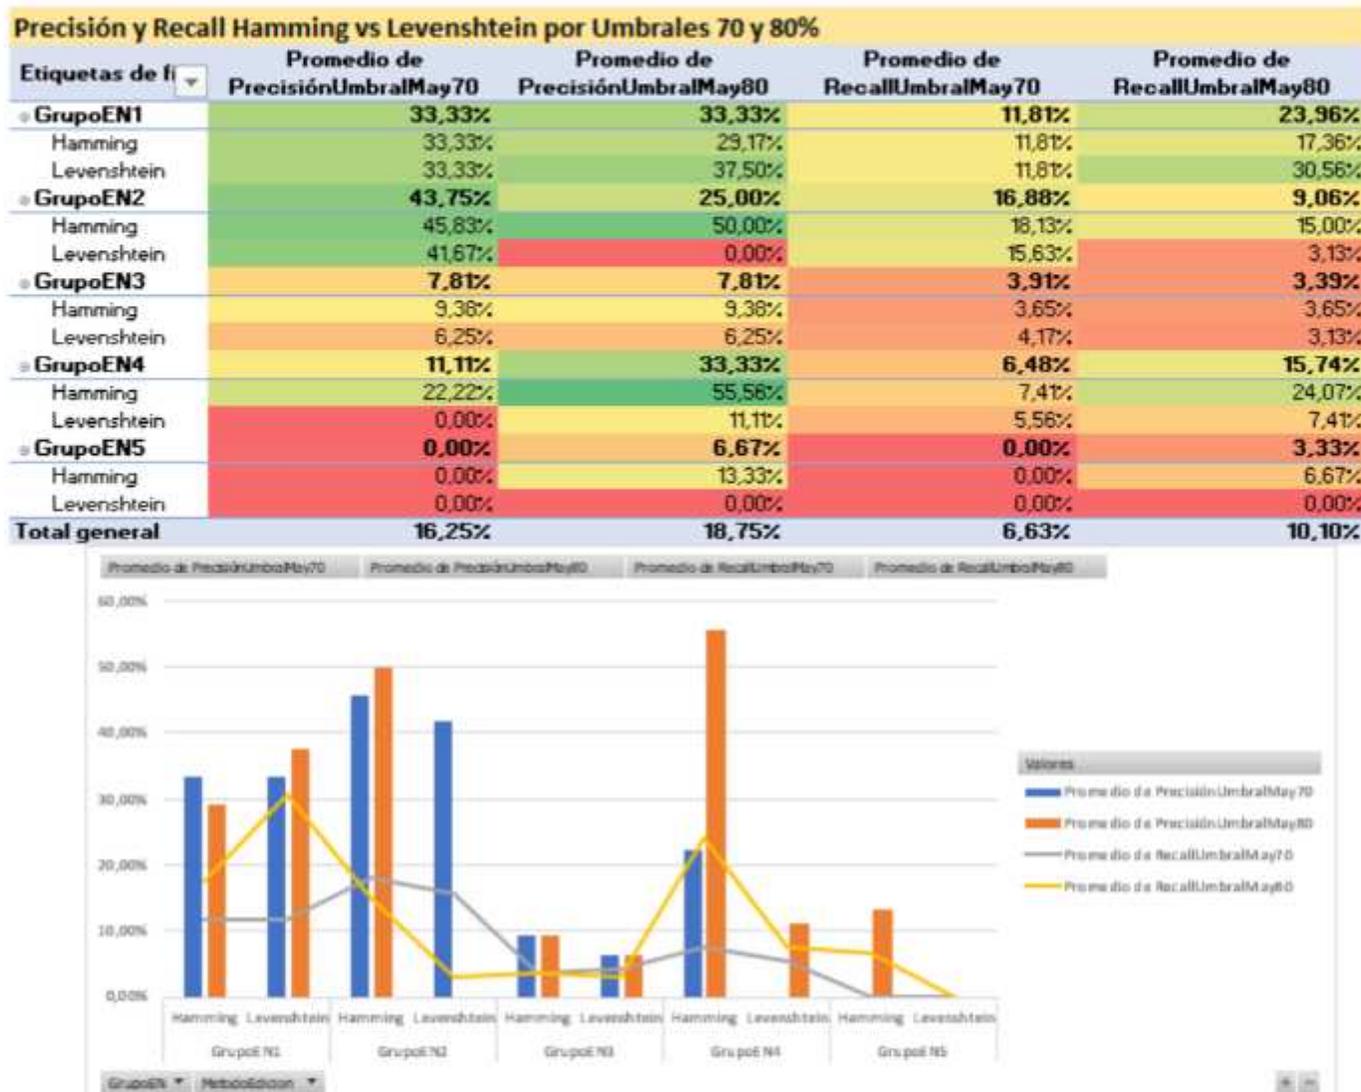


Figura 10. Tablero control - Umbrales HAM y LEV. Fuente: Elaboración propia.

Aunque este procedimiento no exige de la necesidad de contar con el experto humano, puede ser de gran ayuda para minimizar el esfuerzo implicado en su trabajo, debido a que permite acotar el volumen de términos en los que debe centrarse para elegir aquel que mejor represente a la EN.

Se ha observado que los resultados son dependientes de los términos incluidos en cada grupo de EN, y deben analizarse dentro del contexto de cada uno de los escenarios jurídicos creados.

Vale la pena mencionar que no es fácil proporcionar una solución automática, ya que se deben aplicar y adaptar varias técnicas de similitud para adecuarse a los datos concretos de que se disponen. En cuanto a este ensayo, en particular, se concluye que el límite inferior del umbral de coincidencia más relevante es el 80%. De todos modos, y como ya se ha mencionado, ha de tenerse en cuenta qué medida de edición es más fiable en cada escenario a saber: HAM debe considerarse para situaciones donde importa el orden de los caracteres de los términos en cuestión, por ejemplo, fechas, números de leyes, de expedientes, y así por el estilo. Si bien estos también pueden encontrarse fácilmente usando ER, las distancias de edición son más flexibles. En cuanto a LEV, es importante destacar que es más útil para detectar las situaciones problemáticas ya mencionadas, en dichos casos es conveniente mirar los términos del umbral con mejor precisión y recall para esa medida de edición.

VII. TRABAJOS FUTUROS

Para avanzar en esta investigación, a futuro se espera trabajar con un corpus de expedientes jurídicos de mayor

volumen, así también, ampliar las medidas de similitud utilizadas.

A su vez, es necesario un análisis más exhaustivo sobre ciertos resultados llamativos dentro del tablero de control consolidado, como ser los promedios de 0% del grupo EN₃ en el umbral del 70%. Así también, será objeto de estudio el análisis de la precisión y recall para el umbral May90, y la causa por la que no se encontraron términos en ese rango de similitud; probablemente sea necesario incluir mayor cantidad de escenarios jurídicos y por ende EN dentro de estos grupos de estudio.

Por otra parte, es necesario involucrar a mayor cantidad de expertos del dominio, para la validación de los resultados obtenidos, de cara a lograr la automatización del proceso de búsqueda del umbral de coincidencia del corpus completo.

VIII. REFERENCIAS Y BIBLIOGRAFÍA

A. Referencias bibliográficas:

- [1] O. Sposito, J. Bossero, E. Moreno, V. Ledesma, & L. Matteo. "Lexical Analysis Using Regular Expressions for Information Retrieval from a Legal Corpus", en *Computer Science – CACIC 2021*. Springer International Publishing, 2022.
- [2] G. Kowalski. "Information Retrieval Systems: Theory and Implementation", 1st ed. Norwell, MA, USA: Kluwer Academic Publishers, 1997.
- [3] C. Lorenzetti. "Caracterización Formal y Análisis Empírico de Mecanismos Incrementales de Búsqueda basados en Contexto". *Tesis Doctoral en Ciencias de la Computación* - Universidad Nacional del Sur. Buenos Aires, Argentina, 2011.

- [4] G. Salton & M. Lesk. "Computer Evaluation of Indexing and Text Processing". *J. ACM*, 15(1): 8–36, 1968.
- [5] P. Castells, M. Fernandez & D. Vallet. "An Adaptation of the Vector-Space Model for Ontology-Based Information Retrieval". *IEEE Transactions on Knowledge and Data Engineering*. 19(2): 261 – 272, 2007.
- [6] J. Robredo. "Otimização dos processos de indexação dos documentos e de recuperação da informação mediante o uso de instrumentos de controle terminológico". *Ciência Da Informação*, 47(1). 2019. Disponible en: <http://revista.ibict.br/ciinf/article/view/4431>. Fecha de consulta: 07/02/22.
- [7] G. Tolosa & F. Bordignon. "Introducción a la Recuperación de Información: Conceptos, modelos y algoritmos básicos". Universidad Nacional de Luján, Argentina, 2008. Disponible en: <http://eprints.rclis.org/12243/1/Introduccion-RI-v9f.pdf>. Fecha de consulta: 07/02/22.
- [8] B. Harish & S. Guru & M. Shantharamu. "Representation and Classification of Text Documents: A Brief Review". *International Journal of Computer Applications, Special Issue on RTIPPR*. 1. 110 – 119, 2010.
- [9] C. Sánchez Pérez. "Clasificación de Entidades Nombradas utilizando Información Global". *Tesis de Maestría*. Instituto Nacional de Astrofísica, Óptica y Electrónica. 2008. Disponible en: <https://inaoe.repositorioinstitucional.mx/jspui/bitstream/1009/564/1/SanchezPCR.pdf>. Fecha de consulta: 06/03/2022.
- [10] W. Gomaa & A. Fahmy. "A Survey of Text Similarity Approaches". *International Journal of Computer Applications*. 68(13), 2013.
- [11] I. Amón, C. Jiménez. "Funciones de Similitud sobre Cadenas de Texto: Una Comparación Basada en la Naturaleza de los Datos", Disponible en: <https://repositorio.unal.edu.co/bitstream/handle/unal/69915/71644758.20104.pdf?sequence=3&isAllowed=y>. Fecha de consulta: 21/09/2022.
- [12] A. Elmagarmid, P. Ipeirotis, & V. Verykios. "Duplicate Record Detection: A Survey". *IEEE Transactions on Knowledge and Data Engineering*, 19(1): 1-16, 2007.
- [13] R. Hamming. "Error detecting and error correcting codes". *The Bell System Technical Journal*; Vol. XXVI, No. 2, pp. 147-160, 1950.
- [14] E. Gómez Ballester, "Aportaciones a la mejora de la eficiencia de la búsqueda del vecino más cercano", pp.5,19,137, [en línea], Fecha de consulta: 7/11/2022, https://rua.ua.es/dspace/bitstream/10045/28363/1/tesis_%20evagomezballester.pdf
- [15] I. Amón, C. Jiménez, "Funciones de Similitud sobre Cadenas de Texto: Una Comparación Basada en la Naturaleza de los Datos", [en línea], Fecha de consulta: 21/09/2022, <https://repositorio.unal.edu.co/bitstream/handle/unal/69915/71644758.20104.pdf?sequence=3&isAllowed=y>
- [16] I.G. Albeniz, J.R. González de Mendivil, "Estudio sobre la detección de duplicados en orígenes de datos heterogéneos", [en línea], Fecha de consulta: 22/09/2022, [https://academica-unavarra.es/xmlui/bitstream/handle/2454/16765/TF](https://academica.unavarra.es/xmlui/bitstream/handle/2454/16765/TF)

[G. Gorostizu, Albeniz Ion.pdf;jsessionid=6C646114
AECD758F433EF12200A60A92?sequence=1](https://hal.archives-ouvertes.fr/hal-01541446/document)

B. Bibliografía:

C. Cardellino C., M. Teruel, L. Alonso Alemany, & S. Villata. "A Low-cost, High-coverage Legal Named Entity". 2017. Disponible en: <https://hal.archives-ouvertes.fr/hal-01541446/document>. Fecha de consulta: 28/10/2022.

M. Cucatto. "El lenguaje jurídico y su desconexión con el lector especialista: El caso de a mayor abundamiento." Letras de Hoje, 48 (1), pp. 127-138, 2013. Disponible en: http://www.memoria.fahce.unlp.edu.ar/art_revistas/pr.9102/pr.9102.pdf. Fecha de consulta: 06/8/2022.

C. Dozier, M. Light, A. Vachher, S. Veeramachaneni & R. Wudali. "Named Entity Recognition and Resolution in Legal Text". Semantic Processing of Legal Texts, pp.27-43, 2010.

Rodríguez Inés, P. El uso de corpus electrónicos para la investigación de terminología jurídica (2008) Disponible en:

<https://www.tdx.cat/bitstream/handle/10803/286111/pr1de2.pdf?sequence=1>. Fecha de consulta: 06/06/2022

V.I. Levenshtein, "Binary codes capable of correcting deletions, insertions and reversals", Soviet Physics Doklady, pp.10:707-710, 1966. Disponible en: <https://ui.adsabs.harvard.edu/abs/1966SPhD...10..707L/aabstract> Fecha de consulta: 08/11/2022

Recibido: 2022-11-18

Aprobado: 2022-12-23

Hipervínculo Permanente: <https://doi.org/10.54789/reddi.7.2.4>

Datos de edición: Vol. 7 - Nro. 2 - Art. 4

Fecha de edición: 2022-12-29





Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019



Lexical Analysis Using Regular Expressions for Information Retrieval from a Legal Corpus

Oswaldo Mario Sposito , Julio César Bossero , Edgardo Javier Moreno ,
Viviana Alejandra Ledesma  , and Lorena Romina Matteo 

Department of Engineering and Technological Research, National University of La Matanza,
Florencio Varela 1903, San Justo, La Matanza, Buenos Aires, Argentina
{sposito, jbossero, ej_moreno, vledesma, lmatteo}@unlam.edu.ar

Abstract. This article presents part of the work carried out in the framework of a research that aims to optimize an Information Retrieval System, by means of its specialization for the retrieval of legal documents. One of the fundamental sub-processes in this type of system is lexical analysis, in which indexing techniques are applied. These techniques involve extracting a series of concepts representative of the topics covered in a document, and then using them as access points for retrieval. This article describes a proposal for the extraction of information and identification of dates and references to named entities, such as File No., Resolution No., Article No. of Law XXX, which refer to the legal norm in force and are widely used in different judicial documents. For the recognition of such named entities, the process employed the definition of patterns using Regular Expressions, a way of representing a language in a synthetic form, applying a set of rules. From this, the terms obtained are stored in a matrix of terms/documents. This paper also describes the algorithms used during the validation of the proposed solution and presents the experimental results that show that by applying this method a significant reduction in the size of the inputs to the matrix can be achieved.

Keywords: Information retrieval systems · Regular expressions · Recognition of named entities · Lexical analysis

1 Introduction

This article is a continuation of the work presented at the 26th Argentine Congress of Computer Science, CACIC 2021, held in the city of Salta from 4 to 8 October 2021, organized by the Network of National Universities with Computer Science Degrees (RedUNCI) and the National University of Salta, under the title “*Propuesta para la construcción de un corpus jurídico utilizando Expresiones Regulares*” (Proposal for the construction of a legal corpus using Regulatory Expressions Results obtained) [1]. In this work, a theoretical proposal was presented to incorporate, in a legal corpus, references to dates and other common terms regularly used in the legal norm, by means of the Named Entity Recognition (NER) that make up the different judicial documents, using Regular Expressions (RE). RE are character strings that are used to describe or find patterns within other texts, using delimiters and syntax rules.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Author Proof

2 O. M. Sposito et al.

As expressed in the predecessor paper, jurisprudence has an important role as a source of law, because its conclusions support the application of the law in a specific case. The Argentinean judiciary produces every year a large number of rulings, files, among other things. These decisions are stored in documents, making this source of law ever larger, which drives professionals to spend more time to find relevant documents. Therefore, sophisticated computing techniques are needed to minimize search time and improve the relevance of retrieved documents.

The authors of this report belong to a group, which in the year 2021 presented a research project called “*Implementation of a Web System for Information Retrieval Oriented to Legal Documentation with the Parallelized Latent Semantic Indexing Process*”, through the Incentive Program for Research Teachers of the Secretariat of University Policies (PROINCE).

Within the stages to carry out the aforementioned project, the theory and practice of documentary analysis, conceptual indexing, the development of a matrix of terms and the term/document matrix, which presents rows that correspond to terms and columns to documents, in this case a vector of documents is represented as a bag of words. In other words, to represent the textual content of the documents, this proposal uses a data structure consisting of a matrix with two dimensions, in which the indexing terms that have been extracted after processing the documents are stored in the system. These matrixes are widely used in the area of information retrieval, where the bag-of-words hypothesis captures to some extent the subject matter of the document [2].

As mentioned above, this article presents, on the one hand, the proposal to incorporate the references of both dates and the legal norm, through the NER or extraction of entities, such as Files, Decrees, Agreements, Articles, Laws, and others, that make up the different judicial documents, by means of patterns defined by RE. As an extension, an experimental test is also described in order to validate the proposed solution with the concrete results obtained.

2 Research Background

Regarding the work on corpus construction using RE to solve named entities, the work developed by Haag, in his thesis: “*Recognition of named entities in legal domain text*” [3], focuses on the detection, classification and annotation of named entities (e.g., Laws, Resolutions or Decrees) for the InfoLEG¹ corpus, a database that contains the documents of all the laws of the Argentine Republic. It should be noted that the search pattern presented in this article is based on the format presented by Haag, although it should be noted that his work does not include dates.

For his master’s thesis, Duque Bedoya [4], presents a methodology to build a corpus for linguistic analysis, implementing a tagging system that includes the names of people, places, and dates by means of a computational tool. The information extraction processes include the automatic identification of such terms through the application of algorithms and heuristics used in digital libraries. The identification of events is carried out using the combination of the tags previously extracted from the corpus. The tool used for tagging

¹ <http://www.infoleg.gob.ar/>.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

was Unstructured Information Management Architecture (UIMA) a free application to implement linguistic resources using JAVA and C++ programming languages, being compatible with the Eclipse programming environment.

Regarding the construction of various corpora, in the doctoral thesis of Rodríguez Inés [5], “*El uso de corpus electrónicos para la investigación de terminología jurídica*”, an extensive list of the corpora available in Argentina and a detailed description on of more than 10 international multilingual corpora can be found. In addition, Cardellino’s paper [6], “*A Low-cost, High-coverage Legal Named Entity*”, can be mentioned. In this paper, an attempt is made to improve information extraction in legal texts by creating a legal named entity recognizer, classifier, and linker. The resulting tools and resources are open source and are aimed at developing a named entity recognizer, classifier and linker that exploits Wikipedia.

Another work worth mentioning is found in chapter two “*Regular Expressions, Text Normalization, Edit Distance*” of Jurafsky and Martin’s book “*Speech and Language Processing*” [7], where a very clear explanation of the use of RE is given. In addition, a tool for performing language processing using RE is introduced in a theoretical way, and defines how to perform basic text normalization tasks, including word segmentation and normalization, sentence segmentation and lemmatization.

Finally, Robaldo et al., in their paper “*Compiling Regular Expressions to Extract Legal Modifications, present a prototype to automatically identify and classify types of modifications in Italian legal text*” [8]. This prototype uses XML language to define a new set of rules to identify the type of modifications in a text. The rule-based semantic interpreter implements a RE-based pattern matching strategy.

The proposal being presented in this paper is inspired by several aspects of the literature consulted and implements them in a process where a term matrix including the NER and date formats is created.

3 About Information Retrieval Systems

An Information Retrieval System (IRS) [2, 9, 10] is a tool that interacts between a corpus and its users. Its effectiveness depends on the adequate control of the language of representation of the information elements and the searches of its users. To meet its objectives, according to Tolosa et al. [2], an IRS must perform the following basic tasks:

- Logical representation of documents and, optionally, storage of the original.
- Representation of the user’s need for information in the form of a query.
- Evaluation of the documents with respect to a query to establish the relevance of each one.
- Ranking of the documents considered relevant to form the “solution set” or response.
- Presentation of the response to the user.
- Feedback of the queries to increase the quality of the answer.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Author Proof

4 O. M. Sposito et al.

Robredo in [11], states that in any area of knowledge, meaningful terms can be used as descriptors to represent the content of written documents, in the processes of indexing and organizing information, as well as to formulate questions in the information retrieval process. Tolosa et al. in [2] state that the process can be divided into the following stages:

- Lexicographic analysis, words are extracted and normalized.
- Reduction (tokenization) of empty or high-frequency words.
- Lemmatization, words morphologically similar to a base or root form are reduced in order to increase the efficiency of a CRS.
- Selection of the terms to be indexed. Those simple or compound words that best represent the content of the documents are extracted.
- Assignment of weights or weighting of the terms that make up the indexes of each document.

With the advance of technology, the different communities generate an increasing volume of publications in different domains that are rapidly disseminated through different repositories. In this context, in order for users to find relevant publications for various purposes, the process of indexing these documents is the primary factor in achieving quality information retrieval and the consequent success of any search mechanism. Gil-Leiva in his paper explains why indexing is contextualized and provides a brief description of some of the most widely used automatic indexing systems [12]. With the above in mind, this work is framed in the lexicographic analysis within the process of an IRS. In this phase, the NER constitutes an independent tool for information extraction, which plays an essential role for a variety of applications related to natural language processing such as information retrieval.

4 Named Entity Recognition

According to [13] the term named entity “...is a word or sequences of words that are identified as the name of a person, organization, place, date, time, percentage, or amount...”. Therefore, NER aims to recognize and classify such entities in various natural language processing applications. Several works have been reviewed detailing different uses of RE to detect patterns within the text of a document [3, 14, 15]. In the area of NER, a common problem is to obtain relevant information related to some of the mentioned entities, so it becomes important to be able to extract and distinguish this type of elements from the whole set of words that compose a document.

Although some elements are relatively easy to identify by using patterns, e.g., dates or numerical data, there are other elements, such as persons, places, or organizations, that present other difficulties to be identified as belonging to a specific type. In an



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

IRS, a technique such as NER is very important, as it allows searching for very specific information in collections of documents, extracting and organizing the relevant information. In the work of Sánchez Pérez [13], it is mentioned that in recent years there has been extensive work on the development of NER systems to improve the performance of classifiers using machine learning techniques.

As stated in [1], one of the factors influencing the success of standardization in computing has been the use of RE, a language for specifying text search strings [16].

5 Regular Expressions

Patterns constructed as RE allow the recognition of complexly structured character strings. Their name comes from the mathematical theory on which they are based. In chapter 3 of the book “*Introduction to the theory of automata, languages and computation*” [17], the authors argue that REs can be thought of as a “programming language”, in which it is possible to write some important applications, such as text search or replacement applications. In fact, they are recognized by many programming languages, editors, and other tools. Therefore, ERs serve as the input language of many systems that process strings. Examples include the following:

1. Search commands such as the UNIX Grep² command or equivalent commands for locating strings in web browsers or text formatting systems. These systems employ an RE-like notation to describe the patterns the user wishes to locate in a file.
2. Lexical analyzer generators, such as Lex or Flex (a lexical analyzer is the component of a compiler that breaks down the source program into logical or syntactic units consisting of one or more characters that have a meaning). Logical or syntactic units include keywords (e.g., while), identifiers (e.g., any letter followed by zero or more letters and/or digits) and signs (e.g., ‘+’ or ‘<=’).

In other words, an RE is an algebraic notation for characterizing a set of strings. They are particularly useful for text search when we have a pattern and a corpus of texts to search. An RE search function will search the corpus and return all texts that match the defined pattern. From the guide in [18] the following example, explained in Table 1, has been developed: an RE can be used to check if an email is valid:

$$|^{\wedge}[\wedge-] + (\wedge[\wedge-]+)*@[A-Za-z0-9]+(\wedge[A-Za-z0-9]+)*(\wedge[A-Za-z]{2,})\$$" \quad (1)$$

² <https://www.gnu.org/software/grep/>.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Table 1. Description of an RE to validate an e-mail.

Expression	Meaning
<code>^</code>	<code>^</code> at the beginning of the RE, or at the beginning within the []
<code>[\w-]+</code>	The <code>+</code> symbol indicates that one or more characters must appear within square brackets <code>\w</code> indicates characters A to Z both upper and lower case, digits 0 to 9 and the symbol <code>_</code>
<code>(\.[\w-]+)*</code>	The <code>*</code> indicates that this group may appear 0 or more times. The email may optional-ly include a full stop followed by one or more of the characters in square brackets
<code>@</code>	The following must contain the <code>@</code> character
<code>[A-Za-z0-9]</code>	In the RE after the <code>@</code> must contain one or more characters that appear between the square brackets
<code>(\.[A-Za-z0-9]+)*</code>	Followed (optionally, 0 or more times) by a full stop and 1 or more characters in square brackets
<code>(\.[A-Za-z]{2,})</code>	Followed by a full stop and at least 2 characters appearing in square brackets
<code>\$</code>	Marks the end of an RE

To perform this process, a program written in the C#³ programming language is used and to solve the issue of RE, the REGEX library is used. C# is a programming language that is included in the .NET Platform and runs on the Common Language Runtime (CLR). The first language of importance for the CLR is C#, much of what is supported by the .NET platform is written in C#. This language is derived from C and C++, is modern, simple, and entirely object-oriented, and simplifies and modernizes C++ in the areas of classes, namespaces, method overloading and exception handling [19].

6 Test Development

This section presents the development of an experimental design test carried out in the context of the research. This aims to study the behavior of REs in the indexing process, in order to identify dates and named entities. The following paragraphs briefly describe the experiment carried out, followed by the methodology and also the parameters used. In order to carry out the tests, a corpus of 497 documents from a public body with similar characteristics, in terms of terminology used to legal documents was used (see Fig. 1).

Each of the documents has a structure similar to the one shown in Fig. 2, where dates in different formats can be distinguished, as well as other named entities. These make up the entries that are intended to be automatically identified and then normalised and incorporated into the repository, and finally used in the process of searching and retrieving the documents.

³ <https://docs.microsoft.com/en-us/dotnet/csharp/>.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

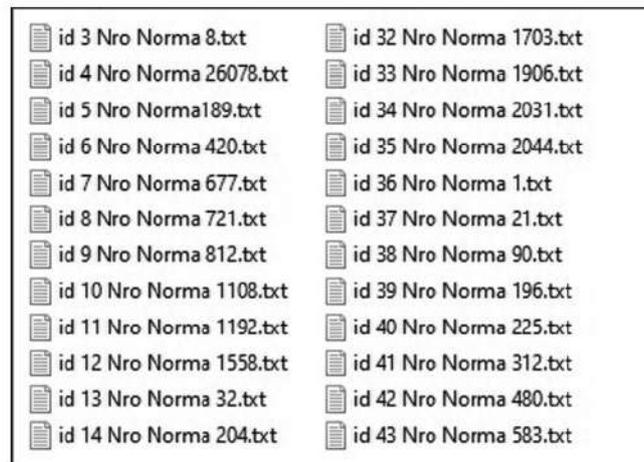


Fig. 1. Representation of the documents used in the experimentation.

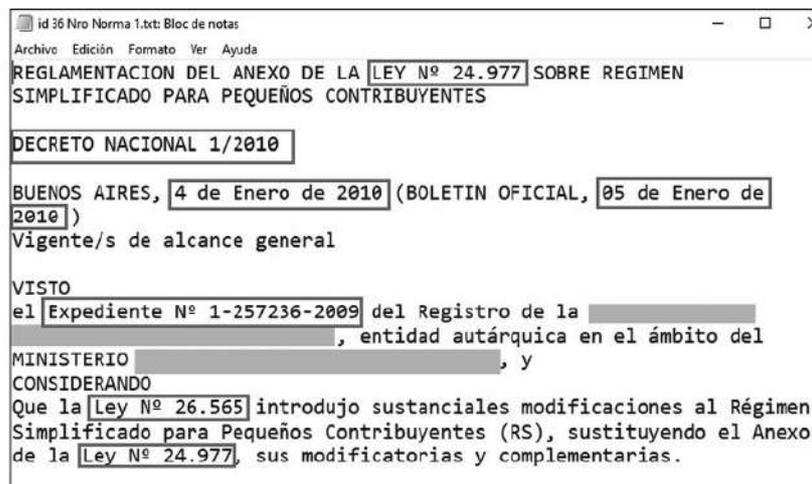


Fig. 2. Fragment of a document showing references to dates and named entities.

In agreement with [3] and also, based on the exploratory analysis carried out, the most common NER pattern is in the following form:

$$\langle \text{Entity Type} \rangle [\text{Nro}] \text{ or } [\text{N}^\circ] \langle \text{Number} \rangle [/ \langle \text{Year} \rangle] \quad (2)$$

where “Entity Type” is a part of the named categories. In order to build a table of terms such as the one intended for this work, a common problem is to obtain relevant information related to all the names of the current judicial regulations to be standardised, so it becomes important to be able to extract and distinguish this type of elements from the whole set of words that make up a document.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

8 O. M. Sposito et al.

Author Proof

In Fig. 3, a part of the pseudo code written in C# language and using the Regex library is shown. The following image shows how a breakpoint acts in the Visual Studio debugger. At this point the library recognizes in the selected paragraph, where a named entity is located. This identification is important to be able to normalise these names, and thus, to be able to incorporate them in a pre-established and uniform way.

```

foreach (Match palabra in Regex.Matches(texto, pattern))
{
    if (Regex.IsMatch(palabra.Groups[0].Value, decnorley2))
    {
        if (Regex.IsMatch(palabra.Groups[0].Value, fecha2))
        {
            palabra.Groups[0].Value
            campoFecha = palabra.Groups[0].Value.Trim().Split(camposplit,
                StringSplitOptions.RemoveEmptyEntries);
            tabaux = ControlarFecha(campoFecha[2].Trim(), campoFecha[4].Trim(), campoFecha[6].Trim());
        }
    }
}

```

Fig. 3. Fragment of the pseudo code to identify named entities.

