

MINERIA DE TEXTOS

Carrera:
Doctorado en Ciencias Informáticas
Maestría en Inteligencia de
Datos orientada a Big Data
Profesor Responsable:
Dr. Marcelo Errecalde
Duración: 64 hs.
Créditos: 4

OBJETIVO

Introducir al alumno en el análisis de información no estructurada ingresada en formato texto con un enfoque teórico-práctico.

El énfasis estará puesto en el análisis estructural de los documentos. Se revisarán distintas herramientas para recolectar textos.

- Esta asignatura se vincula con los objetivos de la carrera al presentar conocimientos actualizados en temas de la disciplina informática, abriendo líneas potenciales de I+D+I.
- La carga teórica representa el 40% de la dedicación horaria del curso, en tanto las tareas experimentales un 60% de la carga horaria total.

MODALIDAD DE EVALUACION

Para aprobar el curso se requiere un 80% de asistencia y la realización de un trabajo final que se definirá una vez completada la exposición de los contenidos teóricos.

Dicho proyecto deberá ser realizado en forma individual y tendrá por objetivo profundizar uno o varios de los conceptos vistos en clase.

La entrega consistirá en un reporte técnico de calidad científica producto de un estudio experimental específico.



POSTGRADO

FACULTAD DE INFORMÁTICA



**UNIVERSIDAD
NACIONAL
DE LA PLATA**

PROGRAMA

- Introducción.
KDD.
Minería de Datos, de Textos y de la Web.
Identificación de casos en los cuales debería o no ser utilizada.
Procesamiento de Lenguaje Natural. Aplicaciones
- Recuperación de Información en la Web.
Modelos de búsqueda.
Minería Web. Web scraping. Descarga. Recolección.
Hipertexto. Repositorios digitales.
Utilización de APIs. Navegador web, HTTP.
- Manipulación del texto a través de strings.
Limpieza. Expresiones regulares.
Conceptos: corpus, parsing, delimiters, segmentation, tokens, stemming, tagger, n-gram, named entity, stop word.
- Modelos de representación.
Bolsa de palabras.
Matriz término-documento.
Modelo vectorial.
Estructuras en forma de grafos.
Cálculo de frecuencias. Términos frecuentes. Relación entre términos.
Medidas de relevancia. Ley de Zipf.
Coocurrencia de términos. Detección de keywords.
- Representaciones avanzadas de documentos.
Cuantificando "estilo".
Enfoques basados en instancias versus enfoques basados en perfil.
Modelos neuronales de textos. Embeddings.
Modelos secuenciales de textos.
Aprendizaje y clasificación incremental.
Redes Neuronales Recurrentes. Clasificación anticipada de textos



POSTGRADO

FACULTAD DE INFORMÁTICA



**UNIVERSIDAD
NACIONAL
DE LA PLATA**

- Análisis semántico.
Diferencia con el sintáctico.
Estructuras tales como glosarios, diccionarios, tesauros, ontologías, etc. Wordnet.
- Discusión de problemas: Agrupamiento, categorización, clasificación, obtención de resúmenes, topic detection, análisis de sentimientos.
- Aplicaciones: Atribución de Autoría.
Determinación del perfil del autor (Author Profiling).
Detección de Plagios.
Análisis de Sentimientos/ Minería de Opiniones.
Detección temprana de riesgos (pedófilos, rumores, depresión, anorexia).
Calidad de Información en la Web.
Recursos y herramientas: NLTK, gensym, LIWC, etc.

ACTIVIDADES EXPERIMENTALES Y DE INVESTIGACIÓN

Tareas en Laboratorio

- Desarrollo de actividades experimentales de minería de textos, con diferentes herramientas de software.
- Análisis comparativos de métodos/algoritmos utilizados en casos de aplicación.

Investigación

- Se les propondrán temas de investigación relacionados con lectura y comprensión de papers científicos relacionados con Minería de Textos, de forma que pueda desarrollar un trabajo de investigación/desarrollo asociado con los temas del curso.

BIBLIOGRAFIA

- Aggarwal, Charu C.; Zhai, ChengXiang. *Mining Text Data*. ISBN 978-1-4614-3222-7. Springer-Verlag New York, 2012.
- Bird, Steven; Klein, Ewan; Loper, Edward. *Natural Language Processing with Python*. ISBN: 978-0-596-51649-9. O'Reilly Media, Inc., 2009.
- Hernández Orallo, José; Ramírez Quintana, M.^a José; Ferri Ramírez, Cèsar. Capítulo: *Minería de web y textos*. En: *Introducción a la minería de datos*. ISBN 9788420540917. Pearson Educación, S.A., 2004.
- Martínez-Méndez, Francisco-Javier. *Recuperación de información: modelos, sistemas y evaluación*. ISBN 84-932537-7-4. El Kiosko JMC, 2004.
- Olivas Varela, José Angel. *Búsqueda eficaz de información en la web*. ISBN 978-950-34-0763-9. Eulps, 2011.
- Bosch, Mela. *La piel del jaguar: la escritura móvil. Heurística y hermenéutica en el tratamiento informático de los documentos*. ISBN 978-3-8473-6869-4. EAE, 2012.
- Peña, Rosalía; Baeza-Yates, Ricardo; Rodríguez Muñoz, José Vicente. *Gestión digital de la información: de bits a bibliotecas digitales y la Web*. ISBN: 9788478975143. RA-MA, 2002.
- Marimón Llorca, Carmen. *Análisis de textos en español : teoría y práctica*. ISBN 978-84-7908-994-8. Universidad de Alicante, 2008.
- Lebart, Ludovic; Salem, André; Bécue-Bertaut, Mónica. *Análisis estadístico de textos*. ISBN 84-89790-57-4. Milenio, 2000.
- Bécue-Bertaut, Mónica. *Minería de textos. Aplicación a preguntas abiertas en encuestas*. ISBN: 978-84-7133-793-1. LA MURALLA, S.A., 2010.
- Jurafsky, Dan; Martin, James H. *Speech and Language Processing* [online]. <https://web.stanford.edu/~jurafsky/slp3/>
- Torres-Moreno, Juan-Manuel. *Automatic Text Summarization*. ISBN 978-1-84821-668-6. ISTE Ltd and John Wiley & Sons, Inc., 2014.
- Christopher D. Manning, Prabhakar Raghavan and Hinrich Schütze, *Introduction to Information Retrieval*, Cambridge University Press. 2008.
- Christopher D. Manning y Hinrich Schütze. *Foundations of Statistical Natural Language Processing*. The MIT Press. Cambridge, Massachusetts. 1999.
- Charu C. Aggarwal. *Machine Learning for Text*, Springer, March 2018.
- Fabrizio Sebastiani. 2002. *Machine learning in automated text categorization*. ACM Computing Surveys. 34, 1, 1-47. 2002.