In relation to date references, which are found within text strings, there are a variety of applications available [21, 22] that help to convert different date formats using RE. Below is a collection of useful RE for finding dates in 'dd/mm/yyyy or yyyy' or 'dd-mm-yyy or yyyy' format:

$$\text{RegEx1} : [0-9]{1, 2}[0-9]{1, 2}[0-9]{2, 4} \text{ or} \quad (3)$$

$$\text{RegEx2} : \{1, 2\}[\{1, 2\}[0-9]{1, 2}[0-9]{2, 4}] \quad (4)$$

Format 'Month, dd, ', e.g., '4 de julio de 2021'.

$$\begin{aligned} & (\text{Ene}(\text{?:ro})?\text{Feb}(\text{?:rero})?\text{Mar}(\text{?:zo})?\text{Abr}(\text{?:il})?\text{May}(\text{?:o})?|\text{Jun}(\text{?:io})? \\ & \text{Jul}(\text{?:io})?\text{Agost}(\text{?:o})?\text{Sep}(\text{?:tiembre})?\text{Oct}(\text{?:ubre})? \\ & \text{Nov}(\text{?:iembre})?\text{Dic}(\text{?:ciembre})?)\s+(\d{1,2})\s+(\d{4}) \end{aligned} \quad (5)$$

In Fig. 4, another fragment of the pseudo code is shown, in this case to identify a date format within a paragraph belonging to a document, using the Regex library.

```

foreach (Match palabra in Regex.Matches(texto, pattern))
{
    if (Regex.IsMatch(palabra.Groups[0].Value, decnorley4))
    {
        if (Regex.IsMatch(palabra.Groups[0].Value, fecha2))
    }
}

```

Fig. 4. Fragment of the pseudo code to identify date format labels with text.

The implemented indexing process can be summarized in the algorithm detailed in Table 2. Line 1 lists the inputs of the algorithm, where: D represents each of the documents to be processed that will be constantly executed, F the date REs, E the named entity REs, M is the term matrix and N is the maximum number of documents to



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Table 2. Summary of the algorithm

Algorithm 1: Proposed method to obtain dates and named entities from a set of documents.

```

1: Input:  $D, F, E, M$  y  $N$ .
2:  $s \leftarrow 0$ ;
3: while  $s < M$  do
4:   for  $p \in D_s$  do
5:     if  $p = F$  then
6:        $TF \leftarrow \text{get\_date}(p)$ ;
7:        $NF \leftarrow \text{normalize\_date}(TF)$ ;
8:     end if
9:      $\text{Matriz}[s, k] \leftarrow \text{valid\_if\_exists\_F}(NF)$ ;
10:    if  $p = E$  then
11:       $TE \leftarrow \text{get\_entity}(p)$ ;
12:       $NE \leftarrow \text{normalize\_entity}(TE)$ ;
13:    end if
14:     $\text{Matriz}[s, k] \leftarrow \text{valid\_if\_exist\_E}(NE)$ ;
15:  end for
16: end while

```

be processed. It is also necessary p , for each of the paragraphs composing a document D and the intermediate storages are represented by TF , NF , TE and NE .

The main loop occurs between lines 3 to 17, where the search and replace of the named dates and entities actually takes place. After being normalized and, after checking that they are only entered once in the matrix of terms, they are incorporated through a function.

7 Results Obtained

Throughout the project, some 6 REs were produced to identify some of the named entities for this experimentation and different date formats. Some of the REs made up covered more than one term to be searched for, as can be seen in Fig. 5.

```
String decnorley3 = "((E|e)xpediente|(E|e)xpte.|(L|l)ey|(D|d)ecreto|(N|n)orma)\\s*" + digito + "+";
```

Fig. 5. Fragment of the pseudo code to create an RE that finds the terms “Expediente”, “Ley”, “Decreto” or “Norma” (File, Law, Decree or Rule).

The document corpus contains a total of 1,279,205 terms. After running the whole process, it was possible to build the Table of Terms, whose structure is shown in Fig. 6.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

10 O. M. Sposito et al.

Author Proof

The table contains 14,218 terms identified without repetition. In the figure, it can be seen that the program builds the table by assigning a unique ID to each term. Accompanying the term is the number of times it appears in the processed corpus. This value is used by other processes for the weighting of each term. This is not detailed in this paper, but it can be deepened in the presented bibliography [2, 9–11].

```

TablaTerminos.txt: Bloc de notas
Archivo Edición Formato Ver Ayuda
Clave;Término;Ocurrencia en el corpus
0;reglamentacion;2
1;anex;4
2;ley;6
3;regim;4
4;simplific;4
5;pequeñ;4
6;contribuyent;4
7;decret;2
8;nacional;2
9;1/2010;1
10;air;2
11;4 de enero de 2010;1
12;boletin;2
13;oficial;2
14;05 de enero de 2010;1
  
```

Fig. 6. Fragment of the Table of Terms with their respective frequencies.

Table 3 presents a summary of the entries found in the processing of the corpus used for the experimentation, including the main named entities detected.

Table 3. Summary of named entities and date formats in the selected corpus.

Reference	Example of the text that appears	Number of times
Art. XX	Art 14	817
arts. XX y XY	Arts. 14 y 17	76
artículo XX	artículo 125	10,404
artículo XX Inciso XXX	artículo 75 inciso 22	853
Ley XXXX o Ley N° XXX	Ley 26.660 o Ley N° 24.977	12,650
Expediente XX XXX o expte. XXX	Expediente N° 1-257236-2009 expte. 20-00160/2000	1,490
Decreto XXX/XXXX	Decreto 1/2010	427



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

On the other hand, Tables 3 and 4 show the results of the occurrences found in the indexing process, in this case, for date formats, both numeric and text.

Table 4. Summary of the ENs and date formats in the selected corpus

Reference	Number of times	Reference	Number of times
31/12/2015	3058	12/9/69	31
2/12/1964	91	6-11-2009	9
30/4/1970	700	3-1-2001	13
4/2/1971	409	03-10-64	92
31/12/70	24	2-21-94	4
1/02/90	8	20-5-97	1

In Tables 3, 4 and 5 it is possible to visualize the number of different formats that can be found for the same entities in a given corpus. With the algorithm proposed to be implemented, the aim is to bring all these different formats to a uniform one, for example, in the case of dates, to use a format composed of two digits for the day, two digits for the month and four digits for the year.

Table 5. Summary of some of the lettered date formats found.

Reference	Example of the text that appears	Number of times
XX de mes de XXXX	9 de febrero de 2009	1152
XX mes de XXXX	21 octubre de 2005	6
mes -XX	feb-01	48
Mes, XX de XXXX	Abril, 9 de 2007	158

8 Conclusions and Future Work

This paper presents an algorithm for searching and replacing text strings using RE. The performance for incorporating dates and named entities in a term indexing process is analyzed.

Through the experience carried out, it could be proved that a great advantage when applying RE to find named entities is that once the correct expression is defined, and after the corresponding exhaustive search, the entities that match exactly with that pattern will be all the existing ones in the corpus. This is all the more important because legal texts are very structured, and entities appear with a certain regularity.

In turn, the REs are a simple tool to use and do not require more than encoding the expression of the pattern itself, and not training a model for its recognition.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Author Proof

12 O. M. Sposito et al.

However, a possible disadvantage is their limitation in finding only the predefined patterns, so it is not possible to find another named entity that does not match any of the existing REs.

As is well known, it is of utmost importance to count on the participation of domain experts to validate the terms coming from the corpus, often by carrying out manual checks, which imply a considerable effort.

Thus, in order to reduce the manual intervention effort and to improve the performance in the exhaustive search for patterns, in a next stage, we intend to explore a complementary technique to the RE. This technique is known as Hamming Distance, a similarity metric, which allows us to reduce the dimensionality (number of terms) of the corpus.

As a next step, it is expected to test the algorithm proposed in this work by implementing it in the self-developed IRS. Furthermore, it is planned to build a legal corpus that will be used to evaluate the response times of the IRS and the relevance of the retrieved documents.

Acknowledgment. Thanks are due to the Department of Engineering and Technological Research of the National University of La Matanza, this work is financed within the framework of the PROINCE C241 project.

References

1. Sposito, O., et al.: Propuesta para la construcción de un Corpus Jurídico utilizando Expresiones Regulares. In: 26th Argentine Congress of Computer Science, CACIC 2021, pp. 746–755. National University of Salta, Buenos Aires (2021). <http://sedici.unlp.edu.ar/handle/10915/129809>. Accessed 25 June 2021
2. Tolosa, G., Bordignon, F.: Introducción a la Recuperación de Información: Conceptos, modelos y algoritmos básicos (2008). <http://eprints.rclis.org/12243/1/Introduccion-RI-v9f.pdf>. Accessed 25 June 2021
3. Haag, K.: Reconocimiento de entidades nombradas en texto de dominio legal (2009). <https://rdu.unc.edu.ar/handle/11086/15323>. Accessed 06 Jan 2022
4. Duque Bedoya, E.: Metodología para la Extracción de Metadatos Semánticos de Textos en español utilizando procesamiento de Lenguaje Natural: Subaplicación Para La Identificación De Contextos Espaciales Y Temporales En Textos Que Describan Interacciones Entre Actores. Universidad Eafit Departamento de Informática y Sistemas (2009). https://repository.eafit.edu.co/bitstream/handle/10784/1261/erika_duque_2009.pdf;jsessionid=19D87B68BAFF2D7E3D4296A8C4E727A4?sequence=1. Accessed 06 Jan 2021
5. Rodríguez Inés, P.: El uso de corpus electrónicos para la investigación de terminología jurídica (2008). <https://www.tdx.cat/bitstream/handle/10803/286111/pri1de2.pdf?sequence=1>. Accessed 06 Jan 2021
6. Cardellino, C., et al.: A low-cost, high-coverage legal named entity (2017). <https://hal.archives-ouvertes.fr/hal-01541446/document>. Accessed 06 Jan 2021
7. Jurafsky, D., Martin, J.: Speech and language processing (2020). <https://web.stanford.edu/~jurafsky/slp3/2.pdf>. Accessed 06 Jan 2021
8. Robaldo, L., et al.: Compiling regular expressions to extract legal modifications (2012). <http://www.di.unito.it/~radicion/papers/robaldo12compiling.pdf>. Accessed 06 Jan 2021

Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

9. Kuna, H., Rey, M., Martini, E., Solonezen, L., Podkowa, L.: Desarrollo de un Sistema de Recuperación de Información para Publicaciones Científicas del Área de Ciencias de la Computación. *Revista Latinoamericana de Ingeniería de Software*, 107–114 (2014). <http://revistas.unla.edu.ar/software/article/view/81>. Accessed 06 Jan 2021
10. González, C.M.: La recuperación de información en el siglo XX. Revisión y aplicación de aspectos de la lingüística cuantitativa y la modelización matemática de la información (2008). <http://www.fuentesmemoria.fahce.unlp.edu.ar/tesis/te.350/te.350.pdf>. Accessed 25 June 2021
11. Robredo, J.: Otimização dos processos de indexação dos documentos e de recuperação da informação mediante o uso de instrumentos de controle terminológico. *Ciência Da Informação* **47**(1) (2019). <http://revista.ibict.br/ciinf/article/view/4431>. Accessed 25 June 21
12. Gil-Leiva, I.: SISA—automatic indexing system for scientific articles: experiments with location heuristics rules versus TF-IDF rules. *Knowl. Organ.* **44**, 139–162 <https://doi.org/10.5771/0943-7444-2017-3-139>
13. Sánchez Pérez, C.: Clasificación de Entidades Nombradas utilizando Información Global (2008). <https://inaoe.repositorioinstitucional.mx/jspui/bitstream/1009/564/1/SanchezPCR.pdf>. Accessed 06 Jan 2022
14. Cucatto, M.: El lenguaje jurídico y su desconexión con el lector especialista: El caso de a mayor abundamiento. *Letras de Hoje* **48** (1), 127–138 (2013). http://www.memoria.fahce.unlp.edu.ar/art_revistas/pr.9102/pr.9102.pdf. Accessed 06 Jan 2021
15. Dozier, C., Kondadadi, R., Light, M., Vachher, A., Veeramachaneni, S., Wudali, R.: Named entity recognition and resolution in legal text. In: Francesconi, E., Montemagni, S., Peters, W., Tiscornia, D. (eds.) *Semantic Processing of Legal Texts*. LNCS (LNAI), vol. 6036, pp. 27–43. Springer, Heidelberg (2010). https://doi.org/10.1007/978-3-642-12837-0_2
16. Seghiri, M.: Metodología protocolizada de compilación de un corpus de seguros de viajes: aspectos de diseño y representatividad. *Rla. Revista de lingüística teórica y aplicada* **49**(2), 13–30 (2011). <https://doi.org/10.4067/s0718-48832011000200002>. Accessed 06 Jan 2021
17. Hopcroft, J., Motwani, R., Ullman, J.: *Introducción a la teoría de autómatas, lenguajes y computación*. ISBN: 978-84-7829-088-8, p. 4. PEARSON Ed. S.A., Madrid (2007)
18. Stack Overflow Documentation: Aprendizaje de Expresiones Regulares. <https://riptutorial.com/Download/regular-expressions-es.pdf>. Accessed 06 Jan 2021
19. Cosio, L., Arrijoja, N.: *C#: Guía Total del Programador* (2010). ISBN 978-987-26013-5-5
20. Regular Expression 101. <https://regex101.com>. Accessed 06 Jan 2021
21. RegEx Testing. <https://www.regextester.com>. Accessed 06 Jan 2021

Propuesta para la construcción de un Corpus Jurídico utilizando Expresiones Regulares

Oswaldo Sposito¹, Ryckeboer Hugo¹, Viviana Ledesma¹, Gastón Procopio¹, Lorena Matteo¹, Cecilia Gargano¹, Julio Bossero¹, Edgardo Moreno¹, Victoria Saizar¹, Patricio Macias¹, Juan Ojeda¹, Fabio Quintana¹, Laura Conti², Sergio García³ y Gustavo Pérez Villar⁴

¹ Universidad Nacional de La Matanza. Departamento de Ingeniería e Investigación Tecnológicas. Florencio Varela 1903. San Justo. La Matanza. {sposito, hugor, vledesma, gprocopio, lmatteo, cgargano, jbossero, ej_moreno, vsaizar, pmacias, jmojeda}@unlam.edu.ar

² Universidad Nacional de La Matanza. Departamento Derecho y Ciencia Política. lconti@unlam.edu.ar

³ Palacio de Tribunales. Departamento Judicial de Morón. Alte. Brown. Piso 4. Morón. sergiogabriel.garcia@pjba.gov.ar

⁴ Subsecretaría de Tecnología Informática del Poder Judicial de la Provincia de Buenos Aires. Palacio de Justicia, avenida 13 entre 47 y 48, primer piso (La Plata). Argentina. gperez@scba.gov.ar

Abstract. En la última década, la construcción de corpus de distintas especialidades ha tenido un amplio desarrollo, debido en gran parte, por su incorporación en el proceso de recuperación de la información. Si bien, en el sistema jurídico argentino, existen varios buscadores de expedientes digitales, en este artículo se presenta una propuesta para incorporar, en un corpus jurídico, las fechas y las referencias de la norma jurídica, mediante el Reconocimiento de Entidades Nombradas (tales como Acordadas, Artículos, Leyes, entre otros), que componen los distintos documentos judiciales, utilizando Expresiones Regulares (ER). Estas cadenas de caracteres se utilizan para describir o encontrar patrones dentro de otros textos, empleando delimitadores y reglas de sintaxis. Se propone una metodología que permita identificar, clasificar y reemplazar estas entradas automáticamente, con el objetivo de ser normalizadas. Por último, se presenta una propuesta para incorporar en un algoritmo de Lematización, la codificación del proceso mencionado usando ER.

Keywords: Corpus, Expresiones Regulares, Sistema de Recuperación de Documento, Lematización, Reconocimiento de Entidades Nombradas

1 Introducción

Este trabajo, continúa con la línea de investigación y trabajo interdisciplinario entre especialistas del área jurídica provincial, técnicos de la Corte Suprema de la Provincia

de Buenos Aires e Investigadores de la Universidad Nacional de La Matanza (UNLaM). En el año 2020, el grupo abordó el análisis, diseño y construcción de una herramienta informática que ayuda a la sistematización y optimización de varios de los procesos judiciales que actualmente se realizan en forma manual o semiautomática en los juzgados de la provincia. La herramienta desarrollada, que se denomina *Experticia*¹ [1-2], pretende dar soporte a los operadores de la justicia en su decisión para la resolución de una causa. De esta manera se busca estandarizar el proceso de despacho de trámites, y a la vez agilizar y reducir los tiempos de carga, minimizando posibles errores como en el ingreso de datos. La información generada con *Experticia*, se almacena en el Sistema Informático de Gestión Asistida Multifuero (GAM), más conocido en el poder judicial como *Augusta*². Este aplicativo fue creado con la finalidad de dotar al Poder Judicial de la Provincia de Buenos Aires, de una plataforma informática única e integral, que permita homogeneizar la gestión administrativa diaria de las causas. En el campo del derecho, la jurisprudencia tiene un papel importante como fuente de derecho; porque sus conclusiones apoyan la aplicación de la ley en un caso específico. El poder judicial argentino produce una gran cantidad de dictámenes, expedientes, etc. cada año, estas decisiones se guardan en documentos, haciendo que esta fuente de derecho sea cada vez mayor, lo que impulsa a los profesionales del derecho a dedicar más tiempo a la búsqueda de documentos relevantes. Por lo tanto, se necesitan técnicas sofisticadas de cómputo para minimizar el tiempo de búsqueda y mejorar la pertinencia de los documentos recuperados. Por este motivo, en el año 2021 se presentó el proyecto de investigación “*Implementación de un Sistema Web de Recuperación de la Información Orientado a Documentación Jurídica con el Proceso de Indexación Semántica Latente Paralelizado*”, por el Programa de Incentivos para Docentes Investigadores de la Secretaría de Políticas Universitarias (PROINCE). Dentro de las etapas para llevar adelante este trabajo, se encuentra la construcción de un corpus jurídico. Varias investigaciones se centraron en remarcar la importancia que tiene la lingüística de corpus como herramienta de ayuda para analizar terminología y fraseología especializada en su contexto original de producción. Hoy, gran parte de los corpus, se compilan a partir de textos electrónicos y la web se ha convertido en una gran fuente de contenidos textuales de todo tipo [3,4].

Un Sistema de Recuperación de Información (SRI) [5-7] es una herramienta que interactúa entre un corpus y sus usuarios. Su efectividad depende del adecuado control del lenguaje de representación de los elementos de información y las búsquedas de sus usuarios. Para cumplir con sus objetivos, según Gabriel H. Tolosa y otros [6], un SRI debe realizar las siguientes tareas básicas:

- Representación lógica de los documentos y – opcionalmente – almacenamiento del original.
- Representación de la necesidad de información del usuario en forma de consulta.
- Evaluación de los documentos respecto de una consulta para establecer la relevancia de cada uno.

¹<https://noficcionweb.com.ar/la-suprema-corte-bonaerense-y-la-unlam-avanzan-en-la-automatizacion-de-la-justicia/>

²<https://www.scba.gov.ar/paginas.asp?id=39889>

- Ranking de los documentos considerados relevantes para formar el “conjunto solución” o respuesta.
- Presentación de la respuesta al usuario.
- Retroalimentación de las consultas (para aumentar la calidad de la respuesta).

La arquitectura de un SRI que permite realizar las tareas básicas enumeradas en el párrafo anterior se puede observar en la Figura 1:

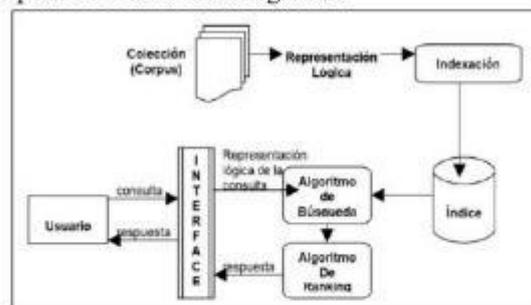


Fig. 1 – Arquitectura de un SRI. Fuente [6]

Como se puede apreciar en la Figura 1, el conjunto de todos los documentos sobre los que se deben realizar operaciones de RI se denomina corpus, colección de documentos o base de datos documental. El proceso de indexación genera la representación lógica de los documentos y las estructuras de datos denominadas índices, estas estructuras son las que permiten que se realicen búsquedas eficientes. El algoritmo de búsqueda se encarga de procesar la consulta de un usuario y de buscar en el índice cuáles documentos se asemejan a la consulta. A continuación, el algoritmo de ranking determina la relevancia de cada documento de acuerdo al nivel de semejanza y retorna un subconjunto con los documentos más relevantes. La interface de usuario permite que éste especifique la consulta, visualice la respuesta y realimente el sistema para mejorar la calidad de las respuestas.

Uno de los principales procesos de un SRI es la indexación y según Tolosa en [5] se puede dividir en las siguientes etapas:

- Análisis lexicográfico: Se extraen las palabras y se normalizan.
- Reducción (Tokenización) de palabras vacías o de alta frecuencia.
- Lematización: Se reducen palabras morfológicamente parecidas a una forma base o raíz, con la finalidad de aumentar la eficiencia de un SRI.
- Selección de los términos a indexar: Se extraen aquellas palabras simples o compuestas que mejor representan el contenido de los documentos.
- Asignación de pesos o ponderación de los términos que componen los índices de cada documento.

Si bien, estos corpus contienen información del mismo dominio, esta es habitualmente del tipo textual. En un expediente judicial, se pueden encontrar, además, referencias de fechas, en distintos formatos, como así también, referencias a diferentes fuentes judiciales³, como se puede ver en el párrafo siguiente: “... de la Ley Nº 25.188, o el Decreto 41/99, o la Ley Nº 25.164 –que rige únicamente para el

³ <https://www.conicet.gov.ar/wp-content/uploads/Ley-25164-De-Marco-de-Regulación-de-Empleo-Público-Nacional.pdf>

personal...su función (artículo 3° de la Ley N° 25.188; art. 47 del Decreto 41/99 y art. 30 de la Ley N° 25.164..."

Los usuarios de distintos ecosistemas, que utilizan corpus *“ad hoc”*, demandan cada vez más servicios, que les permitan extraer información recuperada, usando reconocimiento y categorización de Entidades Nombradas (EN o NE del inglés Named Entity) de fácil integración en aplicaciones del Procesamiento del Lenguaje Natural (PLN) [8]. En este escrito, se presenta una propuesta, que se centra, en la detección, clasificación y normalización de fechas y entidades nombradas (como Acordadas, Artículos, Leyes, Resoluciones o Decretos, etc.) que componen la normativa jurídica, mediante el uso de Expresiones Regulares (ER). La idea es poder incorporar esta información al corpus, en el proceso de la Lematización de los documentos. Esta es una de las etapas de Preprocesamiento en un SRI [6]. Por su parte la técnica de Reconocimiento de EN (REN) se divide generalmente en dos pasos [8]: la delimitación de entidades nombradas y su posterior clasificación. En este trabajo solo nos enfocamos en la primera. Esta propuesta podría incrementar la eficacia en la equiparación entre los términos del documento y los términos de la pregunta del usuario.

2 Trabajos relacionados

Se han desarrollado muchos trabajos relacionados a la temática en cuestión. Diversas propuestas han sido consideradas para la construcción de Corpus jurídicos [9-10], en este último artículo, *“El uso de corpus electrónicos para la investigación de terminología jurídica”*, se encuentra una extensa lista de los corpus disponibles en Argentina y una descripción detallada de mas de 10 corpus multilingües internacionales. Respecto a los trabajos sobre construcción de corpora utilizando Expresiones Regulares para resolver las Entidades Nombradas, tenemos el trabajo desarrollado por Karen Haag, en su tesis: *“Reconocimiento de entidades nombradas en texto de dominio legal”* [8], el escrito se centra en la detección, clasificación y anotación de entidades nombradas (como Leyes, Resoluciones o Decretos, entre otros) para el corpus de *InfoLEG*, una base de datos que contiene los documentos de todas las leyes de la República Argentina. Además, se pueden mencionar, entre otros, el trabajo de Cristian Cardellino [11] *“A Low-cost, High-coverage Legal Named Entity”*. En este documento, se intenta mejorar la extracción de información en textos legales mediante la creación de un reconocedor, clasificador y vinculador de entidad con nombre legal. Otro trabajo que merece ser nombrado se encuentra en el capítulo segundo: *“Regular Expressions, Text Normalization, Edit Distance”* del libro de D. Jurafsky y J. H. Martin: *“Speech and Language Processing”* [12], donde se presenta una herramienta para realizar tareas básicas de normalización de texto que incluyen segmentación y normalización de palabras, segmentación de oraciones y derivación. Por último, se puede nombrar, además, el trabajo de Robaldo, Livio y otros: *“Compiling Regular Expressions to Extract Legal Modifications”*, que presenta un prototipo para identificar y clasificar automáticamente tipos de modificaciones en el texto legal italiano [13].

Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

3 Expresiones Regulares

Uno de los éxitos no reconocidos en la estandarización de la informática ha sido la utilización de ER, un lenguaje para especificar cadenas de búsqueda de texto [12]. Este lenguaje práctico se usa en todos los lenguajes de computadora, procesadores de texto y herramientas de procesamiento de texto como las herramientas Unix `grep`⁴ o Emacs⁵. Formalmente, una expresión regular es una notación algebraica para caracterizar un conjunto de cadenas.

Son particularmente útiles para la búsqueda en textos, cuando tenemos un patrón y un corpus de textos donde buscar. Una función de búsqueda de expresiones regulares buscará en el corpus y devolverá todos los textos que coincidan con el patrón. El corpus puede ser un solo documento o una colección. Por ejemplo, la herramienta de línea de comandos de Unix `grep` toma una expresión y devuelve cada línea del documento de entrada que coincide con la expresión. En otras palabras, son notaciones simbólicas que se utilizan para identificar caracteres mediante una secuencia en el texto. En cierto modo, se parecen al método comodín del comando de Linux "Shell" para hacer coincidir los nombres de archivo y ruta, pero a una escala mucho mayor. Una expresión regular es un patrón capaz de reconocer o filtrar cadenas de caracteres según ciertos criterios. El uso de comodines "*" para indicar cadenas de caracteres cualesquiera o "?" para indicar un carácter único son ejemplos de uso de expresiones regulares. Así, el patrón "aba*" reconoce cadenas como "abaco", "abajo", "abatimiento", "abalorio", "aba-23"; el patrón "do?" reconoce cadenas como "doy", "dos", "dot", "don", "do\$"; el patrón "aba*.txt" describe el conjunto de cadenas de caracteres que comienzan con "aba", contienen cualquier otro grupo de caracteres y luego la cadena ".txt". Los patrones construidos como ER que permiten reconocer cadenas de caracteres de estructura compleja. Las ER son utilizadas para realizar búsquedas o sustituciones en textos [14]. Estas son reconocidas por muchos lenguajes de programación, editores y otras herramientas. Su nombre proviene de la teoría matemática en la que se basan.

3.1 Expresiones Regulares básicas

Una ER determina un conjunto de cadenas de caracteres. Un miembro de este conjunto de cadenas se dice que aparea, equipara o satisface la expresión regular.

Con la idea de mostrar unos ejemplos, en la tabla 1, se pueden ver las ER que componen el conjunto de ER Elementales que aparean con un único carácter [14], en este mismo documento, se encuentra un tutorial del tema.

Tabla 1. Resumen de las ER Elementales que aparean con un único carácter [14].

Expresión	Aparea con
<code>c</code>	ER que aparea con el carácter ordinario <code>c</code>
<code>.</code>	(punto) aparea con un carácter cualquiera excepto nueva línea
<code>[abc]</code>	ER de un carácter que aparea con uno de <code>a</code> , <code>b</code> , <code>c</code>

⁴ <https://www.gnu.org/software/grep/>

⁵ <http://www.gnu.org/software/emacs/>

[^abc]	ER de un caracter que no sea uno de a, b, c
[0-9][a-z][A-Z]	ERs de un caracter que aparezcan con cualquier caracter en el intervalo indicado El signo "-" indica un intervalo de caracteres consecutivos
\e	ER que aparezca con alguno de estos caracteres (en lugar de la e):
	. * [\ cuando no están dentro de []
	^ al principio de la ER, o al principio dentro de []
	\$ al final de una ER
/	usado para delimitar una ER

Por lo general, se encontrará el nombre abreviado como "Regex" o "Regexp". En un editor de texto como EditPad Pro⁶ o una herramienta de procesamiento de texto especializada como PowerGREP⁷, puede usar la expresión regular como la siguiente:

«\b[A-Z0-9._%+-]+@[A-Z0-9.-]+\.[AZ]{2,4}\b» (1)

para buscar una dirección de correo electrónico. Cualquier dirección de correo electrónico, para ser exactos.

4 Reconocimiento de Entidades Nombradas

Encontramos en [15] una definición sobre el término Entidad Nombrada "...es una palabra o secuencias de palabras que se identifican como nombre de persona, organización, lugar, fecha, tiempo, porcentaje o cantidad.". El REN, tiene como objetivo el reconocer y clasificar nombres de personas, lugares, organizaciones o cantidades, en distintas aplicaciones del Procesamiento del Lenguaje Natural. A partir de la bibliografía consultada [8-11]. En estos trabajos se muestran distintos usos de ER para detectar patrones dentro del texto de un documento.

En el área del REN, un problema común es obtener información relevante relacionada con nombres de personas, lugares u organizaciones, por lo cual se vuelve importante el poder extraer y distinguir este tipo de elementos de todo el conjunto de palabras que componen a un documento. Aún cuando algunos elementos son relativamente fáciles de identificar, mediante el uso de patrones (por ejemplo: fechas o datos numéricos) existen otros elementos, como personas, lugares u organizaciones, que presentan otras dificultades para ser identificados como pertenecientes a un tipo específico. En un SRI, una técnica como el REN, es muy importante, ya que permite buscar información muy concreta en colecciones de documentos, extrayendo y organizando la información relevante [15]. En el trabajo de Sánchez Pérez, se menciona que en los últimos años se ha trabajado ampliamente en el desarrollo de sistemas de REN para mejorar el desempeño de clasificadores utilizando técnicas de aprendizaje automático.

⁶ <https://www.editpadpro.com/>

⁷ <https://www.powergrep.com/>

5 Bases metodológicas

Con el propósito de elaborar una propuesta orientada a la incorporación de datos en formato fecha y de entidades nombradas (Leyes, Acordadas, Decretos, Artículos, etc.), usando ER, en un corpus, utilizamos un texto público de Pedido de Libertad Condicional (PLC), disponible en [16]. En este documento se pueden observar cómo aparecen las referencias mencionadas en el texto (Fig.2).

En similares términos todas las constituciones mantuvieron disposiciones similares, el Art. 117 en la Constitución de 1819, el Art. 170 en la de 1826 y el Art. 18 en la de 1853-1860.
 Esta pauta rectora se ha visto enriquecida con la incorporación de la normativa internacional sobre Derechos Humanos (artículo 75, inciso 22 de la Constitución Nacional), en particular el Art. 5º, apartado 6º de la Convención Americana sobre Derechos Humanos; el art. 10, apartado 3º del Pacto Internacional de Derechos Civiles y Politicos.
 La Ley 24.660 en su artículo 1º declara "La ejecución de la pena privativa de libertad, en todas sus modalidades, tiene por finalidad lograr que el condenado adquiera la capacidad de comprender y respetar la ley procurando su adecuada reinserción social, promoviendo la comprensión y el apoyo de la sociedad".

Fig. 2. Extracto del PLC. Distintas formas de entidades nombradas.

En el documento, usado de ejemplo, de casi nueve carillas, se puede contabilizar la cantidad de veces y distintos formatos, en que se encuentran estas referencias.

Tabla 2. Resumen de las EN y los formatos de fechas que figuran en el PLC.

Referencia	Ejemplo del texto que aparece	Cantidad de veces
Art. XX	Art 14	11
arts. XX y XY	arts 14 y 17	14
artículo XX	artículo 5	4
artículo XX Inciso	artículo 75 inciso 22	4
Ley XXXX	Ley 26.660	6
Fecha formato (dd/mm/aaaa)	24/11/1993	4
Fecha formato (dd de mes de aaaa)	27 de octubre de 2006	2
Fecha formato AAAA	1993	3

En coincidencia con [8] y también, en base a un análisis exploratorio del PLC, el patrón de REN más común, se encuentra en la siguiente forma:

$$\langle \text{Tipo Entidad} \rangle [\text{Nro}] \langle \text{Número} \rangle [/ \langle \text{Año} \rangle] \quad (2)$$

Dónde el "Tipo Entidad" es una parte de las categorías nombradas.

En la construcción de un corpus como el propuesto, para este trabajo, un problema común es obtener información relevante relacionada con todos los nombres de la normativa a normalizar, por lo cual se vuelve importante el poder extraer y distinguir este tipo de elementos de todo el conjunto de palabras que componen a un documento.

En el trabajo de Karen Haag [8], se desarrollan todas las entidades nombradas que se utilizan en el poder judicial. Algunos elementos son relativamente fáciles de identificar, mediante el uso de patrones (por ejemplo: fechas o datos numéricos). Existen muchas aplicaciones [17-18] que ayudan a convertir distintos formatos de fecha en ER. A continuación, se muestra una lista de algunas de las variantes que se pueden encontrar en este conjunto de datos:

- 20/04/2009; 20/04/09; 20/4/09; 3/04/09

- 20 de marzo de 2009; 20 de mar de 2009
- Febrero de 2009; septiembre del 09; octubre 2010
- 6/2008; 12/09 o 2009

A continuación, se muestra una colección de ER útiles para encontrar fechas:

- **Formato (dd/mm/aa o aaaa o dd-mm-aa o aaaa)**
RegEx1: `[0-9]{1,2}[\W-][0-9]{1,2}[\W-][0-9]{2,4}` o (2)
RegEx2: `\d{1,2}[\W-]\d{1,2}[\W-]\d{2,4}` (3)
- **Formato 'Mes, dd, aaaa', Por ejemplo, '4 de julio de 2021'.**
`(Ene(?:ro)?|Feb(?:rero)?|Mar(?:zo)?|Abr(?:il)?|May|Jun(?:io)?|Jul(?:io)?|Agost(?:o)?|Sep(?:tiembre)?|Oct(?:ubre)?|Nov(?:iembre)?|Dic(?:ciembre)?)\s+(\d{1,2})\s+(\d{4})` (4)

6 Lematización

En los SRI, la lematización (Stemming en Inglés) es una técnica empleada en la recuperación de datos en los SRI, que sirve para reducir variantes morfológicas de la forma de una palabra a raíces comunes o lexemas; con el fin de mejorar la habilidad de los motores de búsqueda para mejorar las consultas en documentos. Básicamente, este consiste en remover el plural, el tiempo, o los atributos finales de las palabras [19,20]. Cuando se realiza la extracción de palabras de un texto se obtiene una gran cantidad de entradas con formas verbales conjugadas y variantes de concordancia. Logrando la reducción morfológica de todas estas variantes se busca que el usuario recupere tanto los textos que contienen sus términos de búsqueda, como aquellos que contienen las formas derivadas de esos términos. Los algoritmos de lematización más conocidos son: Lovins⁸(1968), Porter⁹ (1980) y Paice¹⁰ (1990). La descripción y comparación de estos y otros algoritmos menos conocidos, se encuentran desarrollados en el trabajo "*Comparative Study of Truncating and Statistical Stemming Algorithms*" en [21]. Todos eliminan "los finales" de las palabras en forma iterativa, y requieren de una serie de pasos para llegar a la raíz, pero no requieren "a priori" conocer todas las posibles terminaciones. Originalmente todos fueron hechos para el inglés, y se diferencian en la eficiencia del código y la elección de sufijos que identifican y eliminan. Esto es solo un ejemplo de la forma en que operan estos algoritmos. El trabajo de Porter¹¹, fue tomado como base por muchos investigadores [22]. El algoritmo¹² sirve para reducir variantes morfológicas de las formas de una palabra a raíces comunes o lexemas; mediante una sucesión de reglas que aplica sobre cada palabra. En esta memoria se presenta una codificación utilizando la librería Regex de .Net¹³. El ejemplo utiliza el método de *Regex.Replace* para reemplazar fechas con el formato mm/dd/aa por fechas con el formato dd-mm-aa.

⁸ <http://snowball.tartarus.org/algorithms/lovins/stemmer.html>

⁹ <https://tartarus.org/martin/PorterStemmer/>

¹⁰ <https://www.scientificpsychic.com/paice/paice.html>

¹¹ <https://tartarus.org/martin/index.html>

¹² <https://tartarus.org/martin/PorterStemmer/def.txt>

¹³ <https://docs.microsoft.com/es-es/dotnet/standard/base-types/regular-expressions?redirectedfrom=MSDN>

```

using System;
using System.Globalization;
using System.Text.RegularExpressions;
public class Class1
{
    public static void Main()
    {
        string dateString =
        DateTime.Today.ToString("d",
        DateTimeFormatInfo.InvariantInfo);
        string resultString = MDYToDMY(dateString);
        Console.WriteLine("Converted {0} to {1}.",
        dateString, resultString);
    }
    static string MDYToDMY(string input)
    {
        try { return Regex.Replace(input,
        @"\b(?:\d{1,2})/(?:\d{1,2})/(?:\d{2,4})\b",
        "${day}-${month}-${year}",
        RegexOptions.None,
        TimeSpan.FromMilliseconds(150)); }
        catch (RegexMatchTimeoutException) { return
        input; } }
}

```

7 Conclusiones y Trabajo Futuro

En este trabajo se propuso implementar, en un algoritmo de lematización, el uso de Expresiones Regulares para incorporar fechas y Entidades Nombradas a un corpus jurídico, para luego ser empleado en un Sistema de Recuperación de Información. Se estudiaron las expresiones regulares, que proporcionan un método eficaz y flexible para procesar texto.

Dentro de las tareas a desarrollar se puede mencionar:

- Incorporar la codificación propuesta al SRI implementado por el proyecto PROINCE mencionado en la introducción.
- Utilizar el algoritmo de Porter y analizar otros Lematizadores.
- Estudiar otras librerías existentes de ER.
- Realizar una clasificación de todas las EN dentro de la norma jurídica Argentina.

Referencias

1. Sposito O. y otros. Sistema Experto para Apoyo del Proceso de Despacho de Trámites de un Organismo Judicial. Jornadas Argentinas de Informática (JAIIO 2020).
2. Sposito O. y otros. Metodológica para evaluar un modelo de Justicia Predictiva". Trabajo presentado en CONAII SI 2020.
3. Capello, A. Sistema de recomendación para textos legales. (2018) En Línea: <http://hdl.handle.net/11086/11342> Fecha de consulta: 25/6/21

4. Moreno A. Internet como fuente para la compilación de corpus jurídicos (2013) CES Felipe II (UCM) En línea: <http://www.cesfelipesecondo.com/revista/Articulos2013/Art%C3%A9culoArsenioAndrade.pdf> Fecha de consulta: 25/6/21
5. Kuna, H., Rey, M., Martini, E., Solonezen, L. & Podkowa, L. Desarrollo de un Sistema de Recuperación de Información para Publicaciones Científicas del Área de Ciencias de la Computación, *Revista Latinoamericana de Ingeniería de Software*, (2014). 2(2): 107-114.
6. Tolosa G. & Bordignon, F. Introducción a la Recuperación de Información: Conceptos, modelos y algoritmos básicos. Universidad Nacional de Luján, Argentina, (2008). En línea: <http://eprints.rclis.org/12243/1/Introduccion-RI-v9f.pdf>. Fecha de consulta: 25/6/21
7. González, C. M. La recuperación de información en el siglo XX. Revisión y aplicación de aspectos de la lingüística cuantitativa y la modelización matemática de la información U. N. de La Plata. (2008) Disponible en: <http://www.fuentesmemoria.fahce.unlp.edu.ar/tesis/te.350/te.350.pdf>. Fecha de consulta: 25/6/21
8. Karen Haag. Reconocimiento de entidades nombradas en texto de dominio legal. Córdoba, Argentina (2019). Recuperado el 01/08/2019 de: <https://rdu.unc.edu.ar/handle/11086/15323>
9. Cucatto M, El lenguaje jurídico y su desconexión con el lector especialista: El caso de a mayor abundamiento. *Letras de Hoje*, 48 (1), 127-138. (2013). En *Memoria Académica*. Disponible en: http://www.memoria.fahce.unlp.edu.ar/art_revistas/pr.9102/pr.9102.pdf Fecha de consulta: 25/6/21
10. El uso de corpus electrónicos para la investigación de terminología jurídica. Disponible en: <http://www.bibliotecact.com.ar/PDF/08118.pdf>. Fecha de consulta: 25/6/21
11. Cardellino C. y otros. A Low-cost, High-coverage Legal Named Entity. (2017) En: <https://hal.archives-ouvertes.fr/hal-01541446/document>. Fecha de consulta: 25/6/21
12. Jurafsky, D. & Martin, J. *Speech and Language Processing*. (2020) En línea: <https://web.stanford.edu/~jurafsky/slp3/2.pdf>. Fecha de consulta: 25/6/21
13. Robaldo, L. y otros. Compiling regular expressions to extract legal modifications. 250. 133-141. 10.3233/978-1-61499-167-0-133. (2012).
14. William Shotts. *The Linux Command Line. (Third Internet Edition)*. A LinuxCommand.org Book. (2016). En línea: <https://filedn.com/liGIo7rEUfzfmU4MQdhIKrh/Cursos/CursoBasicoLinux/ExpresionesRegulares.pdf>. Fecha de consulta: 25/6/21
15. Sánchez Pérez C. Clasificación de Entidades Nombradas utilizando Información Global. (2008). En línea: <https://inaoe.repositorioinstitucional.mx/jspui/bitstream/1009/564/1/SanchezPCR.pdf>. Fecha de consulta: 25/6/21
16. *Revista Pensamiento Penal*. <http://www.pensamientopenal.com.ar/system/files/2016/06/miscelaneas43506.pdf#viewer.action=download>. Fecha de consulta: 25/6/21
17. <https://regex101.com/>
18. <https://www.regextester.com/>
19. Martínez Méndez, F. Recuperación de información: modelos, sistemas y evaluación. Disponible en: <https://digitum.un.es/digitum/bitstream/10201/4316/1/libro-ri.pdf>. (2004) Último acceso: 20/07/2021.
20. Herrero Pascual, Cristina. (2010). Manual de indización: teoría y práctica. *Investigación bibliotecológica*, 24(52), 239-240. http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0187-358X2010000300010&lng=es&tlng=es. Último acceso: 20/07/2021.
21. Figuerola C. y otros (2000) Diseño de un motor de recuperación de la información para uso experimental y educativo. Univ. de Salamanca. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=555288>. Último acceso: 20/07/2021.
22. Bordignon F., W. Panessi. Procesamiento de variantes morfológicas en búsquedas de textos en castellano. *Revista Interamericana de Bibliotecología*, ISSN 0120-0976, Vol. 24, N° 1 (ENE-JUN), 2001, págs. 69-88. <https://dialnet.unirioja.es/servlet/articulo?codigo=4291340>. Último acceso: 20/07/2021.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLAM
Versión	5
Vigencia	03/9/2019

Implementación de un lematizador para la lengua española

Oswaldo Sposito¹, Hugo Ryckeboer¹, Julio Bossero¹, Edgardo Moreno¹, Viviana Ledesma¹, Gastón Procopio¹, Lorena Matteo¹, Cecilia Gargano¹, Victoria Saizar¹, Patricio Macias¹, Juan Ojeda¹, Fabio Quintana¹, Laura Conti², Sergio García³ y Gustavo Pérez Villar⁴

¹ Universidad Nacional de La Matanza. Departamento de Ingeniería e Investigaciones Tecnológicas. Florencio Varela 1903. San Justo. La Matanza.

{sposito, hugor, jbossero, ej_moreno, vledesma, gprocopio, lmatteo, cgargano, vsaizar, pmacias, fquintana, jmojeda}@unlam.edu.ar

² Universidad Nacional de La Matanza. Departamento Derecho y Ciencia Política. lconti@unlam.edu.ar

³ Palacio de Tribunales. Departamento Judicial de Morón. Alte. Brown. Piso 4. Morón.
sergiogabriel.garcia@pjba.gov.ar

⁴ Subsecretaría de Tecnología Informática del Poder Judicial de la Provincia de Buenos Aires. Palacio de Justicia, avenida 13 entre 47 y 48, primer piso (La Plata). Argentina. gperez@scba.gov.ar

Resumen

El proceso de lematización se ha explorado ampliamente, sobre todo, por su aplicación en los Sistemas de Recuperación de Información (SRI). Se utiliza para la reducción de variantes de términos equivalentes semánticamente, llevándolos a una forma normalizada. Identifican un representante canónico para un conjunto de formas de palabras relacionadas. Para ello se eliminan las partes no esenciales de las palabras (sufijos, prefijos) para reducirlos a su parte original (lema). Esto mejora el proceso de indexar los documentos según su temática, ya que estos se agrupan por sus raíces. Las dificultades para desarrollar un algoritmo de este tipo es identificar y eliminar afijos, ya que cada idioma tiene características y reglas gramaticales únicas.

En este trabajo se modifica un lematizador, para el idioma español, basado en el algoritmo de Porter. Las modificaciones implementadas aumentan casi un 26% la obtención de lemas correctos.

Se pone a disposición la codificación de los algoritmos y los lotes de términos con sus respectivos lemas de prueba.

Contexto

El presente trabajo, es una continuación de los proyectos de investigación que se llevan adelante en la Universidad Nacional de La Matanza (UNLAM) del tipo PRONCE (Programa de Incentivos para Docentes Investigadores) de la Secretaría de Políticas Universitarias. Especialmente el trabajo titulado "Implementación de un Sistema de Recuperación de la Información", que se desarrolló en el período 2013-2014. Como resultado de este trabajo, se construyó íntegramente un prototipo de un Sistema de Recuperación de Información (en adelante SRI) con interfaz de aplicación de escritorio. Luego sobre la misma temática se realizaron, en orden cronológico, las siguientes investigaciones relacionadas con este tema:

"Optimización de la Recuperación de Documentos usando como Técnica base el ISL", período 2015-2016; "Uso de Minería de Datos para Acelerar la Recuperación de Documentos", período 2017-2018 y "Resolución Eficiente de la Descomposición en Valores Singulares en una Arquitectura Híbrida y su Posterior Inserción en un Sistema de Recuperación de Información", en el período 2019-2020.

1. Introducción

Si bien existen numerosas definiciones del término "Recuperación de información" (RI o IR, de *Information Retrieval* en inglés), algunos autores [1-2], coinciden en definirla como la aplicación de la tecnología informática para procesar información, incluye su adquisición, organización, recuperación y distribución. Por su parte el objetivo principal de un SRI, es básicamente organizar una colección de documentos, recibir consultas del usuario (que expresan textualmente su necesidad de información), procesarlas y devolver al usuario tandas de documentos empezando por los que su algoritmo considera más relevantes y un mínimo de documentos no relevantes (aquellos que, por la ineficacia del sistema, se consideran incorrectamente como relevantes, pero no de interés para el usuario) [3,4].

La RI, como se expresa en [5], tienen sus orígenes en las bibliotecas y centros de documentación en los que se requerían búsquedas bibliográficas de libros y artículos de revista. Debido a motivos históricos, los documentos en esos centros se representan utilizando un conjunto de términos índice o palabras clave. En la actualidad todavía existen fichas (manuales o electrónicas) en las que se rellenan los campos apropiados con esa información. En esos campos se incluyen datos como el título, autor, fecha de publicación, etc., del documento en cuestión. Pero también se incluyen otros términos que dan una indicación de su contenido, y que normalmente quedan reflejados en



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

el campo materia. Uno o varios especialistas asignan la materia de acuerdo con criterios más o menos subjetivos. Los usuarios que consultan el sistema de recuperación para buscar información deben traducir su necesidad informativa en una consulta adecuada al sistema de recuperación. Esto supone utilizar un conjunto de términos que expresen semánticamente su necesidad. En sistemas tradicionales también es habitual utilizar operadores booleanos para conectar varios criterios de búsqueda por campos diferentes. Como disciplina, la RI tiene pocos años, pero ha experimentado un rápido desarrollo, debido a la aparición de los motores de búsqueda. Un modelo de RI es la especificación sobre como representar documentos y consultas y cómo comparar unos y otros [6]. El objetivo de todo modelo es obtener un orden (ranking) de los documentos recuperados que refleje la relevancia de estos con la consulta del usuario

En el proyecto titulado “Implementación de un Sistema de Recuperación de la Información”, se optó por el modelo algebraico, el propuesto por Salton y McGill [7], para ser utilizado en el filtrado, recuperación, indexado y cálculo de relevancia de documentos, al modelo del espacio vectorial. Una característica de este, es que cada documento, es representado mediante un vector de n elementos, siendo n igual al número de términos indizables que existen en la colección documental o corpus. Hay, pues, un vector para cada documento y, en cada vector, un elemento para cada término o palabra susceptible de aparecer en el documento. Cada uno de esos elementos es cubierto u ocupado con un valor numérico. Si la palabra no está presente en el documento, ese valor es igual a 0. En caso contrario, ese valor es calculado teniendo en cuenta diversos factores, dado que una palabra dada puede ser más o menos significativa (tanto en general como, sobre todo, en ese documento en concreto); este valor se conoce con el nombre de peso del término en el documento [5].

Básicamente, cualquier SRI se apoya principalmente en dos módulos: uno de indización, que construye los vectores de los documentos, y otro de consulta, que calcula la similaridad con una consulta dada [8]. Tanto los documentos como los vectores resultantes, así como productos intermedios y auxiliares, se almacenan en un repositorio auxiliar temporario. En el módulo de indización no todas las palabras o términos que componen un documento se incluyen en los índices. A los términos que se incluyen en el índice se les llama elementos de indización

En este sentido, es que se cree importante destacar brevemente, algunos aspectos generales que las técnicas de indización deben considerar. El primer punto es que no todas las palabras poseen el mismo nivel de significación para representar al documento. La teoría de la indización sugiere que algunas palabras conllevan más significado que otras [9]. Por ejemplo, los sustantivos más que los adjetivos o los verbos, y todas ellas más que las preposiciones. Otro aspecto es que incluir todas las palabras de un texto acarrea ruido en la recuperación. El concepto de indización implica un vocabulario

seleccionado, representar al documento solo con lo más significativo. Por último, un tercer aspecto, es que el lenguaje natural presenta muchas variaciones, y que, al momento de buscar, es deseable expandir la búsqueda para incluirlas. Existen dos grandes grupos de variaciones lingüísticas. El caso en el que dos expresiones distintas cargan con significados muy similares: sinonimia, o justamente lo opuesto, cuando dos formas iguales tienen distinto significado: polisemia. Otro caso más complejo es cuando una frase textualmente igual puede ser interpretada de manera diferente según el contexto [10].

La mayoría de los SRI incluyen algún mecanismo que permite reducir el número de términos de indización utilizando algún control morfológico o de las formas flexionadas de las palabras. El concepto tomado del libro “Introducción a la Morfología y Sintaxis” de Velma B. Pickett y Benjamin F. Elson [11] define la morfología como la rama de la lingüística que estudia la estructura interna de las palabras para definir y clasificar sus unidades: las variantes de las palabras (morfología flexiva) y la formación de nuevas palabras (morfología derivativa y composición). Este tipo de mecanismo se utiliza considerando que aquellos términos con misma raíz tienen también un significado parcialmente equivalente. Por tal razón, estos procesos son utilizados para reducir considerablemente el universo de búsqueda sin que esto implique una pérdida importante de información. Eliminar en mayor o menor medida las variantes de un mismo lexema producidas por flexión: singular, plural, masculino, femenino, los tiempos verbales; y también las formas producidas por derivación: sufijos, prefijos, etc. El concepto de lexema, en lingüística, define la parte que se mantiene invariable en todas las palabras de una misma familia; expresa el significado común a toda la familia y puede coincidir o no con una palabra entera [11]. Estos algoritmos se aplican en el proceso de recuperación, de indización y en ambos.

Los SRI utilizan varias técnicas para realizar este proceso. Una de estas técnicas se conoce como “conflación de términos” [10], que es la reducción de la variedad lingüística de los documentos por medio de la agrupación de las ocurrencias textuales que se refieren a conceptos similares o idénticos. Esta técnica se ocupa de extraer los sufijos y prefijos comunes de palabras literalmente diferentes, pero con una raíz común, que pueden ser consideradas como un sólo término. Siguiendo a [12] encontramos que los algoritmos de conflación funcionan cortando el final o el comienzo de la palabra, teniendo en cuenta la lista de prefijos y sufijos comunes que se pueden encontrar en una palabra flexionada. Pero remarca que este corte indiscriminado puede tener éxito en algunas ocasiones, pero no siempre, por eso se considera que este enfoque presenta algunas limitaciones.

En [9,11,13] se señala que las técnicas más comunes de conflación son la truncación, la lematización o stemming y la aplicación de diccionarios. Para algunos autores estos dos términos (lematización y stemming) no son dos métodos exactamente iguales. Algunos autores [14,15 y 16] sugieren que la principal diferencia es la forma en que



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

funcionan y por tanto el resultado que devuelve cada uno de ellos. Para este trabajo, ambos conceptos, se desarrollan como sinónimos, ya que, en los SRI, estos tienen el mismo objetivo: reducir las formas flexivas de cada palabra en una base o raíz común. La lematización es un proceso lingüístico que, dada una palabra flexionada (ej. comiendo), encuentra su lema (ej. com). Una palabra está flexionada cuando está en plural (amigos), en femenino (amiga), conjugada (comiendo), en diminutivo (amiguita) o en superlativo (amigota grandota), etc. Harman en [6] afirma, que, en los SRI, la reducción de las palabras que tienen la misma raíz bajo el mismo término de indexación puede incrementar la eficacia en la equiparación entre los términos del documento y los términos de la pregunta del usuario. La salida que obtendremos después de la lematización se llama "lema", que es una palabra raíz, después de la lematización, obtendremos una palabra válida que significa lo mismo [7].

El principal objetivo de este trabajo es proponer una mejora en el algoritmo de lematización utilizado en el proyecto 2013-2014, mencionado anteriormente. El código del programa original se encuentra disponible en la web¹ y está escrito en lenguaje PHP². Para recodificar y aplicar las mejoras al algoritmo original y a la propuesta, se reescribieron los códigos en lenguaje C++. Para ello se empleó el entorno de desarrollo integrado o entorno de desarrollo interactivo, en inglés Integrated Development Environment (IDE) Code::Blocks³, que es un software de código abierto, que soporta múltiples compiladores. La idea principal es comparar la calidad de los lematizadores, mediante distintas métricas los algoritmos en el proceso de extraer automáticamente los lemas de un lote de palabras.

2. Modelo conceptual de un SRI

Como ya se mencionó, en principio, la recuperación de información engloba las acciones encaminadas a identificar, seleccionar y acceder a los recursos de información útiles al usuario, el objeto documental se ha organizado y representado, utilizando una serie de normas y convenciones, en un soporte informático, mediante el diseño, creación y mantenimiento de bases de datos. Los SRI implementan una gama diversa de estructuras de datos, algoritmos y técnicas de recuperación de información, por ello, se precisa de un modelo conceptual donde se determinen: el tipo de almacenamiento, operaciones sobre los términos, modelos de búsqueda con base patrones exactos o los modelos inexactos los cuales contendrán las técnicas probabilísticas, los modelos lógicos y los espacios vectoriales [7]. En el trabajo de Martínez Méndez, se puede encontrar un estudio más profundo de los distintos modelos de RI existentes. Abordar en esta parte introductoria los diferentes modelos de SRI obedece a dos cuestiones principales. La primera es

que se necesita exponer a nivel conceptual las ideas que han guiado a los experimentos de los cuales las técnicas de indexación son parte. La segunda, de orden más práctico, es que ayuda a introducir al lector en los formalismos con que se expresan los procesos de RI para que su automatización sea posible. Una visión común en la RI es ver al documento y a la interrogación del usuario como contenedores de palabras que serán comparados, de manera que, cuantas más palabras en común tengan, más relevante será el documento para esa búsqueda.

Según Lorenzetti [17], en su tesis doctoral, escribió que los modelos de IR clásicos consideran que un documento está representado por un conjunto representativo de palabras claves, llamadas término índice, el autor asegura que un término índice es una palabra simple dentro de un documento, cuya semántica nos ayuda a recordar los temas principales sobre los que trata el documento, esta idea fue sugerida también por Luhn en los años 50s [18]. Entonces, dado un conjunto de términos de algún documento se puede notar que no todos son igualmente útiles a la hora de describir el documento. De hecho, hay algunos que son mucho más vagos que otros. No es un problema trivial decidir la importancia de un término como condensador del contenido de un documento. Más allá de esto, hay algunas propiedades de un término que son mensurables con facilidad y que son útiles para evaluar su potencialidad. Por ejemplo, consideremos una colección (o corpus) que contiene cien documentos. Una palabra que aparece en cada uno de los cien documentos es absolutamente inútil como término porque no nos dice nada acerca de cuáles documentos podrían interesarle a un usuario. Pero, otra palabra que aparezca en sólo cinco documentos sería más útil, porque reduce considerablemente el espacio de documentos que podría ser de interés para un usuario. Esto muestra que los distintos términos tienen una relevancia variable al usarlos para describir el contenido de los documentos. Siguiendo con Lorenzetti, también en [17], tomamos la definición que usa para la noción de peso de un término en un documento: "...Sea un término k_i , un documento d_j y el peso asociado a (k_i, d_j) , $w(k_i, d_j) \geq 0$. Este peso es una estimación de la importancia del término como descriptor del contenido semántico de un documento..."

En los SRI, varias tareas, como el almacenamiento, la búsqueda, agrupamiento o categorización de textos tienen como primer objetivo procesar documentos en lenguaje natural⁴ (LN). Se entiende por LN a la técnica que es hacer que las máquinas comprendan los textos no estructurados y extraigan la información relevante de esos textos. El problema que surge es que los algoritmos que pretenden resolver estas tareas necesitan representaciones internas explícitas de los documentos. En el área de recuperación de información, como ya se comentó, una de las formas que se emplea es la expresión vectorial, donde las dimensiones del vector representan términos, frases,

¹ <http://pragone.github.io/stemmer-es/>

² <https://www.php.net/>

³ <https://www.codeblocks.org/>

⁴ https://www.sas.com/es_ar/insights/analytics/what-is-natural-language-processing-nlp.html#nlphowitworks



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

nombres propios o conceptos que aparecen en el documento.

2.1. Modelo de Espacio Vectorial

En este modelo, el texto es representado por un vector de términos, los términos comúnmente son palabras; cualquier texto puede ser representado por un vector en un espacio dimensional Salton en el año 1975 [19]. En el Modelo de Espacio Vectorial (MEV) los documentos se representan a partir de vectores, de la siguiente manera [20]:

$$\text{Vector } d_j = (w_{1j}, w_{2j}, w_{3j}, w_{4j}, \dots, w_{nj}) \quad (1)$$

Donde n es igual al número total de elementos de representación considerados y por su parte w indica el peso que el término en concreto tiene para el documento j , el peso de un término es una medida de su importancia en la representación del documento. Las comparaciones se realizan de acuerdo a lo siguiente: dos vectores pueden ser representados en el hiperespacio y pueden ser medidas las diferencias de dirección entre ambos de la misma forma que se haría en un espacio bidimensional mediante la comparación del coseno del ángulo que forman [2]. El producto escalar de dos vectores normalizados mide el coseno del ángulo que forman. Suficientemente para ordenarlos dada la monotonía existente entre ángulo y coseno. En la Figura 1 se muestra la representación del MEV para la comparación entre la consulta y los documentos.

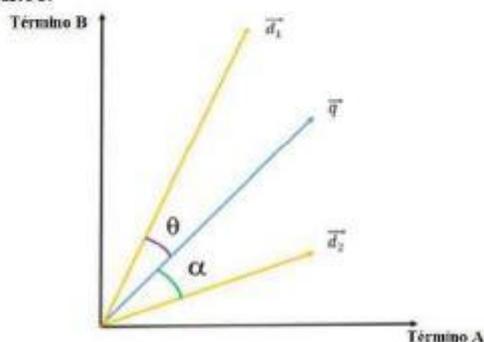


Figura 1. El MEV representa documentos y consultas como vectores para compararlos.

Para asignar una puntuación numérica a un documento para una consulta, este modelo mide la similitud entre el vector de consulta representado como vector q el vector del documento representado como vector d , típicamente el ángulo entre dos vectores es usado como una medida de divergencia entre los vectores, y el coseno del ángulo es usado como la similitud numérica [19]. El cálculo de la similitud cosenoidal, que es una medida que se calcula entre dos vectores distintos de cero, dentro del espacio interno del producto que mide el coseno del ángulo entre ellos. Esta se realiza mediante la siguiente ecuación [21].

$$\text{SimCos}(a, b) = \frac{\sum_{i=1}^k a_i \cdot b_i}{\sqrt{\sum_{i=1}^k a_i^2} \cdot \sqrt{\sum_{i=1}^k b_i^2}} \quad (2)$$

Se ve la conveniencia de tener los documentos representados por vectores normalizados y así evitar uno

de los divisores en la fórmula. El otro divisor es constante y representa a la consulta, se lo puede omitir con lo cual quedan escalados los indicadores, pero no se pierde la monotonía entre evaluador y ángulo: A menor evaluador, mayor ángulo, o sea más disparidad de contenidos. Esta ecuación produce un valor entre 0 y 1, en donde un valor de 0 indica la perpendicularidad (ortogonalidad) de los vectores, lo cual indica que se tendrían dos vectores en dirección completamente diferente, y un valor de 1 indica que los vectores tienen una dirección idéntica [22].

2.1.1. Transformar un documento a valores numéricos

La transformación de un documento, que contiene palabras, a un vector de números con el cual los algoritmos pueden trabajar se realiza de la siguiente manera [23]. Supongamos estos tres documentos (cada frase es un documento):

1. Practica ajedrez.
2. Pesca en el río.
3. Le gusta estudiar ajedrez.

La siguiente matriz tiene como filas a los documentos, y una columna por cada palabra diferente que hay en el total de documentos (vocabulario). La idea es poner la frecuencia de cada palabra en el documento. De esta manera el documento 1 tiene las palabras "practica", "ajedrez" por lo que la fila uno tiene valor 1 para esas palabras y 0 para el resto. En la Figura 2 se muestra un ejemplo de una matriz término-término, para el texto correspondiente al párrafo anterior, el contexto está formado por términos extraídos de un conjunto de oraciones.

	Practica	ajedrez	pesca	en	el	río	le	gusta	estudiar
1	1	1	0	0	0	0	0	0	0
2	0	0	1	1	1	1	0	0	0
3	0	1	0	0	0	0	1	1	1

Figura 2. Matriz término-término del ejemplo anterior.

Solo con mirar las tres frases, uno diría que la 1 y la 3 son similares dado que ambas hablan de ajedrez. Sin embargo, si aplicamos la similitud coseno entre el 1 y el 3 nos da un valor de 0.258, recordemos que 0 es no se parecen nada y 1 los documentos son idénticos. Entre el 1 y el 2 nos da similitud = 0 y entre el 2 y el 3 también 0. Según el trabajo realizado en [24], las consecuencias de este tipo de normalización son:

1. El producto escalar entre dos vectores, el coseno del ángulo que los separa y la inversa de la distancia euclídea entre ellos, son funciones monótonamente crecientes entre sí, y, por lo tanto, equivalentes desde un punto de vista de la IR;

2. todos los documentos se consideran igualmente informativos; la diferencia entre documentos es así cualitativa (qué tipo de información contienen) y no cuantitativa (cuánta información contienen). Si bien es una posición filosófica debatible, la normalización ha probado dar buenos resultados.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Por lo que en este ejemplo tan simple parece que funcionan bien estas técnicas. Hay aun ciertas cosas que pulir en este método, para empezar, hay palabras que van a salir con frecuencia en muchos documentos. Los artículos (la, el, ella, ...) o preposiciones (a, de, por, ...) van a estar en gran cantidad en los documentos que analicemos. Realmente no nos dan ninguna información sobre el documento o similitud con otros, volviendo al ejemplo anterior, la palabra que era clave para la similitud era "ajedrez". Luego, se debería eliminar palabras superfluas que solo nos hacen ocupar espacio en la matriz. Este tipo de palabras se les denomina "stopwords" o "palabras vacías", que en RI, son las palabras que no tienen un significado por sí solas, sino que modifican o acompañan a otras, este grupo suele estar conformado por artículos, pronombres, preposiciones, adverbios e incluso algunos verbos. En el procesamiento de datos en lenguaje natural son filtradas antes o después del proceso en sí, no considerándolos por su nulo significado, en el caso de los buscadores como Google no lo consideran al momento de posicionar, pero si al momento de mostrar los resultados de búsqueda. Antes de empezar a trabajar con los documentos conviene eliminarlas de los documentos, para reducir la cardinalidad de la matriz. Por último, luego de este proceso se debe aplicar otro para quedarse sólo con la raíz de la palabra, como se comentó en los apartados anteriores.

3. Lematización

Como ya se comentó, la lematización es una técnica empleada en la recuperación de datos en los SRI, que sirve para reducir variantes morfológicas de la forma de una palabra a raíces comunes o lexemas; con el fin de mejorar la habilidad de los motores de búsqueda y, a consecuencia, los resultados de las consultas. Básicamente, este consiste en remover el plural, el tiempo, o los atributos finales de la palabra [6,20]. Cuando se realiza la extracción de palabras de un texto se obtiene una gran cantidad de entradas con formas verbales conjugadas y variantes de concordancia. Logrando la reducción morfológica de todas estas variantes se busca que el usuario recupere tanto los textos que contienen sus términos de búsqueda, como aquellos que contienen las formas derivadas de esos términos. Encontramos en [10] este ejemplo, en idioma inglés, "analysis", "analyzing", "analyzer", "analysing" puede reducirse a la forma "analy" que se considera su raíz. Los plurales, los gerundios y las formas de los verbos en pasado son los casos más comunes de palabras susceptibles de aplicar esta técnica. Durante el proceso de lematización siempre existirá un porcentaje de error, pero este es lo suficientemente bajo como para no afectar a la efectividad en la recuperación.

Sin embargo, debido a que este proceso generalmente se basa en heurísticas, está lejos de ser perfecta. De hecho, los errores más frecuentes tienen que ver con la "sobre-reducción" y la "sub-reducción". El primero se produce cuando se corta demasiada palabra. Esto puede resultar en raíces sin sentido, donde todo el significado de la palabra

se pierde o se confunde. O puede resultar en que las palabras se resuelvan con las mismas raíces, aunque probablemente no deberían serlo. Tome las cuatro palabras "universidad", "universo", "universidades" y "universos". Un algoritmo que resuelve estas cuatro palabras en la raíz "univers" se ha sobre-reducido. Si bien podría ser bueno que el "universo" y los "universos" se fusionen y la "universidad" y las universidades se fusionen, los cuatro no encajan. Una mejor resolución podría hacer que los dos primeros se decidan a "univers" y los dos últimos se decidan a "universi". Pero hacer cumplir las reglas que lo establezcan podría dar lugar a que surjan más problemas. La sub-reducción, por otra parte, es el problema opuesto. Viene de cuando tenemos varias palabras, que tienen el mismo lema y significan cosas distintas. Esto se puede ver si tenemos un algoritmo de derivación que deriva las palabras "salida", "sala" y "salada" en el mismo lema: "sal". [10].

Los algoritmos de lematización más conocidos son: Lovins⁵ (1968), Porter⁶ (1980) y Paice⁷ (1990). La descripción y comparación de estos y otros algoritmos menos conocidos, se encuentran desarrollados en el trabajo "Comparative Study of Truncating and Statistical Stemming Algorithms" en [8]. Estos algoritmos, tiene en común que eliminan "los finales" de las palabras en forma iterativa, y requieren de una serie de pasos para llegar a la raíz, pero no requieren "a priori" conocer todas las posibles terminaciones. Originalmente todos fueron hechos para el inglés, y se diferencian en la eficiencia del código y la elección de sufijos que identifican y eliminan.

Según la bibliografía consultada, una de las formas más utilizadas de lematización, es la eliminación de afijos de palabras, la construcción de este proceso depende en gran medida del idioma para el que se desarrolló [20]. Por ejemplo, como se detalla en [25], el autor remarca que: en el inglés, las flexiones de los verbos son apenas 4 por verbo, los sustantivos y adjetivos solamente existen en dos formas (plural y singular), los artículos son pocos y no poseen género ni número. En cambio, en el español, solamente la flexión de los verbos involucra: 3 personas, 2 números 4 tiempos, 3 modos y ciertas combinaciones especiales, resultando cerca de 70 formas verbales simples, si a esto anexamos las formas compuestas y los pronombres enclíticos anidados, tenemos varias centenas de posibles palabras y grupos a considerar por cada verbo. Con los sustantivos y adjetivos, suceda algo similar si consideramos los sufijos y prefijos diminutivos, aumentativos, peyorativos y otros, además del plural, singular y algunas veces, el neutro, el colectivo (para grupos). Un diccionario completo para el español que contenga las formas más usadas, tendría más de 93000 lemas según la 23.ª edición del diccionario de la RAE de 2014⁸.

⁵ <http://snowball.tartarus.org/algorithms/lovins/stemmer.html>

⁶ <https://tartarus.org/martin/PorterStemmer/>

⁷ <https://www.scientificpsychic.com/paice/paice.html>

⁸ <https://www.rae.es/obras-academicas/diccionarios/presentacion-del-diccionario-de-la-lengua-espanola-y-sus-ediciones>



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

3.1. El algoritmo de Porter

El trabajo de Porter⁹ fue tomado como base por muchos investigadores. El algoritmo¹⁰ lee un archivo, toma una serie de caracteres y de esa serie, una palabra; luego la valida verificando que todos los caracteres involucrados sean letras, de ser así, aplica la lematización sobre ella. Esta consiste en hacer pasar esta palabra a través de varios conjuntos de reglas, en [26] se explica detalladamente el proceso, en resumen, se puede decir, que cada conjunto de reglas está formado, por n reglas y cada regla por:

1. Un identificador de regla
2. El sufijo a identificar
3. El texto por el cual debe ser reemplazado al encontrar el sufijo
4. El tamaño del sufijo
5. El tamaño del texto de reemplazo
6. El tamaño mínimo que debe tener la raíz resultante luego de aplicar la regla (esto es a los efectos de no procesar palabras demasiado pequeñas)
7. Una función de validación (una función que verifica si se debe aplicar la regla una vez encontrado el sufijo)

El algoritmo se desarrolló para la lematización de textos en inglés, pero la creciente importancia de la recuperación de información en la década de 1990 llevó a una proliferación del interés en el desarrollo de técnicas de combinación que mejorarían la búsqueda de textos escritos en otros idiomas [25]. Por lo tanto, el algoritmo proporcionó un modelo para el procesamiento natural de textos que no estén en inglés. Porter ha desarrollado toda una serie de lematizadores que se basan en su algoritmo original y que cubren las lenguas romances (francés, italiano, portugués y español), las germánicas (holandés y alemán) y escandinavas (danés, noruego y sueco), así como finlandés y ruso. El autor demostró cómo su algoritmo de supresión de sufijos mejora frente a otros sistemas más complejos la ejecución de la recuperación en términos de exhaustividad.

Este algoritmo tiene dos consideraciones importantes, una es que el sufijo que se elimine sea siempre el más largo y que la palabra cortada mantenga una determinada longitud. Teniendo esto en cuenta, cada palabra puede ser lematizada tantas veces como se considere necesario. El algoritmo, resumido en el trabajo de [27], se fundamenta en:

La medida (m) de la raíz, se basa en la alternancia de vocales (a, e, i, o, u), y (en el caso de que vaya precedida de una consonante) y consonantes, (todas las letras que no son vocales). En su artículo original, Martin F. Porter, que presentó en la Universidad de Cambridge, analiza explícitamente el uso del algoritmo para los sistemas de recuperación de información. El algoritmo, para la lengua inglesa, procede como sigue:

$[C] (VC)^m [V]$

Donde:

[C]: Consonante susceptible de aparecer
(VC): Conjunto de vocal/consonante
 m : medida de cada palabra o parte de palabra
[V]: vocal susceptible de aparecer
Cuando m es igual a 0 la palabra es nula.
Condiciones de la raíz

$\langle x \rangle$ la raíz termina con la letra x

- v la raíz contiene una vocal
- d la raíz termina en doble consonante
- la raíz termina con una secuencia del tipo consonante-vocal-consonante, donde el final de la consonante no es $w, x, o y$

Estas condiciones se pueden combinar entre sí y con la longitud de m mediante operadores booleanos.

Reglas [27]:

- (condición) $S1 \rightarrow S2$
Lo que significa que el sufijo $S1$ se reemplaza por $S2$ si las letras restantes de $S1$ satisfacen la condición.
- El primer paso del algoritmo está diseñado para tratar con participios y plurales pasados.
- Este paso es el más complejo y está dividido en tres partes en la definición original, 1a, 1b y 1c.
- La primera parte trata de los plurales, por ejemplo, $sses \rightarrow ss$ y la eliminación de s .
- La segunda parte elimina ed y ing o realiza $eed \rightarrow ee$ cuando sea apropiado. La segunda parte continúa solo si se elimina ed o ing y transforma el tallo restante para garantizar que se reconozcan ciertamente suficientes más adelante.
- La tercera parte simplemente transforma una terminal y en una i , esta parte se inserta como el paso 2.

Se puede encontrar una implementación del algoritmo de Porter en el portal de NLTK¹¹ (Natural Language Toolkit), que es una plataforma líder para crear programas Python que funcionen con datos de lenguaje humano.

Proporciona interfaces fáciles de usar para más de 50 corpus y recursos léxicos como WordNet, junto con un conjunto de bibliotecas de procesamiento de texto para clasificación, tokenización, derivación, etiquetado, análisis y razonamiento semántico, códigos para bibliotecas de procesamiento del lenguaje natural (NL) de nivel industrial, y un foro de discusión activo.

Se observa que los algoritmos de Lematización dependen en gran medida del idioma en el que están escritos los documentos. Este algoritmo ha sido ampliamente utilizado, referenciado y adaptado durante las últimas tres décadas. Varias implementaciones del algoritmo están disponibles en la WEB, incluido el sitio

⁹ <https://tartarus.org/martin/index.html>

¹⁰ <https://tartarus.org/martin/PorterStemmer/def.txt>

¹¹ <https://www.nltk.org/>



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

web oficial¹² escrito y mantenido por el autor para la distribución de su algoritmo.

3.2. El algoritmo de Snowball

Una modificación del algoritmo trabajo de Porter, es el algoritmo de Snowball¹³. Este puede mapear palabras que no están en inglés.

Dado que es compatible con otros idiomas, el algoritmo puede denominarse lematizador multilingües. El proyecto Snowball, tiene un portal de donde descargarse los códigos fuentes para distintos idiomas: lenguas romances¹⁴ (francés, italiano, portugués y español), las germánicas¹⁵ (holandés y alemán) y escandinavas¹⁶ (danés, noruego y sueco), así como finlandés y ruso¹⁷.

Este algoritmo, fue el implementado en el SRI del año 2013-2014. El mismo, como se comentó, siguió los pasos que propuso Porter.

Este algoritmo funciona dividiendo la palabra en dos regiones, R1 y R2, sin embargo, en algunos casos también se usa otra región RV. R1, R2 y RV se pueden definir de la siguiente manera:

- R1 - región que se encuentra después de la primera letra no vocal (consonante o letras acentuadas) después de una vocal;
- R2 - es la región después de la primera no vocal después de una vocal en R1, o es la región nula al final de la palabra si no hay vocal.
- RV - si la segunda letra es una consonante, RV es la región después de la siguiente vocal siguiente, o si las dos primeras letras son vocales, RV es la región después de la siguiente consonante, de lo contrario (consonante-vocal) RV es la región después de la tercera letra.

Pero RV es el fin de la palabra si no se cumplen esas condiciones. En la Figura 3 se presenta un ejemplo, de nuestra aplicación, de las regiones R1, R2 y RV de la palabra "universidad".

En esta imagen se puede ver al final de la misma, el lema resultante: "univers"

C:\Users\Usuario\Desktop\Fuente\ProgramaPster_PHP_palabra\main.exe

```
Ingrese palabra a Lematizar :universidad

Antes de comenzar paso 0 :
PALABRA universidad
r1 = 2 r1_txt= iversidad
r2 = 4 r2_txt= ersidad
rv = 3 rv_txt= versidad

La palabra queda en: univers
```

Figura 3. Salida del lematizador modificado.

4. Metodología utilizada

Para llevar a cabo la experiencia se seleccionaron 27.265 palabras. Estas fueron elegidas al azar de un leuario que en total posee 1.113.014 términos. Esta colección fue construida por el Dr. Ignacio Mario Morales Flores¹⁸, para su Corrector Ortográfico para Medicina, el mismo es compatible con Word 2016 de Microsoft.

Como se comentó anteriormente, para el SRI desarrollado en el año 2014, se empleó el lenguaje de programación C# (Sharp)¹⁹, para recodificar el proceso de lematización original del algoritmo de Snowball. En esta oportunidad, el código fue reescrito en lenguaje C++ y se encuentra a disposición para el lector, al igual que el resto de los archivos empleados en esta experimentación en [28] se deja un correo para solicitar los siguientes archivos:

- Lematizador_x_palabra.rar: Código fuente que devuelve el lema de la palabra ingresada. Muestra el detalle de cada paso del algoritmo.
- Lematizador_modificado.rar: Código con las propuestas incorporadas. Este programa tiene fijos o hardcoded los datos a procesar.
- LotePrueba.csv: Archivo con palabras y sus lemas.
- verbos.txt: Listado de los verbos 9281 verbos. Obtenidos del mismo sitio que el leuario.

Para obtener los lemas de las 27.265 palabras seleccionadas, se empleó un lematizador para la lengua española que se encuentra disponible en el sitio: <https://snowballstem.org/demo.html#Spanish>. En la fig. 4 se muestra la pantalla principal del mismo. Este conjunto de datos, se tomó para la experimentación, como los lemas correctos a comparar con los lemas devueltos por los algoritmos utilizados en el SRI.

¹² <https://tartarus.org/martin/PorterStemmer/>

¹³ <https://snowballstem.org/demo.html>

¹⁴ <https://snowballstem.org/algorithms/romance.html>

¹⁵ <https://snowballstem.org/algorithms/germanic.html>

¹⁶ <https://snowballstem.org/algorithms/scandinavian.html>

¹⁷ <https://snowballstem.org/algorithms/>

¹⁸ <http://www.cpimario.com>

¹⁹ <https://docs.microsoft.com/en-us/dotnet/csharp/>



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

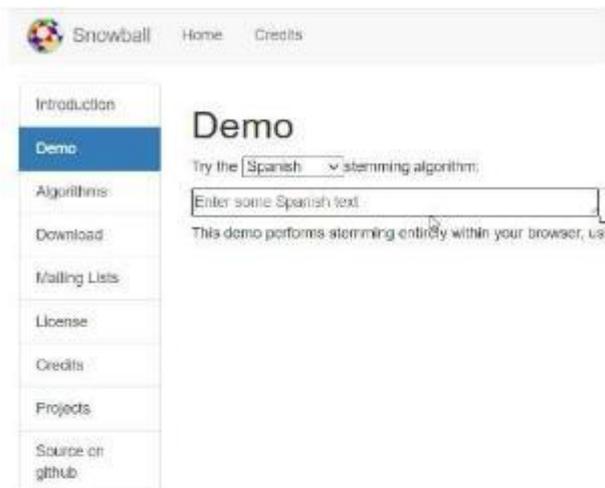


Figura 4. Pantalla del lematizador.

4.1. Evaluación de los algoritmos

Para evaluar los algoritmos de lematización, tanto el original como el modificado, se tomó como guía, el trabajo presentado por Gurusamy, Kannan y Nandhini [27], que evaluó el análisis de rendimiento de los algoritmos básicos de eliminación de tres sufijos derivados en el idioma inglés llamados Lovins, Porter y Paice / Husk mediante la precisión y distintas métricas de desempeño de los algoritmos. En el trabajo mencionado se evalúan los siguiente dos parámetros:

- Precisión del algoritmo.
- Perfomance o rendimiento del algoritmo.

A. Precisión del algoritmo de derivación

Se basa en el número de palabras derivadas correctamente dado por los algoritmos de lematización y el número de únicas palabras en los conjuntos de datos dados. La exactitud es calculada por el debajo de la fórmula:

$$\text{Precisión} = (\text{N}^\circ \text{ palabras correctamente derivadas} / \text{N}^\circ \text{ de palabras únicas}) * 100 \quad (3)$$

B. Rendimiento del algoritmo de derivación.

Se han utilizado cinco métricas de la siguiente manera:

1. Media de palabras por clase de combinación.

Este es el número promedio de palabras que corresponden a la misma raíz o lema para un corpus. Por ejemplo, si las palabras "ingeniero", "ingenieril" e "ingeniería" se derivan de "ingeniero", Entonces el tamaño de esta clase de combinación es de tres.

Los lematizadores más fuertes tenderán a tener más palabras por clase de combinación. Si la combinación de 1000 palabras diferentes da como resultado 250 raíces distintas, luego el número medio de palabras por la clase de fusión sería 4. Obviamente, esta métrica depende del número de palabras procesadas, pero para una colección de palabras de un tamaño determinado, un valor más alto indica una lematización más pesada. El valor se calcula de la siguiente manera:

$$\text{MWC} = N / S \quad (4)$$

Donde MWC es el número medio de palabras por combinación clase.

N: Número de palabras únicas antes de la derivación.

S: Número de lemas únicos después de la derivación.

2. Factor de compresión del índice. Es la reducción fraccional en tamaño del índice logrado mediante la lematización. Por ejemplo, un corpus con 50.000 palabras (N) y 40.000 raíces (S), Tendría un factor de compresión del índice del 20%. El mejor lematizador tenderán a tener factores de compresión de índice más grandes. Esto se puede calcular mediante:

$$\text{ICF} = (N-S) / N \quad (5)$$

Donde ICF es el factor de compresión del índice

N: Número de palabras únicas antes de la derivación

S: Número de lemas únicos después de la derivación

3. El número de palabras y raíces que difieren (NPRD). La lematización a menudo deja las palabras sin cambios. Por ejemplo, una derivación podría no alterar "reacción" porque ya es una palabra raíz. Los lematizadores más fuertes cambiarán las palabras con más frecuencia que los lemas más débiles.

4. Media de caracteres eliminados al formar el lema (MCE): Hay varias métricas que utilizan el principio de que un lematizador fuerte eliminan más caracteres de las palabras que los lematizadores más débiles. Una forma es calcular el número medio de letras eliminadas cuando se aplica un lematizador a una colección de texto. Por lo tanto, suponga que las nueve palabras "reacción", "reaccionar", "reaccionando", "reaccionales", "reaccionamos", "reacciones", "reacciona" y "reaccionemos" se reducen todas a "reacción"; los números de caracteres eliminados son 0, 2, 4, 3, 4, 2, 1 y 4, respectivamente. Esto da una tasa de eliminación media de $20/8 = 2.5$.

5. Distancia de Hamming (MHD): Esta distancia requiere dos cadenas de igual longitud y cuenta el número de posiciones correspondientes donde los caracteres son diferentes [29]. Por ejemplo:

La distancia de Hamming entre "poder" y "goles" es 3.

Si las cadenas son de diferentes longitudes, podemos utilizar la Distancia de Hamming modificada, MHD. Por lo tanto, supongamos que las longitudes de las cadenas son P y Q, donde $P < Q$, usamos la fórmula:

$$\text{MHD} = \text{HD}(1, P) + (Q-P) \quad (6)$$

donde HD(1, P) es la distancia de Hamming para los primeros caracteres P de ambas cadenas. Aplicando esto a una derivación, supongamos que la palabra "fiestitas" se convierte en "fiesta". En este caso, $P = 6$ y $Q = 9$, de modo que $\text{HD}(1, P) = 1$ por comparando "fiesta" con "fiesti", y $(Q-P) = 3$, dando $\text{MHD} = 4$. Claramente, es posible calcular el valor promedio de MHD para cada palabra en la muestra original.

Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

5. Resultados experimentales

5.1. Diseño experimental

Una vez definido el contexto de la prueba, lo que incluyó el lote de palabras para la prueba y las métricas que se utilizarían para la comparación de los resultados conseguidos, se procedió a ejecutar cada versión del algoritmo:

- por un lado, el que se empleó para el SRI versión 2014 (en adelante SRI v2014) y
- por otro lado, la versión mejorada (en adelante SRI v2021).

En la versión original del algoritmo se encontró, comparando con el resultado de los lemas correctos, que no se estaba resolviendo ciertas terminaciones, tales como: "ácea", "acho", "ucho", "astro", "astre", "avo", "bro", "tión", "zon", entre otras. Se modificó el código para incorporar estos sufijos faltantes en la nueva versión.

En la bibliografía consultada, se menciona que existen diferentes técnicas para realizar el proceso de lematización. En [30,31] se menciona lematizadores basados en diccionarios. Para el presente trabajo se agregó un nuevo paso, el mismo consiste en que una vez obtenido el lema resultante, se busca si el mismo corresponde o no a un verbo. De encontrarse, se reemplaza el verbo, por su correspondiente lema. En este proceso, en los 27.265 términos se encontraron 93 verbos. La lista con los 9.281 verbos agregada en el proceso se obtuvo del portal del Dr. Morales Flores. Esto permitió mejorar la versión que se encuentra en la web. Como se observa en la fig. 5.

Demo

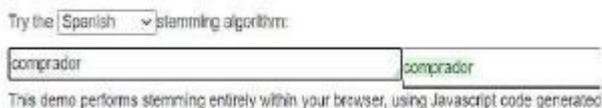


Figura 5. Devolución del lema del Snowball.

En la figura 6, se muestra la pantalla de salida del algoritmo modificado. Se observa los términos que resultan de cada paso, y devuelve correctamente la raíz de la palabra comprador.

```

C:\Users\Usuario\Desktop\Fuente\Programa\Poter_DHP_palabra\main.exe
Ingrese palabra a Lematizar :comprador

Antes de comenzar paso 0 :
PALABRA comprador
r1 = 3 r1_txt= prador
r2 = 5 r2_txt= ador
rv = 3 rv_txt= prador

La palabra queda en: compr

```

Figura 6. Salida del lematizador modificado.

Una vez ejecutados los dos algoritmos y se obtuvieron los siguientes resultados:

A) Precisión de los algoritmos

La precisión, como se indicó en el apartado anterior, es un parámetro que se utiliza para evaluar la eficiencia del algoritmo de derivación. Cabe aclarar que, para esta experiencia, se consideran "correctamente derivados", cuando el lema devuelto por los algoritmos, coincide con el que se obtuvo del portal de Snowballstem.

En la tabla 1 se muestra los valores obtenidos para este paso.

Tabla 1. Comparación entre los dos algoritmos.

	Nº palabras correctamente derivadas	Porcentaje
SRI v2014	17.280	63.38%
SRI v2021	24.267	89.00%

Se puede observar, que las modificaciones planteadas en los párrafos anteriores, mejoraron, casi en un 26%, la cantidad de lemas que coinciden con los lemas del portal.

Luego, se procedió, a realizar los procesos para completar las distintas métricas presentadas en el apartado 4.1.

B) Rendimiento de los algoritmos.

Una vez concluidas las pruebas se realizó los cálculos de las distintas métricas presentadas en el apartado 4.1. En la tabla 2 y la figura 7 se observa como el algoritmo modificado obtiene en cada métrica, mejores valores que su antecesor.

Tabla 2. Tabla de rendimiento

Algoritmo	MWC	ICF	MHD	MCE	NPRD
SRI v2014	1.66	0.40	1.88	1.88	23.732
SRI v2021	1.91	0.48	2.19	2.19	27.261



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019



Figura 7. Rendimiento de los algoritmos de lematización

Como se puede observar en la tabla 2 y en gráfico de la imagen 7, en todas métricas planteadas para, comparar el rendimiento de los algoritmos de lematización, dan mejores valores a la propuesta modificada.

5.2. Limitaciones

Los resultados presentan una buena precisión, pero estos dependen principalmente de disponer de un leuario completo de términos con sus respectivos lemas que estén correctamente verificados. Estas listas que deben ser preparadas exhaustivamente y necesitan muchas veces realizarse manualmente. Como se puede observar en la siguiente imagen, el algoritmo no resuelve correctamente dos términos como por ejemplo el caso de “aconsejeme” y “aconseje”.

Demo

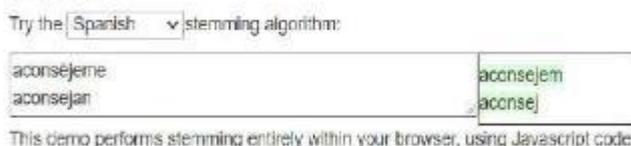


Figura 8. Ejemplo de lemas devuelto por el lematizador.

6. Conclusión y futuras líneas de trabajo

6.1 Conclusiones

En los últimos años hemos sido testigos de un creciente interés, por parte de distintas investigaciones, en obtener mejores SRI y, por optimizar los algoritmos de lematización. El propósito principal de esos algoritmos es reducir diferentes formas gramaticales como un sustantivo, adjetivo, verbo, adverbio, etc. a su forma raíz. Si bien, la mayor parte de los trabajos que se han realizado son para la lengua anglosajona, en este estudio se observó que los trabajos para el idioma español son escasos.

También se ha trabajado con una muestra reducida, mediante la evaluación de los algoritmos, se observa que la nueva versión proporciona una precisión del 89%, mejorando, en casi un 26%, a la versión anterior. Se

concluye que es un aumento considerable, pero todavía resulta importante la cantidad de palabras mal derivadas. Este estudio abre la puerta a seguir profundizando en el tema.

concluye que o considerable, pero n, es un aumento considerable, todavía resulta importante la cantidad de palabras mal derivadas. Este estudio abre la puerta a seguir profundizando en el tema.

Se comprobó, además que, un enfoque basado en reglas no siempre da una salida correcta, respecto a las raíces generadas.

Por último, en lo que respecta al enfoque lingüístico, dado que estos métodos se basan en un léxico, es de suma importancia realizar un estudio exhaustivo del idioma español.

6.2 Futuras líneas de trabajo

A pesar de los avances realizados en este trabajo, en cuanto a mejorar un algoritmo de lematización para la lengua española, aún quedan diversos desafíos por resolver. Estos desafíos contemplan desde la confección de una lista de términos con sus respectivos lemas, hasta perfeccionar las etapas de identificación y tratamiento de todos los sufijos de la lengua. A continuación, se enumeran las diferentes líneas de trabajo futuro surgidas de estos desafíos:

- Modificar el orden de los pasos, propuesto en el algoritmo de Snowball, para optimizar los tiempos de procesamiento. Sobre todo, cuando se realicen las futuras pruebas con el leuario con más de un millón de palabras.
- Estudiar nuevos métodos de derivación. Como se comentó, existen distintas líneas de investigación, además de las mencionadas en este escrito.
- Profundizar en el estudio de la morfología léxica, ciencia que estudia la estructura de las palabras y las pautas que permiten formarlas o derivarlas a partir de otras.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Referencias

- [1] Baeza-Yates, R. Y Ribeiro-Neto, B. (1999). Modern information retrieval. New York: Addison Wesley.
- [2] Salton, G. Y McGill, M.J. (1983). Introduction to modern information retrieval. New York: McGraw-Hill.
- [3] Martínez Méndez, F. Rodríguez Muñoz, J. Reflexiones sobre la evaluación de los Sistemas de Recuperación de Información: Necesidad, Utilidad y Viabilidad. Anales de documentación: Revista de biblioteconomía y documentación, ISSN 1575-2437, Nº. 7, 2004, pp 153-170. Disponible en: <https://revistas.um.es/analesdoc/article/view/1651/1701>. Último acceso: 20/07/2021.
- [4] Blair, D. C. (1990). Language and representation in information retrieval. Amsterdam: Elsevier.
- [5] Zazo Rodríguez A. y otros. (2002). Recuperación de información utilizando el modelo vectorial. U. de Salamanca. Disponible en: http://eprints.rclis.org/13963/1/zazo2002_recuperacion.pdf. Último acceso: 20/07/2021.
- [6] Salvador Oliván, José y Arquero Avilés, Rosario. (2006). Una aproximación al concepto de recuperación de información en el marco de la ciencia de la documentación. Investig. bibl [online]. 2006, vol.20, n.41, pp.13-43. ISSN 2448-8321. Último acceso: 20/07/2021.
- [7] Martínez Méndez, F. (2004). Recuperación de información: modelos, sistemas y evaluación. Disponible en: <http://eprints.rclis.org/16262/1/libro-ri.PDF>. Último acceso: 20/07/2021.
- [8] Figuerola C. y otros (2000) Diseño de un motor de recuperación de la información para uso experimental y educativo. Univ. de Salamanca. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=5555288>. Último acceso: 20/07/2021.
- [9] Herrero Pascual, Cristina. (2010). Manual de indización: teoría y práctica. Investigación bibliotecológica, 24(52), 239-240. http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0187-358X2010000300010&lng=es&tlng=es. Último acceso: 20/07/2021.
- [10] González, C. (2008). La recuperación de información en el siglo XX: Revisión y aplicación de aspectos de la lingüística cuantitativa y la modelización matemática de la información. UNLP. Disponible en: www.memoria.fahce.unlp.edu.ar/tesis/te.350/te.350.pdf. Último acceso: 20/07/2021.
- [11] Pickett V y Elson V. (1986). Introducción a la Morfología y Sintaxis. Disponible en: https://www.sil.org/system/files/rea_pdata/81/03/80/81038041802320181524909262276762975630/pickett_IntroMorfo_ed2.pdf. Último acceso: 20/07/2021.
- [12] Gómez Díaz R. (2002). Estudio de la incidencia del conocimiento lingüístico en los sistemas de recuperación de la información para el español. I.S.B.N.: 84-7800-831-4 Ed. Universidad de Salamanca. Salamanca (España)
- [13] Galvez, C.; Moya-Anegón, F.; Solana, V. H. Term conflation methods in information retrieval: non-linguistic and linguistic approaches. Journal of Documentation, v. 61, n. 4, p. 520-547, 2005.
- [14] Jurafsky D. & Martin J. (2020). Regular Expressions, Text Normalization, Edit Distance Speech and Language Processing. Disponible en: <https://web.stanford.edu/~jurafskyslp3/2.pdf>. Último acceso: 20/07/2021.
- [15] McCabe A. (2020). Lemmatization and Stemming. A Brief Article on the History, Differences and Use-Cases of each Rooting Approach. Disponible en: <https://medium.com/@alec.mccabe93/lemmatization-and-stemming-5b6b3718b49>. Último acceso: 20/07/2021.
- [16] Manning C.; Raghavan P. y Schütze H. An Introduction to Information Retrieval. Cambridge University Press. Cambridge, England. Online edition (c). 2009. <https://nlp.stanford.edu/IR-book/pdf/irbookprint.pdf>. Último acceso: 20/07/2021.
- [17] Lorenzetti, Carlos M. (2011). Caracterización Formal y Análisis Empírico de Mecanismos Incrementales de Búsqueda basados en Contexto. Tesis Doctoral en Ciencias de la Computación - Universidad Nacional del Sur. Disponible en: <https://arxiv.org/pdf/1810.04167.pdf>. Último acceso: 20/07/2021.
- [18] Hans P. Luhn. A statistical approach to mechanized encoding and searching of literary information. IBM Journal of Research and Development, 1(4):309-317, October 1957. Disponible en: <http://openlib.org/home/krichel/courses/lis618/readings/luhn57.pdf>. Último acceso: 20/07/2021.
- [19] Salton, G., Wong, A., & Yang, C. S. (1975). A Vector Space Model for Information Retrieval. Communications of the ACM, 18(11), 613-620. Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.44.6.5101&rep=rep1&type=pdf>. Último acceso: 20/07/2021.
- [20] Tolosa G. y Bordignon F. (2008) Introducción a la Recuperación de Información. Conceptos, modelos y algoritmos básicos. Universidad Nacional de Luján, Argentina. Disponible en: <http://eprints.rclis.org/12243/1/Introduccion-RI-v9f.pdf>. Último acceso: 20/07/2021.
- [21] Mendoza Olguín, G., Laureano de Jesús, Y., & Pérez de Celis Herrero, M. (2019). Métricas de similitud y evaluación para sistemas de recomendación de filtrado colaborativo. Revista de Investigación en Tecnologías de la Información, 7(14), 224-240. Disponible en: <https://www.riti.es/ojs2018/inicio/index.php/riti/article/view/175>. Último acceso: 20/07/2021.
- [22] Blanco E. y Sanz H. (2016). Algoritmos de clustering y aprendizaje automático aplicados a Twitter. Disponible en: <https://upcommons.upc.edu/bitstream/handle/2117/82434/113257.pdf>. Último acceso: 20/07/2021.
- [23] Torres López, Carmen, & Arco García, Leticia. (2016). Representación textual en espacios vectoriales semánticos. Revista Cubana de Ciencias Informáticas, 10(2), 148-180. Disponible en: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2227-18992016000200011&lng=es&tlng=es. Último acceso: 20/07/2021.
- [24] Gómez S. A. (2001) Un Agente para clasificación y filtrado de páginas Web. Disponible en: <https://core.ac.uk/download/pdf/296326901.pdf>. Último acceso: 20/07/2021.
- [25] Hohendahl A. Lemmatizador Morfosintáctico y Semántico Robusto con Flexionador y Estimador Idiomático, usando algoritmos eficientes y compactos para idiomas muy ricos en formas como el español. Disponible en: http://sedici.unlp.edu.ar/bitstream/handle/10915/22789/Documento_completo.pdf?sequence=1. Último acceso: 20/07/2021.
- [26] Bordignon F., W. Panessi. Procesamiento de variantes morfológicas en búsquedas de textos en castellano. Revista Interamericana de Bibliotecología, ISSN 0120-0976, Vol. 24, Nº. 1 (ENE-JUN), 2001, págs. 69-88. <https://dialnet.unirioja.es/servlet/articulo?codigo=4291340>. Último acceso: 20/07/2021.
- [27] Gurusamy, Vairaprakash & Kannan, Subbu. (2017). Performance Analysis: Stemming Algorithm for the English Language. International Journal for Scientific Research and Development. 5. 2321-613. https://www.researchgate.net/publication/319525961_Performance_Analysis_Stemming_Algorithm_for_the_English_Language. Último acceso: 20/07/2021.
- [28] jbossoro@unlam.edu.ar o ej_moreno@unlam.edu.ar



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLAM
Versión	5
Vigencia	03/9/2019

- [29] R.W. Hamming. (1950). Error Detecting and Error Correcting Codes. In The Bell System Technical Journal, vol 29, issue 2, American Telephone and Telegraph Company, USA, 1950.
- [30] Olivas Varela J. (2011). Las técnicas de soft-computing en La recuperación de información. Disponible en: http://eventos.citius.usc.es/sematica2011/PDFs/traspas_JAngelOlivas.pdf. Último acceso: 20/07/2021.
- [31] Jivani, Anjali. (2011). A Comparative Study of Stemming Algorithms. Int. J. Comp. Tech. Appl. 2. 1930-1938.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Adecuación de un Sistema de Recuperación de Información para su utilización en un Contexto Jurídico

Osvaldo Sposito¹, Hugo Ryckeboer¹, Julio Bossero¹, Edgardo Moreno¹, Viviana Ledesma¹, Gastón Procopio¹, Lorena Matteo¹, Cecilia Gargano¹, Victoria Saizar¹, Patricio Macias¹, Juan Ojeda¹, Fabio Quintana¹, Laura Conti², Sergio García³ y Gustavo Pérez Villar⁴

¹ Universidad Nacional de La Matanza. Departamento de Ingeniería e Investigación Tecnológicas. Florencio Varela 1903. San Justo. La Matanza.

{sposito, hugor, jbossero, ej_moreno, vledesma, gprocopio, lmatteo, cgargano, vsaizar, pmacias, fquintana, jmojeda}@unlam.edu.ar

² Universidad Nacional de La Matanza. Departamento Derecho y Ciencia Política. lconti@unlam.edu.ar

³ Palacio de Tribunales. Departamento Judicial de Morón. Alte. Brown. Piso 4. Morón. sergiogabriel.garcia@pjba.gov.ar

⁴ Subsecretaría de Tecnología Informática del Poder Judicial de la Provincia de Buenos Aires. Palacio de Justicia, avenida 13 entre 47 y 48, primer piso (La Plata). Argentina. gperez@scba.gov.ar

RESUMEN

En las últimas décadas, las instituciones públicas, particularmente el Poder Judicial (PJ), con el desarrollo de las TICs, han generado un importante aumento en: la generación de documentos digitales, en los repositorios de los mismos y en los Sistemas de Recuperación de Información (SRI). Este trabajo se orienta a estudiar y proponer soluciones para la recuperación de documentos judiciales, se hace una propuesta para la construcción de la matriz de términos en un proceso de indización.

Palabras clave: SRI, Modelo Vectorial, Indización, Lematización.

CONTEXTO

La línea de investigación aquí presentada es parte del proyecto de investigación "Implementación de un Sistema Web de Recuperación de la Información Orientado a Documentación Jurídica con el Proceso de Indexación Semántica Latente Paralelizado", perteneciente al programa de Investigaciones PROINCE (Programa de Incentivos para Docentes Investigadores) de la Secretaría de Políticas Universitarias del Ministerio de Educación de la Nación. Los integrantes del equipo son docentes e investigadores

dependientes de las siguiente Unidades Académicas de la Universidad Nacional de La Matanza (UNLaM): el Departamento de Ingeniería e Investigaciones Tecnológicas (DIIT), y el Departamento Derecho y Ciencia Política, además, colaboran personal técnico de la Subsecretaría de Tecnología Informática del Poder Judicial de la Provincia de Buenos Aires.

1. INTRODUCCIÓN

En este trabajo se describe un proceso de indización, que consiste en extraer una serie de términos, representativos de los temas tratados en un documento, para utilizarlos después como puntos de acceso para la recuperación de esos documentos de un corpus jurídico. El propósito es brindar jurisprudencia similar a los profesionales del derecho luego de realizar una consulta. Entendiendo el concepto de jurisprudencia, como el conjunto de las sentencias de distintos fallos dictados por los tribunales de justicia u organismos judiciales de un Estado. En el campo del derecho, la jurisprudencia juega un papel importante como fuente del derecho; por ser la comprensión e interpretación de las normas jurídicas basada en las sentencias pasadas emitidas por órganos oficiales,



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

estas sustentan la aplicación de la ley en un caso concreto. En el PJ se producen una enorme cantidad de documentos jurídicos (dictámenes, expedientes, etc.) cada año, lo cual produce que esta fuente de derecho sea cada vez mayor, lo que impulsa a los profesionales del derecho a dedicar más tiempo a la búsqueda de una decisión relevante.

Basándonos en [1] coincidimos, en que los SRI están en continua mejoría, esto se debe a: la incorporación de utilidades dependientes de la expansión de su uso, el avance de las aplicaciones tecnológicas y el claro deslinde de sus funciones.

En [2], se referencia a Calvin N. Mooers como quien introdujo por primera vez en 1950 el término Recuperación de Información (en inglés Information Retrieval) en la literatura de documentación, la definió como «*la búsqueda de información en un stock de documentos, efectuada a partir de la especificación de un tema*». Sólo un año más tarde, el mismo autor ampliaba esta definición al manifestar que la recuperación de información abarca los aspectos intelectuales de la descripción de información y su especificación para la búsqueda, y también cualquier sistema, técnica o máquina que se utilice para llevar a cabo la operación [3].

Según la bibliografía consultada [4-6], una SRI es un programa que interactúa entre un corpus y sus usuarios. Su efectividad depende del adecuado control del lenguaje de representación de los elementos de información y las búsquedas de sus usuarios. Para cumplir con sus objetivos, según Gabriel H. Tolosa y otros [5], un SRI debe realizar las siguientes tareas básicas:

- Representación lógica de los documentos y, opcionalmente, almacenamiento del original.
- Representación de la necesidad de información del usuario en forma de consulta.

- Evaluación de los documentos respecto de una consulta para establecer la relevancia de cada uno.
- Ranking de los documentos considerados relevantes para formar el “conjunto solución o respuesta. Presentación de la respuesta al usuario.
- Retroalimentación de las consultas para aumentar la calidad de la respuesta.

Jaime Robredo en [5], asevera que en cualquier área del conocimiento, los términos con significado se pueden utilizar como descriptores para representar el contenido de documentos escritos, en los procesos de indización y organización de la información, así como para formular preguntas en el proceso de recuperación de información. Tolosa en [5] afirma que el proceso se puede dividir en las siguientes etapas:

- Análisis lexicográfico: Se extraen las palabras y se normalizan.
- Reducción (Tokenización) de palabras vacías o de alta frecuencia.
- Lematización: Se reducen palabras morfológicamente parecidas a una forma base o raíz, con la finalidad de aumentar la eficiencia de un SRI.
- Asignación de pesos o ponderación de los términos que componen los índices de cada documento.

Los SRI implementan una gama diversa de estructuras de datos, algoritmos y técnicas de recuperación de información, por ello, se precisa de un modelo conceptual donde se determinen: el tipo de almacenamiento, operaciones sobre los términos, modelos de búsqueda con base patrones exactos o los modelos inexactos los cuales contendrán las técnicas probabilísticas, los modelos lógicos y los espacios vectoriales [8]. En el trabajo de Martínez Méndez, se puede encontrar un estudio detallado de los distintos modelos de RI existentes. Uno de los modelos más utilizados [4-5], es el Modelo de Espacio



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Vectorial. En este modelo, el texto es representado por un vector de términos, los términos comúnmente son palabras; cualquier texto puede ser representado por un vector en un espacio dimensional Salton en el año 1975 [9]. En un espacio de documento que consiste en documentos D_i , cada uno identificado por uno o más términos de índice T_j ; los términos pueden ser ponderados de acuerdo a su importancia, o no ponderados con pesos restringidos a 0 y 1. En el modelo los documentos se representan a partir de vectores, de la siguiente manera:

$$D_i = (T_1, T_2, \dots, T_j) \quad (1)$$

En la Figura 1 se muestra un espacio de índice tridimensional, donde cada elemento se identifica con hasta tres términos distintos.

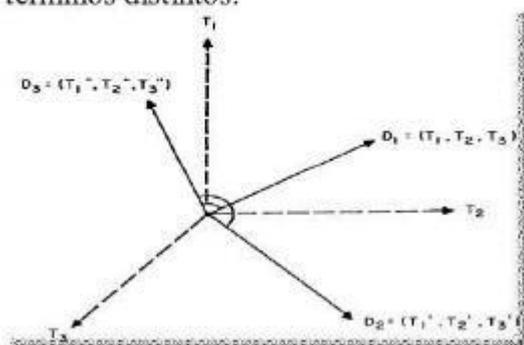


Figura. 1. Representación vectorial espacial de los documentos [9].

Una consulta se puede ver como un documento por lo tanto se puede ver como un vector.

Matemáticamente, una de formas de establecer la cercanía de dos vectores es calcular el coseno del ángulo que forman los dos vectores entre sí. Esta fórmula tiene la ventaja de su bajo esfuerzo computacional y es independiente de los módulos de los vectores. De manera similar, se puede calcular el coseno del

ángulo entre cada vector de documento y el vector de consulta para encontrar su cercanía. Para encontrar un documento relevante para el término de la consulta, se calcula la puntuación de similitud entre cada vector del documento y el vector del término de la consulta aplicando la similitud del coseno. Finalmente, aquellos documentos con puntajes de similitud altos se considerarán documentos relevantes para la consulta. [9].

Como se comentó, dentro de la indización se encuentra la lematización, que es una técnica empleada en la recuperación de datos en los SRI, que sirve para reducir variantes morfológicas de la forma de una palabra a raíces comunes o lexemas; con el fin de mejorar la habilidad de los motores de búsqueda y, a consecuencia, los resultados de las consultas. Básicamente, este consiste en remover el plural, el tiempo, o los atributos finales de la palabra [5,6,10]. En el trabajo de González [6], afirma que “cuando se realiza la extracción de palabras de un texto se obtiene una gran cantidad de entradas con formas verbales conjugadas y variantes de concordancia. Logrando la reducción morfológica de todas estas variantes se busca que el usuario recupere tanto los textos que contienen sus términos de búsqueda, como aquellos que contienen las formas derivadas de esos términos...”. Cabe aclarar que, en este proyecto, nosotros también simplificamos las apariciones de sustantivos y adjetivos. Los algoritmos de lematización más conocidos son: Lovins¹ (1968), Porter² (1980) y Paice³ (1990). Originalmente todos fueron hechos para el inglés, y se diferencian en la eficiencia

1

<http://snowball.tartarus.org/algorithms/lovins/stemmer.html>

² <https://tartarus.org/martin/Porter/Stemmer/>

³ <https://www.scientificpsychic.com/paice/paice.html>



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

del código y la elección de sufijos que identifican y eliminan. Una modificación del algoritmo trabajo de Porter, es el algoritmo de Snowball⁴. Este puede mapear palabras que no están en inglés. Estos algoritmos permiten realizar “derivaciones”, esto es remover los sufijos comunes morfológicos e inflexionales de palabras literalmente diferentes, pero con una “raíz” común, que pueden ser consideradas como un sólo término. Este algoritmo requiere de un conjunto de pasos para llegar a la raíz.

2. LÍNEAS de INVESTIGACIÓN y DESARROLLO

El presente trabajo tiene como eje central el desarrollo de un SRI. Entre las líneas de investigación a considerar en este proyecto se pueden mencionar:

- El problema de la recuperación de información, el modelo vectorial y la forma de almacenar los términos de una colección (corpus) de pruebas.
- La paralelización del proceso de Indexación Semántica Latente (ISL). Se estudian las librerías: Compute Unified Device Architecture (CUDA) y CUDA Basic Linear Algebra Subprograms (CuBlas), aplicadas a una arquitectura híbrida.
- La aplicando el patrón de arquitectura Modelo-Vista-Controlador (MVC), para desarrollos WEB. Aplicando el lenguaje de programación C#.
- Estudio de la librería REGEX., para resolver las Expresiones Regulares (ER).
- Estudio y evaluación de distintos algoritmos de ranking para Documentos. Las pruebas serán realizadas tomando como base un corpus jurídico real.

3. RESULTADOS OBTENIDOS/ESPERADOS

Durante el año 2021 se ha trabajado, principalmente, en dos temas, por un lado, en el estudio, análisis y modificación de algoritmos y técnicas que permitan la lematización de términos, y por otro, en el proceso que permita incorporar, de un corpus jurídico, las fechas y las referencias de la norma jurídica actual, mediante el Reconocimiento de Entidades Nombradas (tales como Acordadas, Artículos, Leyes, entre otros), que componen los distintos textos judiciales, utilizando Expresiones Regulares (ER). Se presentaron en distintos congresos las siguientes publicaciones:

1. “*Propuesta para la construcción de un corpus jurídico utilizando Expresiones Regulares*”. Presentado en el XXVII Congreso Argentino de Ciencias de la Computación (CACIC). Salta, Argentina [8].

Una ER es una notación algebraica para caracterizar un conjunto de cadenas [11]. Son particularmente útiles para la búsqueda en textos, cuando se tiene un patrón y un corpus de textos donde buscar. En este trabajo se demostró que es posible incorporar en el proceso de Análisis lexicográfico Expresiones Regulares para incorporar fechas y Entidades Nombradas a una matriz de términos. Dentro de las tareas a desarrollar, durante este año, se puede mencionar:

- Incorporar la codificación propuesta al SRI implementado por el proyecto PROINCE mencionado en la introducción.
 - Analizar otros algoritmos y técnicas de derivación.
 - Estudiar otras librerías existentes de ER.
 - Realizar una clasificación de todas las EN dentro de la norma jurídica Argentina.
2. “*Implementación de un lematizador*”

⁴ <https://snowballstem.org/demo.html>



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

para la lengua española". Trabajo presentado en el Workshop del IX Congreso Nacional de Ingeniería en Informática/Sistemas de Información. CONAIISI 2021. Mendoza. Argentina. En este trabajo se muestra una modificación realizada al algoritmo de Snowball. Mejorando en un 26% la lematización de términos. Se prevé para este año:

- Modificar el orden de los pasos, propuesto en el algoritmo de Snowball, para mejorar los tiempos de procesamiento.
- Estudiar nuevos métodos de derivación.
- Profundizar en el estudio de la morfología léxica, ciencia que estudia la estructura de las palabras y las pautas que permiten formarlas o derivarlas a partir de otras.

4. FORMACIÓN DE RECURSOS HUMANOS

La presente línea de investigación la lleva adelante un equipo de 15 integrantes provenientes de dos departamentos de la UNLaM, el DIIT y el Departamento de Derecho y Ciencia Política.

- 1 alumno de grado. En el año 2021 se graduó en la carrera de Ingeniería de Informática.
- 2 asesores especialistas externos. (uno perteneciente al Poder Judicial de la Provincia de Buenos Aires y un Secretario de Juzgado).

5. BIBLIOGRAFÍA

- [1] Galindo Ayuda, F. (2020). Avances en sistemas jurídicos de recuperación de documentos. *Scire: Representación Y organización Del Conocimiento*, 26(1), 63-74. <https://doi.org/10.54886/scire.v26i1.4698>. Fecha de consulta: 07/02/22
- [2] S. Oliván, J.A., & Arquero Avilés, Rosario. (2006). Una aproximación al concepto de recuperación de información en el marco de la ciencia de la documentación. *Investigación bibliotecológica*, 20(41), 13-43. Disponible en: <http://www.scielo.org.mx/scielo.php?script=s>
[ci_arttext&pid=S0187-358X2006000200002&lng=es&tng=es](http://www.scielo.org.mx/scielo.php?script=ci_arttext&pid=S0187-358X2006000200002&lng=es&tng=es). F. de consulta: 07/02/22
- [3] C.N. Mooers, "The theory of digital handling of non-numerical information and its implications to machine economics", en *Technical Bulletin No. 48*. Cambridge, MA: Zator Co., 1950 (Ponencia presentada en Association for Computing Machinery, Rutgers Univ., New Brunswick, NJ, 1950, March 29).
- [4] Kuna, H., Rey, M., Martini, E., Solonezen, L. & Podkova, L. Desarrollo de un Sistema de Recuperación de Información para Publicaciones Científicas del Área de Ciencias de la Computación. *Rev. Latinoamericana de Ingeniería de Software*, (2014). 2(2): 107-114. <http://revistas.unla.edu.ar/software/article/view/81>. Fecha de consulta: 07/02/22
- [5] Tolosa G. & Bordignon, F. Introducción a la Recuperación de Información: Conceptos, modelos y algoritmos básicos. UNDeL, Argentina, (2008). En línea: <http://eprints.rclis.org/12243/1/Introduccion-RI-v9f.pdf>. Fecha de consulta: 07/02/22
- [6] González, C. M. La recuperación de información en el siglo XX. Revisión y aplicación de aspectos de la lingüística cuantitativa y la modelización matemática de la información UNLP. (2008) Disponible en: <https://memoria.fahce.unlp.edu.ar/tesis/te.350/te.350.pdf>. Fecha de consulta: 07/02/22
- [7] Robredo, J. (2019). Otimização dos processos de indexação dos documentos e de recuperação da informação mediante o uso de instrumentos de controle terminológico. *Ciência Da Informação*, 47(1). Recuperado de <http://revista.ibict.br/ciinf/article/view/4431>. Fecha de consulta: 07/02/22.
- [8] Martínez Méndez, F. (2004). Recuperación de información: modelos, sistemas y evaluación. Disponible en: <http://eprints.rclis.org/16262/1/libro-ri.PDF>. Fecha de consulta: 07/02/22.
- [9] Salton, G., Wong, A., & Yang, C. S. (1975). A Vector Space Model for Information Retrieval. *Communications of the ACM*, 18(11), 613-620. Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.446.5101&rep=rep1&type=pdf>. F. consulta: 07/02/22.
- [10] Zazo Rodríguez A. y otros. (2002). Recuperación de información utilizando el modelo vectorial. U. de Salamanca. Disponible en: <http://eprints.rclis.org/13963/1/zazo2002recuperacion.pdf>. Fecha de consulta: 07/02/22.
- [11] Robaldo, L. y otros. Compiling regular expressions to extract legal modifications. 250. 133-141. 10.3233/978-1-61499-167-0-133. (2012).



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Resultados preliminares de una técnica de localización de documentos en espacios métricos utilizando K-means

Oswaldo Sposito¹, Julio Bossero¹, Edgardo Moreno¹, Viviana Ledesma¹, Gastón Procopio¹, Lorena Matteo¹, Cecilia Gargano¹, Victoria Saizar¹, Patricio Macías¹, Juan Ojeda¹, Fabio Quintana¹, Laura Conti², Sergio García³ y Gustavo Pérez Villar⁴

¹ Universidad Nacional de La Matanza. Departamento de Ingeniería e Investigación Tecnológicas. Florencio Varela 1903. San Justo. La Matanza.

{sposito, jbossero, cj_moreno, vledesma, gprocopio, lmatteo, cgargano, vsaizar, pmacias, jmojeda}@unlam.edu.ar

² Universidad Nacional de La Matanza. Departamento Derecho y Ciencia Política. Iconiti@unlam.edu.ar

³ Palacio de Tribunales. Departamento Judicial de Morón. Alte. Brown. Piso 4. Morón. sergiogabriel.garcia@pjba.gov.ar

⁴ Subsecretaría de Tecnología Informática del Poder Judicial de la Provincia de Buenos Aires. Palacio de Justicia, avenida 13 entre 47 y 48. primer piso (La Plata). Argentina. gperez@scba.gov.ar

Resumen

En un modelo basado en espacio vectorial, un Sistema de Recuperación de Información, para encontrar los documentos más similares a una consulta, debe enfrentar a esta, con todos los documentos existentes en el corpus. En este enfoque, todos los objetos deben ser convertidos a vectores de características numéricas y la comparación entre ellos se debe realizar calculando una métrica de proximidad o similitud. Este proceso, si bien es el mejor, requiere un alto costo computacional. Varios estudios analizan la posibilidad de fraccionar el corpus de modo tal de reducir el tiempo, sin perder calidad de la primera respuesta que entrega el sistema frente a una consulta. Se propone que los segmentos contengan documentos afines con la finalidad que muchas consultas queden resueltas por examen de un solo segmento, aunque esa respuesta adolezca de algunos documentos. Para llevar a cabo este segmentación, se emplean técnicas de agrupación automática, que permiten organizar, extraer características y clasificar objetos según su similitud o proximidad. Este artículo presenta el desarrollo de un programa parametrizable, que permite la construcción de un espacio métrico de n cantidad de documentos, con diversos tamaños de dimensionalidad y utilizando distintas normas (distancia). Esta herramienta permite a los usuarios visualizar rápidamente los resultados de la búsqueda, utilizando diferentes configuraciones.

1. Introducción

Este grupo de investigación perteneciente a la Universidad Nacional de La Matanza (UNLaM), desde el año 2013 viene investigando sobre distintos procesos que conforman un Sistema de Recuperación de Información (SRI) [1-7]. En el año 2021, se presentó a través del

Programa de Incentivos para Docentes Investigadores de la Secretaría de Políticas Universitarias (PROINCE), un proyecto con el título "Implementación de un Sistema Web de Recuperación de la Información Orientado a Documentación Jurídica con el Proceso de Indexación Semántica Latente Paralelizado". En este proyecto se propone una versión renovada de un SRI, orientado de modo especial a la recuperación de documentos jurídicos (dictámenes, expedientes, etc.). Uno de los objetivos es la construcción corpus jurídico lo suficientemente voluminoso para poder evaluar los tiempos de respuesta del SRI y la pertinencia de los documentos recuperados.

El objetivo de todo sistema de recuperación de documentos es sugerir una lista de documentos ordenados de acuerdo a la cercanía que manifiestan al requerimiento formulado. Sólo el examen de los documentos por parte del requeridor confirma el mayor o menor acierto del sistema [1]. Cualquier usuario de buscadores de la WEB tiene la experiencia de que no siempre la primera respuesta que ofrece el sistema sea la más adecuada. Es lógico pensar que, conforme los corpus aumentan de tamaño, ese tiempo aumenta por ser proporcional al tamaño. Para reducir ese tiempo se puede recurrir a un aumento de potencia de cómputo los que encaran ese camino recurren especialmente al paralelismo o a un pre-proceso que tienda a acelerar todas las consultas posteriores o al menos a un alto porcentaje de las mismas. En el trabajo presentado en [3], se expuso que esto requiere dos algoritmos preparatorios:

- uno que particione el corpus utilizando una noción de vecindad o similitud y
 - el entrenamiento de un algoritmo de clasificación que dirija la consulta hacia la parte más promisoriosa.
- posteriormente, por cada consulta, se debe ejecutar dos pasos:
- 1) Aplicar el algoritmo que direcciona la consulta hacia una de las partes.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

2) Enfrentar la consulta con cada documento de esa parte para determinar su grado de adecuación y posterior posición en la lista de documentos sugeridos.

Si la parte elegida efectivamente contiene un alto porcentaje de los documentos que hubieran encabezado la lista de haber hecho el proceso sobre la totalidad el usuario no sentiría demasiado la baja de la exhaustividad¹. Evidentemente, habrá consultas cuya respuesta completa esté repartida entre varias partes, pero mientras haya en la página inicial suficientes documentos representativos de la respuesta ideal para que el usuario los examine hay tiempo de procesar otras partes y mostrarle cuando solicite la segunda página lo que hubiera faltado en la primera [3]. En este trabajo se ensaya el camino inverso, en lugar de efectuar macro-agrupamientos se comienza con micro agrupamientos. A igual que en el ensayo de la técnica citada al carecer de una voluminosa cantidad de documentos para experimentar el proceso de recuperación, en el presente trabajo se construye artificialmente vectores que representan documentos y consultas en lenguaje natural. Estos vectores, conformarán un corpus de la experimentación. El mismo, utilizando una técnica de clasificación no supervisada (clustering), K-means [8], agrupará los objetos en k grupos basándose en sus similitudes o cercanías. Con estas simulaciones se pretende demostrar que hay un modo de estructurar los datos, por una única vez, tal que sugerir los mejores documentos no requiere examinarlos todos.

Como es sabido, el modelado y la simulación es cada vez más importante para el análisis y diseño de sistemas complejos [9]. El objetivo de estas técnicas es poder ayudar o dar el soporte necesario a distintos interesados durante el proceso de diseño, análisis y diagnosis de sistemas ingenieriles.

En el punto 2 se expone el marco teórico de las distintas tecnologías que abarcan este escrito, en el punto 3 se hace un pequeño resumen de algunos trabajos similares al presentado en este trabajo, en el punto 4 se explica la herramienta presentada, junto con la descripción de cada una de las salidas, luego en el punto 5 se explica otra aplicación que sirve para analizar los resultados obtenidos, y por último en el punto 6 se exponen las propuestas a trabajos futuros.

2. Marco Teórico

En este apartado se introducen algunos conceptos básicos sobre los temas que abarca este trabajo. Se describen brevemente cada uno de ellos.

2.1 Sistema de Recuperación de Información

Un SRI puede definirse como la representación, almacenamiento, organización y el acceso a elementos de

información [1]. Estos sistemas permiten la recuperación de los documentos, previamente almacenados, por medio de consultas. Salton piensa que "cualquier SRI puede ser descrito como un conjunto de ítems de información (Documentos), un conjunto de peticiones (Queries) y algún mecanismo (Procesador) que determine qué ítems satisfacen las necesidades de información expresadas por el usuario en la petición" [9].

Los autores Gabriel Tolosa y Fernando Bordignon [10], dan una clasificación de los documentos en estructurados y no estructurados tal como se puede visualizar en la Figura 1. Los primeros son aquellos en los que se pueden reconocer elementos estructurales con una semántica bien definida, mientras que los segundos corresponden a texto libre, sin formato. De acuerdo a esta clasificación se puede diferenciar distintos modelos de recuperación de información, de acuerdo a características estructurales de los documentos.

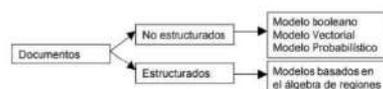


Figura 1. Modelos de SRI. [10]

En este trabajo, sólo se hace referencia al modelo vectorial.

2.2 El Modelo Vectorial

El modelo vectorial de recuperación de información fue presentado por Gerard Salton en 1975 y posteriormente asentado en 1983 junto con McGill [11-12]. Propone un marco en el que es posible el emparejamiento parcial a diferencia del modelo de recuperación booleano, asignando pesos no binarios a los términos índice de las preguntas y de los documentos. Estos pesos de los términos se usan para computar el grado de similitud entre cada documento guardado en el sistema y la pregunta del usuario [4][5].

El modelo vectorial se basa en el grado de similaridad de una consulta dada por el usuario con respecto a los documentos de la colección cuyos términos fueron ponderados mediante TF-IDF (del inglés Term frequency – Inverse document frequency), frecuencia de término – frecuencia inversa de documento (o sea, la frecuencia de ocurrencia del término en la colección de documentos), es una medida numérica que expresa cuán relevante es una palabra para un documento en un corpus [11-13]. Esta medida se utiliza a menudo como un factor de ponderación en los SRI. La forma más natural de describir un documento es a través de los términos que lo componen, mientras más palabras se utilicen, más oportunidades habrá de recuperar un documento. Entonces, esta medida, pondera el uso de una determinada palabra dentro de un conjunto de documentos. Supone que dependiendo de dicho valor un elemento es importante y relevante para la clasificación de documentos frente a la consulta de un usuario. Este indicador se obtiene con el producto entre TF y IDF ($TF \times$

¹ Porcentaje de documentos relevantes recuperados, sobre el total de documentos relevantes que hay.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

IDF). A continuación, se busca clarificar la esencia de ambos conceptos:

- **TF: Frecuencia de términos**, es la cantidad de veces que aparece dicho término en dicho documento. TF puede calcularse de manera «sencilla» como el número de veces que se repite un término en un documento o de formas mucho más complejas con expresiones matemáticas como operadores booleanos o logaritmos.

$$TF = \frac{N^{\circ} \text{ Total del término en el documento}}{N^{\circ} \text{ Total de palabras en el documento}}$$

- **IDF: Frecuencia inversa de documento**, se utiliza para disminuir el peso de aquellos términos que son muy frecuentes en varios textos que se están considerando. Igualmente, en este caso puede expresarse matemáticamente con expresiones que incluyen logaritmos o de manera simplificada:

$$IDF = \frac{N^{\circ} \text{ Total de documentos}}{N^{\circ} \text{ de documentos con el término buscado}}$$

Ejemplo de cálculo del TF*IDF:

Suponiendo que se está leyendo un documento de 100 palabras dónde la palabra «rio» aparece 3 veces.

El TF se calcularía: $TF = 3/100 = 0,03$

Se encuentran 10 millones de documentos y donde la palabra «rio» supongamos aparece en 1.000.

El IDF se calcularía: $\log_2(10.000.000/1.000) = 4$

Finalmente al aplicar la expresión completa del TF-IDF se obtiene: $TF \times IDF = 0,03 \times 4 = 0,12$

Resumiendo, esto significa que un factor que indique la frecuencia de un término debe estar presente en una métrica de documentos o de consultas. El valor TF-IDF aumenta proporcionalmente al número de veces que una palabra aparece en el documento, pero es compensada por la frecuencia de la palabra en la colección de documentos, lo que permite manejar el hecho de que algunas palabras son generalmente más comunes que otras [13].

La idea básica del modelo vectorial reside en la construcción de una matriz (comúnmente llamada matriz de términos/documentos), donde las filas fueran estos últimos y las columnas correspondieran a los términos incluidos en ellos. Las filas de esta matriz (que en términos algebraicos se denominan vectores) serían equivalentes a los documentos que se expresarían en función de las apariciones (frecuencia) de cada término. De esta manera, un documento podría expresarse de la siguiente manera: $d_1 = (1, 2, 0, 0, 0, \dots, 1, 3)$: Siendo cada uno de estos valores el número de veces que aparece cada término en el documento. La longitud del vector de documentos sería igual al total de términos de la matriz (el número de columnas). De esta manera, un conjunto de m documentos se almacenaría en una matriz de m filas por n columnas, siendo n el total de términos almacenados en ese conjunto de documentos [12].

Para definir la distancia entre dos vectores en R^2 , se utilizará R^2 como modelo. La fórmula de la distancia en geometría analítica nos dice que la distancia d entre dos puntos en el plano, (u_1, u_2) y (v_1, v_2) , es: [13]

$$d = \sqrt{(u_1 - v_1)^2 + (u_2 - v_2)^2}$$

En terminología vectorial, esta distancia puede considerarse como la longitud de $u-v$, donde $u = (u_1, u_2)$ y $v = (v_1, v_2)$, como se observa en la Figura 2. Es decir,

$$\|u - v\| = \sqrt{(u_1 - v_1)^2 + (u_2 - v_2)^2}$$

lo cual conduce a la siguiente definición.

$$d(u, v) = \|u - v\| = \sqrt{(u_1 - v_1)^2 + (u_2 - v_2)^2}$$

Esta función, aplicada a 3 o más dimensiones, es una generalización del teorema de Pitágoras y se denomina distancia euclidiana.

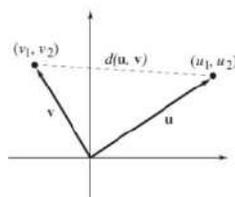


Figura 2. Distancia entre dos vectores [13]

Volviendo a los SRL en el modelo vectorial, los pesos de los términos se emplean para calcular la similitud entre los documentos y las consultas [12]. Este modelo ordena los documentos recuperados de manera decreciente de acuerdo, al grado de similitud. Los documentos y consultas son representados como vectores de dimensión t (número total de términos en la colección) y una forma de calcular la similitud es con el 1-coseno del ángulo entre el vector que representa a la consulta y el que representa al documento. Figura 3. En la imagen que pueden observar los vectores d_1 , d_2 y q , que representan a los documentos 1, 2 y a la consulta respectivamente. Estos vectores son números que tienen una magnitud y una dirección. Tanto la magnitud como la dirección deben medirse con respecto al espacio en el que se define el vector. Cada dimensión del espacio representa una característica de interés y un vector representa la medida en que el objeto del modelo tiene esas características. Por tanto, un vector es una lista de números: uno para cada característica que forma parte del espacio modelo. La dirección del vector es la que va desde el origen del espacio hasta el punto definido por esos números.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

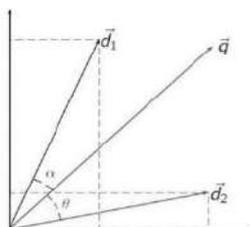


Figura 3. Representación de objetos en el modelo vectorial [12]

Dentro de esta clasificación, como modelo alternativo, está el modelo de Indexación Semántica Latente (Latent Semantic Indexing, LSI) [4] que descansa sobre la Descomposición de Valores Singulares (en inglés Singular Value Decomposition, SVD) [5] que es una técnica de factorización de matrices que permite descomponer una matriz. La SVD permite construir una nueva matriz de menor rango que la original y que entre todas ellas sea la de menor distancia euclídea de la matriz original. Esta reducción de rango permite disminuir la dimensión de los vectores representativos de los documentos. Como se verá más adelante la reducción de dimensión en la representación de documentos es esencial para la efectividad de la técnica propuesta.

Con la LSI se pretende la resolución de perturbaciones en la recuperación de información debido a problemas de sinonimia y polisemia o equivoicidad del habla corriente. Por ejemplo, si se desea buscar la palabra "estación", la cual tiene múltiples significados (polisemia) una búsqueda literal de la palabra produciría muchos resultados posibles (estación de tren, estación del año, etc.). Si lo que se desea buscar es "estación del año", podrían interesar resultados de palabras distintas, pero con un significado igual o similar, por ejemplo "temporada", "época" y así por el estilo (sinonimia). La LSI permite la búsqueda por conceptos o definiciones (en contraposición a la búsqueda literal). En este punto, interesa aclarar al lector, acerca del término "orientaciones temáticas", que es utilizado para hacer referencia a la cantidad de características numéricas del vector. Resumiendo, ese número representa que, palabras que se utilizan en un mismo contexto tiene significados similares en un SRI y esto permite identificar patrones entre los términos contenidos en una colección de textos.

En [14], los autores señalan que, son varias las investigaciones, donde se aplica la búsqueda por similitud o por proximidad para recuperar dentro de bases de datos métricas, objetos que resulten parecidos o relevantes a una determinada consulta. Este proceso se modela matemáticamente a través de un espacio métrico, en el cual los objetos son representados como una caja negra donde la única información disponible es la distancia de este objeto a los otros.

2.3 Espacios Métricos: Generalidades

En [15], se encuentra una definición dada por el matemático francés Maurice Fréchet: un espacio métrico es un par (X, d) , donde X es un conjunto arbitrario no vacío y $d : X \times X \rightarrow \mathbb{R}_{\geq 0}$ una aplicación, llamada distancia o métrica, tal que, para cualesquiera $x, y, z \in X$, se verifica:

$$(1) d(x, y) \geq 0. \quad (1)$$

$$(2) d(x, y) = 0 \Leftrightarrow x = y. \quad (2)$$

$$(3) d(x, y) = d(y, x). \quad (3)$$

$$(4) d(x, z) \leq d(x, y) + d(y, z) \quad (4)$$

Los métodos tradicionales de búsqueda están orientados al tratamiento de datos con una estructura determinada, generalmente mediante atributos que reflejan las propiedades de los objetos y son representados mediante registros almacenados en la base de datos. Las búsquedas en este contexto, donde los atributos son generalmente de tipo estructurado (numérico, alfanumérico, de tiempo, entre otros), están basadas en la búsqueda exacta y sus variantes de búsqueda por rango. Ésta última se realiza entre valores determinados, restringiéndose la igualdad a unas posiciones determinadas, por ejemplo, consultar por una cadena alfanumérica con algunos caracteres específicos [15].

Los objetos multimedia utilizados en las aplicaciones actuales son tipos de datos no estructurados, éstos pueden ser imágenes, videos, audio, documentos de texto, secuencias de ADN, entre otros [16]. Generalmente no poseen una estructura determinada, razón por la cual una búsqueda total exacta es inaplicable. Los datos multimedia presentan una gran dificultad para reproducirse en las mismas condiciones (por ejemplo: dos imágenes tomadas de una misma escena casi nunca son exactamente iguales), siendo muy sensibles a situaciones de ruido, distorsiones, entre otras degradaciones. Por estos motivos, si se desea buscar un objeto multimedia en una base de datos, se debe realizar a través de una búsqueda por similitud, es decir determinar cuáles son los elementos más semejantes, parecidos o "cercaños" a algún otro, definido como objeto de consulta [16].

Por lo expuesto hasta el momento, se puede decir que, los espacios métricos pueden ser de dimensión infinita. Una base de datos métrica es realmente un espacio vectorial de dimensión finita D , donde los elementos son vectores de coordenadas reales, es decir elementos de \mathbb{R}^D . Alrededor de este modelo de datos se han realizado muchos desarrollos, tanto de índices y operaciones, como de lenguajes de consulta. Sin embargo, generalmente estos desarrollos no pueden ser extendidos a las bases de datos métricas, donde sólo se dispone de la información de distancia entre los objetos [16].

2.4 Espacios normados

Una norma en un espacio vectorial X es una aplicación $\| \cdot \| : X \rightarrow \mathbb{R}$, que a cada vector $x \in X$ hace corresponder un número real no negativo $\|x\|$, verificando las tres condiciones siguientes:



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

(N.1) Desigualdad triangular:

$$|x+y| \leq |x|+|y| \quad \forall x,y \in X \quad (5)$$

(N.2) Homogeneidad por homotecias:

$$|\lambda \cdot x| = |\lambda| \cdot |x| \quad \forall x \in X, \forall \lambda \in \mathbb{R} \quad (6)$$

(N.3) No degeneración:

$$x \in X, |x| = 0, \text{ si y sólo si } x = 0 \quad (7)$$

Un espacio normado es un espacio vectorial X , en el que se ha fijado una norma $\|\cdot\|$. Para cada $x \in X$, se dice también que el número real $|x|$ es la norma del vector x . En este trabajo, se utilizarán las normas 1, 2 y 4. A continuación se expresan sus respectivas fórmulas:

La norma $\|1\|$ viene dada por

$$\|X\|_1 = \sum_{i=1}^n |x_i|$$

La norma $\|2\|$ o norma Euclídeana es dada por:

$$\|X\|_2 = \left(\sum_{i=1}^n x_i^2 \right)^{1/2}$$

Por último, la norma 4.

$$\|X\|_4 = \left(\sum_{i=1}^n x_i^4 \right)^{1/4}$$

2.5 Introducción al Aprendizaje Automático

El aprendizaje automático o aprendizaje de máquinas (del inglés, machine learning ML), es una rama de la Inteligencia Artificial (IA), cuyo objetivo es desarrollar sistemas que aprendan, o mejoran el rendimiento, en función de los datos que consumen. Estas técnicas permiten hacer predicciones, frecuentemente precisas a partir de observaciones con datos previos [8]. Podemos considerar tres tipos de aprendizajes:

- **Aprendizaje supervisado:** Se dispone de un conjunto de datos (llamados de entrenamiento) y cada dato está asociado a una etiqueta o clase. Se construye un modelo que en una fase de entrenamiento (training) utiliza dichas etiquetas, para determinar si el dato está clasificado correctamente o incorrectamente por el modelo. La idea es que se utilice el modelo para clasificar nuevos datos que no cuenten con etiqueta.
- **Aprendizaje no supervisado:** los datos no tienen etiquetas (o no queremos utilizarlas) y estos se clasifican a partir de su estructura interna de los mismos (propiedades, características).
- **Aprendizaje por refuerzo:** algunos datos de entrenamiento tienen etiquetas, pero no todos.

Este trabajo hace referencia solamente al algoritmo de clasificación no supervisado K-means.

El algoritmo K-means o K-medias es un método de agrupamiento que divide un conjunto de n observaciones en k grupos distintos gracias a valores medios. Como ya se

comentó, pertenece al ámbito de los algoritmos No Supervisados, ya que las n observaciones no cuentan con un atributo clase o etiqueta, que nos diga de qué grupo es cada dato, siendo los datos agrupados según sus propiedades o características [17].

El agrupamiento de las n observaciones en los k grupos distintos se realiza minimizando la suma de distancias entre cada observación y una ubicación real o imaginaria que representa el centro del grupo. Cada punto de datos se asigna a cada uno de los grupos mediante la reducción de la suma de cuadrados en el grupo. A esta ubicación se la denomina centroide. La distancia más común es la distancia euclídea. El algoritmo cuenta con tres pasos:

- **Inicialización:** una vez escogido k (número de grupos), se establecen los centroides en el espacio de los datos, por ejemplo asignando los k puntos aleatoriamente.
- **Asignación de las observaciones a los centroides:** cada observación es asignada al centroide más cercano a ella usando la medida de distancia que se determine.
- **Actualización de los centroides:** se actualiza la posición de los centroides de cada grupo tomando como posición la media de la localización de las observaciones de dicho grupo.

Se repiten los pasos 2 y 3 hasta que los centroides se quedan fijos, o se mueven por debajo de una distancia umbral fijada [18]. En la siguiente figura se explica el funcionamiento del algoritmo, la imagen fue obtenida de [18], los ejemplos de entrenamiento se muestran como puntos y los centroides de clúster se muestran como cruces.

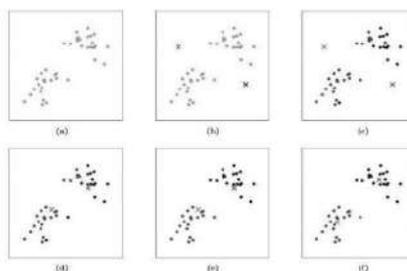


Figura 4. Secuencia del algoritmo K-means [18]

En esta Figura se observa, en un espacio bidimensional, las siguientes secuencias: (a) el conjunto de datos original; (b) centroides de grupos iniciales aleatorios; (c-f) ilustración de ejecutar dos iteraciones de K-means. En cada iteración, se asignó cada ejemplo de entrenamiento al centroide de clúster más cercano (que se muestra al "pintar" los ejemplos de entrenamiento del mismo color que el centroide de clúster al que está asignado); luego se mueve cada centroide de grupo a la media de los puntos asignados a él.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

3. Trabajos relacionados

Existen varios trabajos que siguen la idea de segmentar o agrupar, utilizando alguna técnica de IA, un repositorio de documentos.

- En [19] se examina el uso de algoritmos genéticos (GA) y programación genética (GP) para aprender algoritmos aplicados en SRI. La ponderación de la estructura del documento es una técnica mediante la cual las diferentes partes de un documento (título, resumen, etc.) contribuyen de manera desigual al peso general del documento durante la clasificación.
- En [20], este artículo describe los enfoques más destacados para aplicar IA en un SRI. El buscador de formular una consulta tratando de describir su necesidad de información. La consulta se compara con vectores de documentos que se extrajeron durante una fase de indexación. Se utiliza la función de similitud del coseno para determinar los documentos más similares, así el usuario puede evaluar la relevancia con respecto a su problema.
- Clusterdoc [21]: es un sistema de recuperación y recomendación de documentos que está dirigido a usuarios con necesidades de búsqueda de información, que a través de algoritmos de agrupamiento divide el conjunto de datos en pequeños grupos con características comunes, lo cual permite minimizar el espacio de búsqueda y proporcionar información adaptada a los intereses del usuario.

4. Caso de Estudio

Se presenta una herramienta que se programó en lenguaje C++. Un fragmento del mismo se puede ver en la Figura 5. Se empleó el entorno de desarrollo integrado (IDE), que es una aplicación de software que ayuda a los programadores a desarrollar código de software de manera eficiente, Code-Block². El nombre del programa es RedDocxx.cpp. Donde xx es la versión del mismo.

```
int main() {
    printf("Con que prefijo quiere las
    salidas: ");
    fgets(pre, 10, stdin);
    if( pre[strlen(pre)-1] == '\n' )
        pre[strlen(pre)-1] = '\0';
    strcat(pre, "_");
    lpre = strlen(pre);
    printf("Cuantas orientaciones
    tematicas tienen los documentos?");
    scanf("%d", &K0);
    printf("Cuantos documentos tiene el
    corpus? ");
    scanf("%d", &Z[0].N);
    do {
```

² <https://www.codeblocks.org/>

```
printf(" Cuantos casos de
prueba (<=5)? ");
scanf("%d", &N_pr); }
while( N_pr > 5 );
printf("Puede fijar la semilla
del azar (0=no fijar): ");
scanf("%d", &Z[0].sem_doc);
if(Z[0].sem_doc)
    srand( Z[0].sem_doc );
```

Figura 5. Segmento de código fuente, mostrando el pedido de los parámetros iniciales.

Con los datos pedidos en el inicio del programa, los cuales son:

- **Prefijo de Salida:** Prefijo que se aniepondrá a los nombres que tendrán los archivos resultantes del proceso. Por ejemplo el prefijo 300K1, podría referirse a un lote de 300.000 documentos, realizado con norma 1. Elegir prefijos con semántica, facilita su manipuleo posterior, pero no es una exigencia. El cálculo no está influenciado por el prefijo. Es un recurso de orden práctico para que resultados de distintas simulaciones no se pisen en la memoria.
- **Cantidad de orientaciones temáticas:** Este valor representa la cantidad de dimensiones del vector. A este vector se lo denomina también perfil del documento.
- **Cantidad de documentos del corpus.** Si bien la experimentación esta planteada para un SRI, se podría usar para cualquier otro universo de objetos.
- **Cuantos casos de prueba.** Son las consultas que se crearan para validar la experimentación. Hubiera sido correcto en un sistema en producción pedir esto una vez armado el modelo, pero durante su gestión permitía ver resultados aun en ejecuciones abortadas por algún error.
- **Puede fijar la semilla del azar.** Al ser una simulación, se recurre al pseudoazar en diversos momentos para la generación de los perfiles, las consultas e inicializar el algoritmo Kmeans. Se utiliza la función rand() del lenguaje C++, esta arranca con semilla propia, pero puede ser cambiada. Esto permite repetir una experiencia con distinto azar. En la Figura 6 se observa como el sistema interactua en el pedido de los datos de entrada.

Figura 6. Pedido de valores de entrada

Luego del ingreso de estos valores iniciales, el programa crea los objetos (documentos y consultas). Después de cada (re-)distribución se actualiza el centroide tomando el centro



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

de gravedad (o sea la media) del grupo la cantidad de centroides a utilizar se solicita las siguientes preguntas:

- **Cuántos grupos quiere formar?:** En este ejemplo, para los 300.000 documentos se configuraron 30.000 grupos.
- **Puede fijar la semilla del azar para elegir semillas (0=no fijar):** Idem al punto anterior.
- **Cuántos quiere listar en las recuperaciones:** Frente a cada pregunta, se examinará el contenido de los grupos cuyos centroides quedan más cercanos. Estos serán ordenados mediante esta distancia. Este valor limita cuantos serán examinados en detalle. Con esto se evita listados voluminosos.
- **Quiere controlar las iteraciones (S) o las deja librado al sistema (N)?:** Esta última pregunta, se realiza en todos los niveles. La información intermedia permite ver los tamaños de los grupos y da pie a cambiar parcial o totalmente las semillas del K-means. La experiencia ha demostrado que cambiarlas no introduce mejora sensible por lo tanto para producir las tablas de este escrito se ha renunciado a la posibilidad de intervenir. La segunda pregunta se refiere a la terminación. Tal como se explicó se puede dar por terminado cuando no se produzcan cambios o cuando estos estén por debajo de un umbral. Cuando queda liberado al sistema este reitera hasta la ausencia de cambios.

Por ejemplo, si el primer grupo, o sea el 0, contiene 3 documentos y estos ocupan los lugares 170, 340, 1720, entonces en una estructura "direc" se guardan los números 170, 340, 1720, (quedaron en orden creciente aunque ello no tiene ninguna implicación) a continuación irán los números de los que ocupan el grupo 1 y así sucesivamente. Para poder acceder rápidamente a uno de los grupos se necesita saber donde comienza y donde termina aunque queda claro que termina donde empieza el grupo siguiente. En una estructura QA (cantidades acumuladas) se guarda la posición del primer elemento de cada grupo. Y para uniformar la lógica de consulta se agrega con un grupo adicional ficticio, el fin del último grupo. Si hay K grupos hay K+1 inicios. Siempre QA[0]=0 y QA[K]=N (K es la cantidad de grupos del K-means y N la cantidad de documentos). El programa permite establecer, varios niveles de recuperación de documentos. En el nivel siguiente N será la cantidad de centroides del primer agrupamiento y K la cantidad de grupos en el segundo nivel. De cada elemento se guarda su ubicación en un vector de tamaño N, al cual se denomina "esta_en[]", con lo cual se da la siguiente redundancia:

Para todo x almacenado en direc entre las posiciones QA[g] y QA[g+1] esta_en[x]=g o poniendo más variables:

Para todo x, y y g se satisface que: QA[g] <= y < QA[g+1] & direc[y] = x => esta_en[x] = g (8)

El sistema genera una serie de archivos, que como se comentó, llevan todos el mismo prefijo elegido por el usuario. Para este caso de estudio 300K1. En la Figura 7 se muestra el archivo "300K1_resumen".

```

NORMA1
50 orientaciones temáticas
Un corpus con 300000 documentos simulados
Se fija la semilla del azar en 0
Será evaluado con 5 casos de prueba.
Se recuperara hasta la respuesta 100a.
Se ha fijado 30000 grupos en el primer nivel con semilla 0.
Se listarán 5000 grupos en las recuperaciones.
Se ha fijado 3000 grupos en el segundo nivel con semilla 0.
Se listarán 170 grupos en las recuperaciones.
Se ha fijado 300 grupos en el tercer nivel con semilla 0.
Se listarán 60 grupos en las recuperaciones.
Se ha fijado 30 grupos en el cuarto nivel con semilla 0.
Se listarán 18 grupos en las recuperaciones.
Se ha fijado 3 grupos en el quinto nivel con semilla 0.
Se listarán 2 grupos en las recuperaciones.
Ejecución finalizada por el usuario.
Ln:8 Col:8 100% UNIX(LF) UTF-8
  
```

Figura 7. Vista del archivo 300K1_resumen.

El primer dato que aparece es Norma1, recordar que una norma es una diferencia de distancia.

El archivo "300K1 Ubicacion de cada documento en la respuesta a la consulta #1", asigna el ordinal [1;300000] que debiera ocupar cada documento basandose en su distancia a la consulta #1. Figura 8.

```

000000 39489 117252 388382 242766 146416 25113 82528 273690 289767 105406
000010 25914 27293 291633 189402 208236 59672 84899 212127 224944 72986
000020 50088 257577 385825 183046 255973 291945 10838 236680 296255 91222
000030 196491 135469 13809 13435 235594 278756 369297 186485 227246 139281
000040 163851 248891 269316 295991 67813 198581 133843 196546 294182 19824
000050 159831 296336 113751 58137 208656 257576 384216 187652 71712 188378
000060 209579 295223 174558 90989 281272 152759 337421 232035 15786 65839
000070 297729 152297 283708 164316 183880 222795 98984 163344 53188 183119
000080 69891 175074 183411 6730 219700 133253 46387 148348 293153 80100
000090 182221 181458 96484 79868 93770 136563 78785 281454 178899 160870
000100 122229 184516 142332 24932 249139 158998 166567 173381 295881 22181
Ln:1 Col:1 100% UNIX(LF) UTF-8
  
```

Figura 8. Vista del archivo 300K1_Ubicacion de cada documento en la respuesta a la consulta #1.

El archivo "300K1_fronteras de los grupos del primer nivel", permite controlar que todo es coherente. Como hay 30000 grupos ocupa un solo renglón. Si el valor es de 5 dígitos que van desde 00000 hasta 29999. Este valor designa la ubicación en el archivo del primer elemento, por ejemplo 1380 el que está a su derecha ocupa el lugar 1381 el siguiente 1382 y así hasta el último que ocupa el lugar 1389. En esta tabla por diferencia de dos valores consecutivo se sabe el tamaño de un grupo. Figura 9.

```

Estas son las fronteras de los integrantes del primer nivel si estuvieran
ordenados por región o la cual pertenecen
es la tabla [0]-QA creciente de 0 a 300000.
000000 0 14 28 42 56 70 84 98 112 126 140 154 168 182 196 210 224 238 252 266 280 294 308 322 336 350 364 378 392 406 420 434 448 462 476 490 504 518 532 546 560 574 588 602 616 630 644 658 672 686 700 714 728 742 756 770 784 798 812 826 840 854 868 882 896 910 924 938 952 966 980 994 1008 1022 1036 1050 1064 1078 1092 1106 1120 1134 1148 1162 1176 1190 1204 1218 1232 1246 1260 1274 1288 1302 1316 1330 1344 1358 1372 1386 1400 1414 1428 1442 1456 1470 1484 1498 1512 1526 1540 1554 1568 1582 1596 1610 1624 1638 1652 1666 1680 1694 1708 1722 1736 1750 1764 1778 1792 1806 1820 1834 1848 1862 1876 1890 1904 1918 1932 1946 1960 1974 1988 2002 2016 2030 2044 2058 2072 2086 2100 2114 2128 2142 2156 2170 2184 2198 2212 2226 2240 2254 2268 2282 2296 2310 2324 2338 2352 2366 2380 2394 2408 2422 2436 2450 2464 2478 2492 2506 2520 2534 2548 2562 2576 2590 2604 2618 2632 2646 2660 2674 2688 2702 2716 2730 2744 2758 2772 2786 2800 2814 2828 2842 2856 2870 2884 2898 2912 2926 2940 2954 2968 2982 2996 3010 3024 3038 3052 3066 3080 3094 3108 3122 3136 3150 3164 3178 3192 3206 3220 3234 3248 3262 3276 3290 3304 3318 3332 3346 3360 3374 3388 3402 3416 3430 3444 3458 3472 3486 3500 3514 3528 3542 3556 3570 3584 3598 3612 3626 3640 3654 3668 3682 3696 3710 3724 3738 3752 3766 3780 3794 3808 3822 3836 3850 3864 3878 3892 3906 3920 3934 3948 3962 3976 3990 4004 4018 4032 4046 4060 4074 4088 4102 4116 4130 4144 4158 4172 4186 4200 4214 4228 4242 4256 4270 4284 4298 4312 4326 4340 4354 4368 4382 4396 4410 4424 4438 4452 4466 4480 4494 4508 4522 4536 4550 4564 4578 4592 4606 4620 4634 4648 4662 4676 4690 4704 4718 4732 4746 4760 4774 4788 4802 4816 4830 4844 4858 4872 4886 4900 4914 4928 4942 4956 4970 4984 4998 5012 5026 5040 5054 5068 5082 5096 5110 5124 5138 5152 5166 5180 5194 5208 5222 5236 5250 5264 5278 5292 5306 5320 5334 5348 5362 5376 5390 5404 5418 5432 5446 5460 5474 5488 5502 5516 5530 5544 5558 5572 5586 5600 5614 5628 5642 5656 5670 5684 5698 5712 5726 5740 5754 5768 5782 5796 5810 5824 5838 5852 5866 5880 5894 5908 5922 5936 5950 5964 5978 5992 6006 6020 6034 6048 6062 6076 6090 6104 6118 6132 6146 6160 6174 6188 6202 6216 6230 6244 6258 6272 6286 6300 6314 6328 6342 6356 6370 6384 6398 6412 6426 6440 6454 6468 6482 6496 6510 6524 6538 6552 6566 6580 6594 6608 6622 6636 6650 6664 6678 6692 6706 6720 6734 6748 6762 6776 6790 6804 6818 6832 6846 6860 6874 6888 6902 6916 6930 6944 6958 6972 6986 7000 7014 7028 7042 7056 7070 7084 7098 7112 7126 7140 7154 7168 7182 7196 7210 7224 7238 7252 7266 7280 7294 7308 7322 7336 7350 7364 7378 7392 7406 7420 7434 7448 7462 7476 7490 7504 7518 7532 7546 7560 7574 7588 7602 7616 7630 7644 7658 7672 7686 7700 7714 7728 7742 7756 7770 7784 7798 7812 7826 7840 7854 7868 7882 7896 7910 7924 7938 7952 7966 7980 7994 8008 8022 8036 8050 8064 8078 8092 8106 8120 8134 8148 8162 8176 8190 8204 8218 8232 8246 8260 8274 8288 8302 8316 8330 8344 8358 8372 8386 8400 8414 8428 8442 8456 8470 8484 8498 8512 8526 8540 8554 8568 8582 8596 8610 8624 8638 8652 8666 8680 8694 8708 8722 8736 8750 8764 8778 8792 8806 8820 8834 8848 8862 8876 8890 8904 8918 8932 8946 8960 8974 8988 9002 9016 9030 9044 9058 9072 9086 9100 9114 9128 9142 9156 9170 9184 9198 9212 9226 9240 9254 9268 9282 9296 9310 9324 9338 9352 9366 9380 9394 9408 9422 9436 9450 9464 9478 9492 9506 9520 9534 9548 9562 9576 9590 9604 9618 9632 9646 9660 9674 9688 9702 9716 9730 9744 9758 9772 9786 9800 9814 9828 9842 9856 9870 9884 9898 9912 9926 9940 9954 9968 9982 9996 10000
Ln:1 Col:1 100% UNIX(LF) UTF-8
  
```

Figura 9. Vista del archivo 300K1_fronteras de los grupos del primer nivel.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

Universidad Tecnológica Nacional
3 y 4 de noviembre de 2022

AJEA - Actas de Jornadas y Eventos Académicos de UTN
DOI: <https://doi.org/10.33414/ajea.1146.2022>

Los "QA" se volcaron en archivos como "300K1_Ubicacion respetando grupos del primer nivel", "... del segundo nivel", etc. Figura 10.

```

300K1_Ubicacion respetando grupos del primer nivel
De donde sacar del primer nivel de abajo para que desde segundo nivel se tenga consecutivos. Esto lo describe "[0].dirsc"
000000 8192 39399 23352 13096 6625 72423 87525 118757 156985 164857
000010 21713 222152 252935 296729 6382 30682 33562 47756 48953 62965
000020 109120 148813 170130 172238 176118 179419 227562 279972 41122 116562
000030 140336 152816 166334 170828 208303 248221 287960 4207 16929 51239
000040 74802 102252 122866 179722 206522 209642 92836 14101 135829 157469
000050 174395 189931 192084 213495 225110 237667 244332 273300 286115 112296
000060 145429 146461 206628 254485 283122 286267 12657 18206 28543 72881
000070 108459 113661 113952 215688 300 13762 22528 16865 7525 77683
000080 133496 150641 162675 207991 265138 54804 55887 72795 93489 185563
000090 112787 122756 155974 165862 166195 193963 225887 215257 244644 253904
000100 43985 80660 84952 131648 168176 194191 196285 216238 263188 288310
Ln:1, Col:1 100% (UNIX) UTF-8

```

Figura 10. Archivo 300K1 Ubicacion respetando grupos del primer nivel.

Esta salida va en combinación con la figura anterior. Permite encontrar los documentos de cada grupo. La anterior te dijo que el grupo 0 tiene 14 elementos. Se puede observar que del lugar 0 al 14 hay una secuencia creciente de 14 valores. Que sea creciente no tiene ninguna importancia, es fruto del algoritmo de llenado. Detrás empieza otra secuencia con los integrantes del grupo 1.

Los "esta en" se volcaron como "300K1_grupo del primer nivel al cual pertenece cada documento", etc. Como hay 30000 grupos en el primer nivel y allí se repartieron los 300000 documentos, en "[0].esta_en" se describe a que grupo pertenece cada documento.

Esta salida no depende de la consulta, servirá para verificar el contenido de los grupos. Tal vez haya tablas en exceso, fruto de en el momento de armarlas aún no se sabía exactamente cuáles eran imprescindibles.

```

300K1_grupo del primer nivel al cual pertenece cada documento
000000 26225 8999 116655 22846 19181 27743 4202 451 23769 22228
000010 13452 10673 7534 27861 11559 17990 12947 3050 4281 13824
000020 13852 17536 21344 6034 10844 14436 12982 8304 2689 24468
000030 15947 2677 27136 13284 21954 29665 10683 7812 1896 7569
000040 29689 29689 29707 6428 10844 13957 9879 12390 21553 16128
000050 9635 7888 4249 1816 16471 18518 11674 4971 11465 13294
000060 4386 16762 21934 26500 8727 11345 10228 20950 26617 9423
000070 10532 20166 24548 28179 21195 29398 14771 1723 3883 23612
000080 14886 4178 23465 2050 84 17933 18539 26427 20514 16098
000090 18 25812 4578 14866 9214 19201 9999 7726 24352 16132
000100 7 29781 15245 12329 8118 24076 9844 17345 6063 26582
Ln:1, Col:1 100% (UNIX) UTF-8

```

Figura 11. Resumen del archivo 300K1_grupo del primer nivel al cual pertenece cada documento.

El archivo "300K1 Respuesta usando centroides de primer nivel a la consulta #1", lista los documentos rescatados identificados por su ubicación en la respuesta ideal.

```

300K1_Respuesta usando centroides de primer nivel a la consulta #1
1 el centroide 426280 a distancia 2.716765 de la consulta con 16 documentos y radio 3.188962
00 2 17 10 38 37 76 98 249 493 1488
18 2361 8407 6168 14787 20956 18535
...
2 el centroide 813567 a distancia 3.837605 de la consulta con 14 documentos y radio 3.418283
00 76 108 446 589 903 2722 3765 4293 5384 7585
18 13256 24838 30798 77844
...
300 el centroide 811980 a distancia 1.882846 de la consulta con 14 documentos y radio 2.944384
00 850 1116 1152 812 6571 5999 14984 15195 18979 40561
18 40414 71938 99327 10201
Ln:1, Col:1 100% (UNIX) UTF-8

```

Figura 12. Resumen del archivo 300K1 Respuesta usando centroides de primer nivel a la consulta #1.

Por último, el archivo "300K1_Documentos ordenados tal como van en la respuesta ideal a la consulta #1", para que el usuario no se pierda buscando valores en tablas, donde los subíndices empiezan en 0, se lista 10 documentos por fila. Esta característica la tienen todas las tablas en su formato de impresión. Si se busca el 2º documento se sabe que está en la fila encabezada por 20. Si la tabla fuera más grande habría empezado con 000, 010, 020.

```

300K1_Documentos ordenados tal como van en la respuesta ideal a la consulta #1
000010 11789 34393 72455 176631 242288 232348 64782 245986 7835 125938
000020 214938 40586 14812 174620 74663 34514 169996 140411 73030 157441
000030 296755 930 287559 178335 208275 49424 212343 58264 271753 138179
000040 230754 308064 185895 113550 133838 18824 15692 151130 286482 292995
000050 120168 146066 259449 265345 163148 282179 287194 17818 269128 212376
000060 225483 380725 67809 248337 114821 248837 116478 114395 146167 59811
000070 68623 129553 251629 259741 19529 32893 48318 41832 219876 191175
000080 169663 195541 211793 177201 277066 157487 217629 182729 279944 183851
000090 133776 187188 298815 153928 88310 182560 306112 98797 208965 37627
000100 36812 238574 254882 98113 184918 785110 167553 60792 240876 208288
...
299990 144887 120940 163489 128150 68812 281991 196676 830 143786 249870

```

Figura 13. Resumen del archivo 300K1_Documentos ordenados tal como van en la respuesta ideal a la consulta #1.

La idea de este primer programa, es crear una estructura se facilite a los usuarios correr diferentes consultas. Las consultas se enfrentan con todos los documentos y de acuerdo a su distancia se los ordena. En un archivo se dan los números de los documentos empezando por los más cercanos. A la inversa, por cada documento se genera la posición que ocupa en el listado anterior, empezando por esto y todo lo que sigue se hace para cada consulta.

Es de interés saber que pasa si se quisiera decidir la respuesta usando el primer nivel de agrupamiento. Para eso se calcula la distancia de la consulta a los K centroides y con ello se ordenan los K centroides, luego se examina el contenido de los sucesivos centroides identificando los documentos del grupo por la posición que ocupan en la respuesta ideal. Si el centroide más promisorio es por ejemplo el 7 con ayuda de QA[7] y QA[8] se delimitan los direc de los documentos que integran el grupo y consultando la tabla de posiciones de los documentos en la consulta se conocen sus números.



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

5. Resultados y discusiones

Para este trabajo se realizaron varias corridas con 50, 100, 200 y 300 mil documentos. Cada uno de estos ensayos se realizaron con las 3 normas (métrica de distancia) propuestas. Dada la cantidad de archivos resúmenes que arroja RedDocxx.cpp, fue necesario realizar otro programa para que saque, automáticamente, un resumen con la cantidad de documentos que vamos a utilizar para realizar un análisis. Este programa, también se entrega, como parte del trabajo presentado, lee los siguientes archivos para realizar el resumen:

- **resumen**
- **ubicacion respetando grupos del primer nivel:**
- **fronteras de los grupos del primer nivel**
- **Respuesta usando centroides de primer nivel a la consulta #X:** Donde X es el valor ingresado como parámetro.

El archivo resultante de nombre "300k1_k2_Extracto comprimido de primer nivel de la consulta #X", se puede ver en la Figura 14. El valor X, es parte de uno de los parámetro solicitado.

```

C:\Users\...> 300k1_k2_Extracto comprimido de primer nivel de la consulta #X
Contiene los documentos cuyo ordinal no supera a 100
Simulación con 300000 documentos distribuidos en 30000 grupos
Mediante cálculos en 2 por mil de distancias adicionales se ha recuperado:
2 4 14 15 17 18 24 30 31 33 37 39 47 51 58 59 65 67 74 75 81 82 84 90 91 97 100
Mediante cálculos en 4 por mil de distancias adicionales se ha recuperado:
2 4 5 7 14 15 17 18 24 25 30 31 33 34 37 39 42 44 47 48 51 55 58 59 65 67 74 76 81 82 84 85
87 90 91 97 100
Mediante cálculos en 6 por mil de distancias adicionales se ha recuperado:
2 4 5 7 12 14 15 17 18 23 25 30 31 33 34 37 39 42 44 47 48 51 55 58 59 65 67 74 76 81 82 84 85
87 90 91 97 100
Mediante cálculos en 8 por mil de distancias adicionales se ha recuperado:
2 4 5 7 12 14 15 17 18 24 25 30 31 33 34 37 39 42 44 47 48 51 55 58 59 65 67 74 76 81 82 84 85
87 90 91 97 100
Mediante cálculos en 10 por mil de distancias adicionales se ha recuperado:
2 4 5 7 12 14 15 17 18 24 25 30 31 33 34 37 39 42 44 47 48 51 55 58 59 65 67 74 76 81 82 84 85
87 90 91 97 100
Mediante cálculos en 12 por mil de distancias adicionales se ha recuperado:
2 4 5 7 12 14 15 17 18 24 25 30 31 33 34 37 39 42 44 47 48 51 55 58 59 65 67 74 76 81 82 84 85
87 90 91 97 100
Mediante cálculos en 14 por mil de distancias adicionales se ha recuperado:
2 4 5 7 12 14 15 17 18 24 25 30 31 33 34 37 39 42 44 47 48 51 55 58 59 65 67 74 76 81 82 84 85
87 90 91 97 100
Mediante cálculos en 16 por mil de distancias adicionales se ha recuperado:
2 4 5 7 12 14 15 17 18 24 25 30 31 33 34 37 39 42 44 47 48 51 55 58 59 65 67 74 76 81 82 84 85
87 90 91 97 100
Mediante cálculos en 18 por mil de distancias adicionales se ha recuperado:
2 4 5 7 12 14 15 17 18 24 25 30 31 33 34 37 39 42 44 47 48 51 55 58 59 65 67 74 76 81 82 84 85
87 90 91 97 100
se recupera por fin de archivo.
  
```

Figura 14. Resumen del archivo 300K1_Extracto comprimido de primer nivel de la consulta #1.

El programa solicita entonces, una serie de entradas, que se explican a continuación:

- **prefijo de los documentos?** Como se comentó, esto fundamentalmente sirve para poder procesar diferentes lotes y no confundirlos.
- **número de la consulta?.** El sistema procesa hasta un máximo de 5 consultas. Se puede elegir cual de ellas se pretende analizar. Se recuerda que el límite surge por el hecho de procesar las mismas conforme avanzan los niveles. Si se procesara una consulta por completo, antes de procesar otra, su número sería ilimitado.
- **Hasta que ordinal de la respuesta quiere que aparezca (por ej. 100)?:** Como cada grupo entrega en promedio diez documentos, cada uno de los cuales ocupa un lugar en la respuesta ideal. Se considera que respuestas muy alejadas no ofrecen interés. Para poder cuantificar cuantas respuestas útiles se obtienen tal como ilustra la tabla 2 es necesario poner un límite. Sin

un límite las figuras de barras serían imposibles de construir. 100 es un número generoso, significa que devolviendo 10 sugerencias de lectura por pantalla se podría alimentar 10 pantallas.

• **Cada cuantos milésimos quiere ver una respuesta y hasta cuanto?:** Para poder comparar sin la influencia del tamaño del corpus en los resultados, es necesario unificar la métrica. Si se fijara un valor absoluto, por ejemplo midiendo distancias a 1000 documentos, los experimentos con un corpus de 1000 documentos darían un rendimiento del 100%. Es necesario admitir que en un corpus más numeroso es inevitable mirar, o sea, medir distancias a más documentos para obtener los más cercanos. Se puede tomar como comparación, para entender esto la búsqueda en una tabla unidimensional ordenada, a mayor tabla el número de comparaciones aumenta, aunque sea logarímicamente. Para este caso se ha admitido un aumento lineal si bien se espera que con el agregado de más niveles de agrupamiento llegue a ser también logarítmico.

En la siguiente Tabla se muestra el resultado de la ejecución del programa bajo una misma norma y con distintas cantidades de documentos.

Tabla 1. Cantidad de documentos recuperados bajo norma 1, con distintas cantidades de documentos. Elaboración propia.

En 0/000	Cantidad de documentos recuperados bajo norma 1 para corpus de tamaño:			
	50.000	100.000	200.000	300.000
2	8	6	20	27
4	13	14	27	37
6	17	19	31	40
8	21	25	33	44
10	24	29	35	47
12	26	33	37	47
14	30	36	39	48
16	31	38	42	51
18	34	41	45	52
20	34	41	45	54

Esta tabla permite apreciar el crecimiento conforme se miden más distancias y comparando lo recuperado entre dos líneas consecutivas se observa que conforme se avanza los agregados suelen darse preferentemente entre los ordinales más elevadas.

En un sistema en producción nunca se sabrá el ordinal de cada elemento obtenido y simplemente se lo insertará en una cola de prioridad. Con sucesivos experimentos queremos determinar una cota expresada porcentualmente en la cantidad de elementos a examinar. Esto exigirá correr una gran cantidad de simulaciones, tarea aún no realizada, cambiando la consulta, lo que cuesta menos y cambiando



Código	FPI-009
Objeto	Guía de elaboración de Informe de avance de proyecto
Usuario	Director de proyecto de investigación
Autor	Secretaría de Ciencia y Tecnología de la UNLaM
Versión	5
Vigencia	03/9/2019

tanto el agrupamiento como los documentos simulados lo que implica nuevos K-means.

Entre la tabla 2, se muestra la comparativa entre las distintas normas para cada corpus.

Tabla 2. Cantidad de documentos recuperados bajo norma 1,2 y 4, en pruebas con 50, 100, 200 y 300 mil documentos.

Expresa de en 0,000	Cantidad de documentos recuperados											
	50.000			100.000			200.000			300.000		
	1	2	4	1	2	4	1	2	4	1	2	4
2	8	11	4	6	16	8	16	20	7	27	21	16
4	13	19	7	14	19	11	27	27	9	37	24	21
6	17	24	8	19	22	15	31	31	13	40	31	27
8	21	27	10	25	27	17	33	33	16	44	33	29
10	24	29	11	29	30	19	35	35	19	47	41	31
12	26	30	11	33	34	19	37	37	23	47	47	33
14	30	34	19	36	37	21	39	39	27	48	51	36
16	31	34	21	38	39	25	42	42	28	51	53	37
18	34	36	21	41	39	26	43	43	29	52	54	38
20	34	37	25	41	40	29	45	45	30	54	57	42

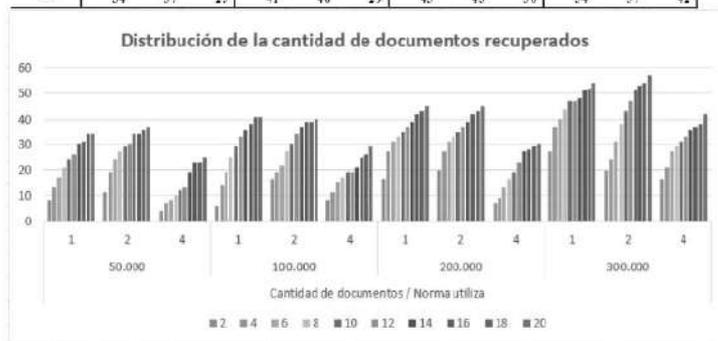


Figura 15. Gráfico de la cantidad de documentos recuperados bajo norma 1,2 y 4, en pruebas con 50, 100, 200 y 300 mil documentos. Elaboración propia.

Observando la tabla 2, se comprueba que el primer intervalo de 2 milésimos es el que aporta la mayor cantidad de elementos, lo cual confirma que ordenarlos por la distancia a los centroides es un buen criterio para examinar los contenidos. Esto queda confirmado también por la curvatura negativa cuando se expresa de modo gráfico (Figura 15). De las normas ensayadas la de orden 2, o sea la euclidiana es la que obtuvo los mejores resultados en contra de una intuición que a mayor exponente se castigaria los que presentaran puntualmente grandes diferencias en algunas de las dimensiones. A igual que la tabla anterior se ve que un corpus más numeroso mejora la calidad de la recuperación.

Se puede concluir, diciendo que no lograr el 100% de los elementos deseables no afecta a la utilidad del sistema, dada la imprecisión de la noción de similitud y la hipótesis

de que contar la aparición de ciertas palabras garantiza la calidad del contenido o el acierto en la sugerencia de su lectura. Por otra parte, haber reducido el problema al agrupamiento tentativamente de a 10 obliga a un 10% de mediciones de distancia. Esta cantidad bajará drásticamente si se agrega un nivel o varios por encima repitiendo el esquema de K-means sobre los centroides del primer nivel y así siguiendo hacia arriba. El esquema de como organizar la exploración se vuelve más complejo y será un tema a abordar en el futuro.

6. Trabajos futuros

Es predecible que los Kmeans crezcan en forma cuadrática con el tamaño de la población. Problema similar se tuvo con los SVD que crecen en forma cúbica con la cantidad de dimensiones de los vectores [3-4]. Con aquellos se redujo drásticamente el tiempo recurriendo al paralelismo de los procesadores gráficos. Hay que tener presente que a igual que con SVD esto se calcula una vez antes de liberar el sistema y se recalcula cuando la cantidad de documentos recuperados lo justifica. Como estos recálculos se pueden hacer sin afectar a la operación del sistema no tiene demasiado importancia el tiempo.

Se analizará la posibilidad de visualizar gráficamente los grupos y los centroides.

Por otro lado, se agregarán más opciones como, por ejemplo, elegir distintas métricas de distancias, o distintos algoritmos de agrupamiento (DbSCAN, Modelo Mezcla Gaussiana (GMM), Equilibrio Iterativo de Reducción y Agrupación mediante Jerarquías o Balance Iterative Reducing and Clustering using Hierarchies (BIRCH por sus siglas en inglés), etc.

Finalmente, se considera que también es posible paralelizar el proceso para realizar las pruebas en lotes de mayores a un millón de documentos y con orientaciones temáticas que superen los 100 elementos.

7. Referencias

- de la Computación (WICC 2020), El Calafate, Santa Cruz, pp. 738-742, mayo 2020. ISBN 978-987-3714-82-5.
- [6] Sposito O., Ledesma V., Procopio G., Ryckeboer H., Saizar V. y Vamberg A. (2020). "Comparación de un Algoritmo de Bidiagonalización para su Utilización en la Recuperación de Información", XXVI Congreso Argentino de Ciencias de la Computación (CACIC 2020). Universidad Nacional de La Matanza, pp. 72-81. Modalidad virtual, octubre de 2020. ISBN 978-987-4417-90-9.
- [7] Sposito O., Ledesma V., Procopio G., Saizar V. (2020). "Implementación de un Algoritmo de Bidiagonalización en un Entorno Híbrido para su Aplicación en la Recuperación de Información", 8vo. Congreso Nacional de Ingeniería Informática y Sistemas de Información (CoNaiISI 2020). UTN, San Francisco, Córdoba, noviembre de 2020.
- [8] Hernández Orallo, J. y otros. "Introducción a la minería de datos", Editorial: Pearson. Edición: 1. Año 2004
- [9] Gimbergia, A y otros. Modelado y Diseño de Sistemas Complejos mediante Técnicas de Simulación. WICC 2014 XVI Workshop de Investigadores en Ciencias de la Computación. Disponible en: <https://core.ac.uk/download/pdf/296374584.pdf>
- [10] "Introduction to Modern Information Retrieval". Gerard Salton, Michael J. Michael J. McGill. Ed. McGraw-Hill, Inc. New York, NY, USA. ISBN: 0070544840. 1986
- [11] Tolosa Gabriel H. y Bordignon Fernando R.A. "Introducción a la Recuperación de Información - Conceptos, modelos y algoritmos básicos". Universidad Nacional de Luján. Creative Commons Atribución-No Comercial-Compartir Obras Derivadas Igual 2.5 Arg. License. 2007. Disponible en: <http://eprints.rclis.org/12243/1/Introduccion-RI-v9f.pdf>
- [12] Modelo vectorial de recuperación de información. (2020, febrero 26). EcuRed. Disponible en: https://www.ecured.cu/index.php?title=Modelo_vectorial_de_recuperaci%C3%B3n_de_informaci%C3%B3n&oldid=3644075.
- [13] Larson, Ron. (2013). Fundamentos de álgebra lineal, séptima edición ISBN: 978-607-519-803-3
- [14] Dos Santos, E. & otros. (2015). Procesamiento de búsquedas por similitud. Tecnologías de paralelización e indexación. ICT-UNPA-115-2015 ISSN: 1852-4516
- [15] Guccione, Jorge y Guccione, J. (2018) Espacios Métricos. UBA http://cms.dm.uba.ar/academico/matenas/tercuet2014/calculo_avanzado/EspaciosMetricos.pdf
- [16] Reyes Nora Susana. (2015). Bases de Datos Métricas. Universidad Nacional de San Luis. Disponible en: <https://users.dcc.uchile.cl/~guavarro/algoritmos/tesisNora.pdf>
- [17] "Inteligencia artificial avanzada". Raúl Benítez, Gerard Escudero, Samir Kanaan. Universitat Oberta de Catalunya. 2013. Disponible en: <http://archivos.inteligencia-artificial.net/archivos/RaulBenitezotros.%20Inteligencia%20Artificial%20Aumentada.pdf>
- [18] Chris Piech.(2012). K Means. <https://stanford.edu/~cpiech/cs221/handouts/kmeans.html>
- [19] Trotman, A. (2004). An artificial intelligence approach to information retrieval (abstract only). Proceedings of the 27th Annual International Conference on Research and Development in Information Retrieval - SIGIR '04. <https://doi.org/10.1145/1008992.1009150>
- [20] Mandl, Thomas. (2008). Artificial Intelligence for Information Retrieval. 10.4018/9781599048499.ch023.
- [21] Giugni O, Marylin & LEON G, Luis. Clusterdoc un sistema de recuperación y recomendación de documentos basado en algoritmos de agrupamiento. uct [online]. 2011, vol.15, n.60, pp.121-129. ISSN 1316-4821.

ANEXO I

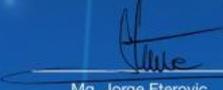
CERTIFICADOS DIVULGACIÓN




San Justo, 3 de enero de 2023

Certificamos que el artículo
"Determinación del umbral inferior de coincidencia aplicando medidas de edición a términos jurídicos",
 de Lorena Romina Matteo, Viviana Ledesma y Osvaldo Sposito, ha sido publicado en el Volumen: 7 - Número 2 (Diciembre-2022) de la revista digital ReDDI ISSN: 2525-1333.


 Dra. Bettina Donadello
 Gestión Editorial
 ReDDI E-Journal


 Mg. Jorge Eterovic
 Dirección Ejecutiva
 ReDDI E-Journal

ISSN: 2525-1333

Universidad Nacional de La Matanza

DIIT
 Departamento de Ingeniería y Programación Tecnológica





XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN

Por medio del presente se CERTIFICA que:

Edgardo J. Moreno

Ha participado en calidad de AUTOR del trabajo "Construcción de un Corpus Jurídico utilizando Expresiones Regulares" en el XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN llevado a cabo de manera virtual por la Facultad de Ciencias Exactas de la UNSa del 04 al 08 de octubre de 2021.

Salta, Argentina


 Lic. Patricia Pesado
 Coordinadora
 Red UNCI


 Ing. Daniel Hoyos
 Decano
 Facultad de Ciencias Exactas
 UNSa

Firmado digitalmente por
 Gil Gustavo Darrel
 Rolando Vera Decano
 Facultad de Ciencias Exactas
 Fecha y hora: 20.10.2021
 12:09:35





XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN

Por medio del presente se CERTIFICA que:

Hugo Emilio Ryckeboer

Ha participado en calidad de AUTOR del trabajo "Construcción de un Corpus Jurídico utilizando Expresiones Regulares" en el XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN llevado a cabo de manera virtual por la Facultad de Ciencias Exactas de la UNSa del 04 al 08 de octubre de 2021.

Salta, Argentina



Lic. Patricia Pesado
Coordinadora
Red UNCI



Ing. Daniel Hoyos
Decano
Facultad de Ciencias Exactas
UNSa

Firmado digitalmente por:
Lic. Patricia Pesado
Máster, Vice Decano -
Facultad de Ciencias Exactas
Fecha y Hora: 10/10/2021
12:08:52





XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN

Por medio del presente se CERTIFICA que:

Julio Bossero

Ha participado en calidad de AUTOR del trabajo "Construcción de un Corpus Jurídico utilizando Expresiones Regulares" en el XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN llevado a cabo de manera virtual por la Facultad de Ciencias Exactas de la UNSa del 04 al 08 de octubre de 2021.

Salta, Argentina



Lic. Patricia Pesado
Coordinadora
Red UNCI



Ing. Daniel Hoyos
Decano
Facultad de Ciencias Exactas
UNSa

Firmado digitalmente por:
Lic. Patricia Pesado
Máster, Vice Decano -
Facultad de Ciencias Exactas
Fecha y Hora: 10/10/2021
12:07:36







XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN

Por medio del presente se CERTIFICA que:

Lorena Matteo

Ha participado en calidad de AUTOR del trabajo "Construcción de un Corpus Jurídico utilizando Expresiones Regulares" en el XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN llevado a cabo de manera virtual por la Facultad de Ciencias Exactas de la UNSa del 04 al 08 de octubre de 2021.

Salta, Argentina



Lic. Patricia Pesado
Coordinadora
Red UNCI



Ing. Daniel Hoyos
Decano
Facultad de Ciencias Exactas
UNSa

Firmado digitalmente por:
Lic. Patricia Pesado
Molinos, Vice Decano -
Facultad de Ciencias Exactas
Fecha y Hora: 20/10/2021
12:07:35







XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN

Por medio del presente se CERTIFICA que:

Oswaldo Mario Sposito

Ha participado en calidad de AUTOR del trabajo "Construcción de un Corpus Jurídico utilizando Expresiones Regulares" en el XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN llevado a cabo de manera virtual por la Facultad de Ciencias Exactas de la UNSa del 04 al 08 de octubre de 2021.

Salta, Argentina



Lic. Patricia Pesado
Coordinadora
Red UNCI



Ing. Daniel Hoyos
Decano
Facultad de Ciencias Exactas
UNSa

Firmado digitalmente por:
Lic. Patricia Pesado
Molinos, Vice Decano -
Facultad de Ciencias Exactas
Fecha y Hora: 20/10/2021
12:07:52

CACIC 2021



XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN

Por medio del presente se CERTIFICA que:

Viviana Ledesma

Ha participado en calidad de AUTOR del trabajo "Construcción de un Corpus Jurídico utilizando Expresiones Regulares" en el XXVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN llevado a cabo de manera virtual por la Facultad de Ciencias Exactas de la UNSa del 04 al 08 de octubre de 2021.

Salta, Argentina


Lic. Patricia Pesado
Coordinadora
Red UNCI


Ing. Daniel Hoyos
Decano
Facultad de Ciencias Exactas
UNSa

Firmado digitalmente por:
Lic. Gustavo Daniel
Molero, Vice Decano -
Facultad de Ciencias Exactas
Fecha y hora: 20.10.2021
12:06:59

CERTIFICADO

Julio Cesar Bossero, Osvaldo Mario Sposito, Viviana Ledesma, Hugo Ryckeboer, Laura Conti, Sergio Garcia, Edgardo Moreno, Lorena Matteo, Victoria Saizar, Patricio Macias, Fabio Quintana, Gustavo Perez Villar, Cecilia Gargano, Gaston Procopio,

han presentado el trabajo

en el 9º Congreso Nacional de Ingeniería Informática / Sistemas de Información (CoNaISI 2021) organizado por la Red de Carreras de Ingeniería Informática / Sistemas de Información (RIISIC) perteneciente al CONFEDI, realizado de forma Virtual por la Universidad Tecnológica Nacional Facultad Regional Mendoza, los días 04 y 05 de noviembre de 2021; se otorga el presente certificado en calidad de autor.


Ing. Nelson Roberto Sotomayor
Coordinador RIISIC 2021


Mg. Ing. Marcela Fernandez
Coordinadora CoNaISI 2021


Esp. Ing. José Balacco
Decano UTM - FRM

 UTN
Departamento de Ingeniería
en Sistemas de Información



**9º CoNaISI
2021**
El Segundo Encuentro de
Ingeniería Informática y
Sistemas de Información

 confedi
Consejo Argentino de Carreras de Ingeniería
y Ciencias Exactas

**XXIV WORKSHOP DE INVESTIGADORES EN CIENCIAS DE LA COMPUTACIÓN**

Se certifica que

Julio C. Bossero

ha participado en calidad de autor del artículo

Adecuación de un Sistema de Recuperación de Información para su Utilización en un Contexto Jurídico

aceptado en el XXIV WORKSHOP DE INVESTIGADORES EN CIENCIAS DE LA COMPUTACIÓN – WICC 2022 organizado por la Universidad Champagnat.

Abril 2022 - Mendoza, Argentina.


Lic. Patricia Pesado
Coordinadora
RedUNCI


Lic. Alejandro Giuffrida
RECTOR
UNIVERSIDAD CHAMPAGNAT

**XXIV WORKSHOP DE INVESTIGADORES EN CIENCIAS DE LA COMPUTACIÓN**

Se certifica que

Viviana Ledesma

ha participado en calidad de autor del artículo

Adecuación de un Sistema de Recuperación de Información para su Utilización en un Contexto Jurídico

aceptado en el XXIV WORKSHOP DE INVESTIGADORES EN CIENCIAS DE LA COMPUTACIÓN – WICC 2022 organizado por la Universidad Champagnat.

Abril 2022 - Mendoza, Argentina.


Lic. Patricia Pesado
Coordinadora
RedUNCI


Lic. Alejandro Giuffrida
RECTOR
UNIVERSIDAD CHAMPAGNAT





Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Luis Busnelli, ha participado en calidad de Autor del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
Coordinador titular
Red UNCI


Lic. Miguel A. Molina
Decano del Departamento de
Ciencias Exactas Físicas y Naturales

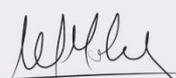


Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Viviana Ledesma, ha participado en calidad de Autora del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
Coordinador titular
Red UNCI


Lic. Miguel A. Molina
Decano del Departamento de
Ciencias Exactas Físicas y Naturales



Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Cecilia Gargano, ha participado en calidad de Autora del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
Coordinador titular
Red UNCI


Lic. Miguel A. Molina
Decano del Departamento de
Ciencias Exactas Físicas y Naturales



Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Julio Bossero, ha participado en calidad de Autor del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
Coordinador titular
Red UNCI


Lic. Miguel A. Molina
Decano del Departamento de
Ciencias Exactas Físicas y Naturales



Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Gerardo Frega, ha participado en calidad de Autor del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
Coordinador titular
Red UNCI


Lic. Miguel A. Molina
Decano del Departamento de
Ciencias Exactas Físicas y Naturales

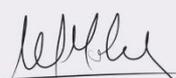


Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Victoria Saizar, ha participado en calidad de Autora del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
Coordinador titular
Red UNCI


Lic. Miguel A. Molina
Decano del Departamento de
Ciencias Exactas Físicas y Naturales



Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Fabio Quintana, ha participado en calidad de Autor del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
Coordinador titular
Red UNCI


Lic. Miguel A. Molina
Decano del Departamento de
Ciencias Exactas Físicas y Naturales



Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Laura Conti, ha participado en calidad de Autora del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
Coordinador titular
Red UNCI


Lic. Miguel A. Molina
Decano del Departamento de
Ciencias Exactas Físicas y Naturales



Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Sergio García, ha participado en calidad de Autor del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
Coordinador titular
Red UNCI


Lic. Miguel A. Molina
Decano del Departamento de
Ciencias Exactas Físicas y Naturales



Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Carlos Colombain, ha participado en calidad de Autor del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
Coordinador titular
Red UNCI


Lic. Miguel A. Molina
Decano del Departamento de
Ciencias Exactas Físicas y Naturales



Red UNCI  DACEFyN | Universidad Nacional de La Rioja

cacic2022

Se certifica que Gustavo Pérez Villar, ha participado en calidad de Autor del artículo: Desarrollo de Interfaces de Programación de Aplicaciones aplicadas en Experticia, un Sistema Experto Jurídico; aceptado en el marco del **XXVIII Congreso Argentino de Ciencias de la Computación - (CACIC 2022)**, realizado en la ciudad de La Rioja entre los días 03 al 06 de octubre del 2022.-


Lic. Patricia Pesado
 Coordinador titular
 Red UNCI


Lic. Miguel A. Molina
 Decano del Departamento de
 Ciencias Exactas Físicas y Naturales



51 JAIIO
 JORNADAS ARGENTINAS DE INFORMÁTICA

17 AL 27 DE OCTUBRE 2022


 Sociedad Argentina de Informática

extiende el presente diploma a

VIVIANA ALEJANDRA LEDESMA

por haber participado como **Panelista** de

SID 2022 - Simposio Argentino de Informática y Derecho

durante las 51° Jornadas Argentinas de Informática, realizadas del 17 al 27 de Octubre de 2022.


Claudia Pons
 Coordinadora General de las 51 JAIIO


Marcelo De Vincenzi
 Coordinador General de las 51 JAIIO


Carlos Neil
 Coordinador General de las 51 JAIIO


Sandra D'Agostino
 Presidenta de SADIO

51jaiio.sadio.org.ar



51 JAIIO
JORNADAS ARGENTINAS
DE INFORMÁTICA

17 AL 27 DE OCTUBRE 2022



SADIO
Sociedad Argentina de Informática

extiende el presente diploma a

VIVIANA ALEJANDRA LEDESMA

por haber participado como **Panelista** de

SID 2022 - Simposio Argentino de Informática y Derecho

durante las 51° Jornadas Argentinas de Informática, realizadas del 17 al 27 de Octubre de 2022.

 Claudia Pons Coordinadora General de las 51 JAIIO	 Marcelo De Vincenzi Coordinador General de las 51 JAIIO	 Carlos Neil Coordinador General de las 51 JAIIO	 Sandra D'Agostino Presidenta de SADIO
---	---	---	---

🌐 51jaiio.sadio.org.ar

Certificado

FUNDEJUS

Fundación de Estudios para la Justicia

Perú Jur N° 13364 - En Perú Jur. Pcia. Bs. As.
Organización No Gubernamental reconocida por la OEA

Presidencia Honoraria

José Luis de Rueda

Vicepresidencia Honoraria

Alejo José Ruiz Piz

Consejo Asesor

Horacio Aguilar

Sergio Alcaró

Salvador G. Borjal

Roberto Bricelj

Gabriel Bustos

Luz María Cabello

Carlos Campolongo

Daniel Ervicio

Marta del Carmen Faller

Roberto Antón Falcione

Felipe Facio

Cecilia Geronzi

Juan Carlos Herrer

Hilda Rojas

Lucía E. Larrondelet

Angela Leubama

Marta Pérez Tomperley

Albino Pizarro

Alberto G. Pizarro

Marta Graciela Rivar

Alberto Antonio Rivas

Edmundo Enrique Sacco

Eugenio Raúl Zaffaroni

Consejo de Administración

Presidentes

Ricardo Blas Casal

Vicepresidentes

Carlos Fabián Blanco

Director Ejecutivo

Juan Manuel Gornall

Secretaría Técnica

Lorena Mito

Secretaría Administrativa

Juan Pablo Vidal

Equipo

Gabriel Bustos

Viviana

Laura Colares

Ana D. Alvarez

Mónica La Ruffa (ex-vice de Bustos)

Marta Pío León

Pablo Jorda

Ex Miembros Fundador

Elisa A. Wilson

Ex Integrantes del

Consejo Asesor

Carmen Arceles

Germán Balcaro Campes

Antonio Calles

Abel Fabian Díaz de Rivas

José María García

Guillermo M. Giannattasio

Alberto A. Spina

Margarita Trujillo

Instituto de Investigaciones y

Estudios

Director: Felipe Facio

Oficina de Género

Marta Pío León

Abel Ruiz

Departamento de Relaciones

Internacionales

Santiago Dolata

CERTIFICO: que Laura Conti, ha participado en carácter de disertante en la Jornada de actualización " *La gestión judicial en los tiempos actuales: nuevos desafíos* ", llevada a cabo el día miércoles 2 del corriente mes y año, organizada por FUNDEJUS (Fundación de Estudios para la Justicia) y la Asociación de Magistrados y Funcionarios del Departamento Judicial de Morón en el marco del convenio de cooperación firmado por ambas instituciones. Auspiciada por el Colegio de Abogados del Departamento Judicial de Morón.-

Expido el presente, a pedido de la interesada, para ser presentado por ante quien corresponda, a los 8 días del mes de noviembre del año 2022.-



Carlos Fabián Blanco
VICE-PRESIDENTE DE FUNDEJUS

Lavalle 1580 4° E. (C1048AAL) Ciudad Autónoma de Bs. As.
Tel./Fax: (34-011) 4374-0616

<http://www.fundejus.org>

E-mail: info@fundejus.org

República Argentina

ANEXO I

CERTIFICADOS CAPACITACIÓN

EDUCACIÓN 

Certificado de Asistencia

Julio Bossero

Ha asistido y completado el curso:

Git: Desarrollo Colaborativo



9/12/2021

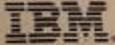
Fecha de emisión



Lorena Somer
Coordinadora Académica



**Certificado
Verificado**



Esto es para certificar que

Laura Conti

completó y aprobó

AI0101SP: Inteligencia Artificial para todos: Domina los fundamentos

un curso de estudio ofrecido por IBM, una iniciativa de aprendizaje en línea de IBM mediante edX.



Esfuerzo
8 horas

Certificado Verificado
Emiso el febrero 14, 2022

ID Válida del Certificado
[6468d7fccc47a696639e10192d139f2](https://www.edx.org/certificate/6468d7fccc47a696639e10192d139f2)



Ray Ahuja
AI and Data Science Program Director
IBM

doinGlobal

Online smart learning

**CONSTANCIA DE FINALIZACIÓN DE CURSADO –
CERTIFICADO EN TRÁMITE**

Se deja constancia que la alumna Conti, Laura, legajo número 15386, número de identificación 24028816, actualmente ha finalizado el cursado de manera regular y aprobado el Curso Superior en Derecho: Inteligencia Artificial y Derecho, dictado y certificado por la Fundación General de la Universidad de Salamanca (Salamanca – España) & doinGlobal (Silicón Valley - USA), encontrándose a la fecha el certificado correspondiente en proceso de expedición.

Cantidad de horas cátedra curso: 120 horas.

A solicitud de la interesada y para ser presentado ante quien corresponda, se expide esta constancia a los veintisiete días del mes de diciembre del año dos mil veintidós.



Belén Redondo
Oficina de Alumnos

¹ doinGlobal
5493515 52-2850 - belen.redondo@doinglobal.com
2880 Zanker Road - San Jose, CA 95134 -Silicon Valley | USA
doinglobal.com

EDUCACIÓN **IT**

Certificado de Aprobación

Cecilia, Gargano

Ha completado y aprobado el curso:
Python Programming

Duración:
21hs



Lorena Sommer
Coordinadora Académica

04/11/21

Fecha

EDUCACIÓN **IT**

Certificado de Aprobación

Cecilia, Gargano

Ha completado y aprobado el curso:
Python para Analisis de Datos

Duración:
18hs



Lorena Sommer
Coordinadora Académica

04/02/22

Fecha

EDUCACIÓN **IT**

Certificado de Aprobación

Viviana, Ledesma

Ha completado y aprobado el curso:
Introducción a UX

Duración:
12hs



Lorena Sommer
Coordinadora Académica

21/10/21

Fecha

EDUCACIÓN **IT**

Certificado de Asistencia

Viviana Ledesma

Ha asistido y completado el curso:

Diseño de interfaz de usuario



29/11/2021

Fecha de emisión



Lorena Sommer
Coordinadora Académica



REPUBLICA ARGENTINA



Universidad Nacional de La Matanza
Dirección de Pedagogía Universitaria

Se deja constancia que **Matteo, Lorena Romina, DNI 23701391** ha asistido al intercambio pedagógico - didáctico “*Aulas híbridas y bimodalidad en la educación superior*”, en esta Casa de Altos Estudios. Por tanto, se extiende el presente Certificado.

San Justo, 28 de octubre de 2021


Lic. Jorgelina Monti
Directora de Pedagogía Universitaria



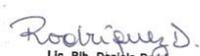
CERTIFICADO

Buenas prácticas de consumo y producción de la información científica y académica

LORENA MATTEO

Certificamos que ha participado en calidad de asistente al ciclo de capacitación organizado y dictado por la Biblioteca Leopoldo Marechal de la Universidad Nacional de La Matanza

03 de noviembre de 2022


Lic. Bib. Daniela Rodríguez
A/C Directora
Biblioteca Leopoldo Marechal
Universidad Nacional de La Matanza

educación 

Certificado de aprobación

Edgardo Moreno

Ha asistido y completado el Curso:

Programación .NET con C# .NET

Duración
40 h

16 de mayo de 2022

Fecha de emisión



Lorena Somer
Coordinadora Académica

educación 

Certificado de aprobación

Edgardo Moreno

Ha asistido y completado el Curso:

Programación .NET con C# .NET

Duración
40 h

16 de mayo de 2022

Fecha de emisión



Lorena Somer
Coordinadora Académica

EDUCACIÓN IT

Certificado de Asistencia

Fabio Quintana

Ha asistido y completado el curso:

Node.js y Mongo DB



14/1/2022

Fecha de emisión



Lorena Somer
Coordinadora Académica



EDUCACIÓN IT

Certificado de Asistencia

Fabio Quintana

Ha asistido y completado el curso:

Vue.JS



4/12/2021

Fecha de emisión



Lorena Somer
Coordinadora Académica



EDUCACIÓN **IT**

Certificado de Aprobación

Victoria, Saizar Godoy

Ha completado y aprobado el curso:
ReactJS Developer

Duración:
36hs



Lorena Sommer
Coordinadora Académica

07/07/22

Fecha

EDUCACIÓN **IT**

Certificado de Aprobación

Victoria, Saizar Godoy

Ha completado y aprobado el curso:
Web API .Net Core

Duración:
21hs



Lorena Sommer
Coordinadora Académica

06/07/22

Fecha



Unidad Académica: **Departamento de Ingeniería e Investigaciones Tecnológicas**

Código: **C241**

Título del Proyecto: **Implementación de un Sistema Web de Recuperación de la Información Orientado a Documentación Jurídica con el Proceso de Indexación Semántica Latente Paralelizado**

Director del Proyecto: Sposito, Osvaldo

Fecha de inicio: **1/1/2021**

Fecha de finalización: **31/12/2022**

1. Datos del alumno

Apellido y Nombre: **Juan Ojeda**

DNI: **32.265.949**

Unidad Académica: **Departamento de Ingeniería e Investigaciones Tecnológicas**

Carrera que cursa: **Ingeniería en Informática**

Período evaluado: **1/1/2022 a 31/12/2022**

2. Dictamen de evaluación de desempeño del alumno:

Colocar una cruz donde corresponda

2.1 Satisfactorio: X

2.1 No satisfactorio:

Fundamentos del dictamen:

El alumno trabajó de modo satisfactorio, desenvolviéndose con idoneidad en la realización de sus actividades definidas para el primer año del cronograma.

3. Propuesta de continuidad en el proyecto (si corresponde según duración estimada)

Colocar una cruz donde corresponda

3.1 Continuar en el presente proyecto:

3.2 No continuar en el presente proyecto:

Fundamentos del dictamen:

El alumno ha mostrado responsabilidad y dedicación en su trabajo.

San Justo 31/12/2022

.....
Lugar y fecha

.....
Firma del Director

Sposito Osvaldo Mario

.....
Aclaración de firma



Unidad Académica: **Departamento de Ingeniería e Investigaciones Tecnológicas**

Código: **C241**

Título del Proyecto: **Implementación de un Sistema Web de Recuperación de la Información Orientado a Documentación Jurídica con el Proceso de Indexación Semántica Latente Paralelizado**

Director del Proyecto: Sposito, Osvaldo

Fecha de inicio: **1/1/2021**

Fecha de finalización: **31/12/2022**

1. Datos del alumno

Apellido y Nombre: **Fabio Quintana**

DNI: **33.676.620**

Unidad Académica: **Departamento de Ingeniería e Investigaciones Tecnológicas**

Carrera que cursa: **Ingeniería en Informática**

Período evaluado: **1/1/2022 a 31/12/2022**

2. Dictamen de evaluación de desempeño del alumno:

Colocar una cruz donde corresponda

2.1 Satisfactorio: X

2.1 No satisfactorio:

Fundamentos del dictamen:

El alumno se desempeñó satisfactoriamente en la realización de sus actividades planificadas en el cronograma para el primer año del proyecto.

3. Propuesta de continuidad en el proyecto (si corresponde según duración estimada)

Colocar una cruz donde corresponda

3.1 Continuar en el presente proyecto:

3.2 No continuar en el presente proyecto:

Fundamentos del dictamen:

El alumno ha mostrado responsabilidad y dedicación en su trabajo. Es una persona respetuosa y de buen trato.

San Justo 31/12/2022

.....
Lugar y fecha

.....
Firma del Director

Sposito Osvaldo Mario

.....
Aclaración de firma