

18-19

MÁSTER UNIVERSITARIO EN I.A.
AVANZADA: FUNDAMENTOS, MÉTODOS
Y APLICACIONES

GUÍA DE ESTUDIO PÚBLICA



DESCUBRIMIENTO DE INFORMACIÓN EN TEXTOS

CÓDIGO 31101254



Ámbito: GUJ - La autenticidad, validez e integridad de este documento puede ser verificada mediante el "Código Seguro de Verificación (CSV)" en la dirección <https://sede.uned.es/valida/>



B6610EBDAE90B7356AF200332B1789FC

ÍNDICE

PRESENTACIÓN Y CONTEXTUALIZACIÓN	
REQUISITOS Y/O RECOMENDACIONES PARA CURSAR ESTA ASIGNATURA	
EQUIPO DOCENTE	
HORARIO DE ATENCIÓN AL ESTUDIANTE	
COMPETENCIAS QUE ADQUIERE EL ESTUDIANTE	
RESULTADOS DE APRENDIZAJE	
CONTENIDOS	
METODOLOGÍA	
SISTEMA DE EVALUACIÓN	
BIBLIOGRAFÍA BÁSICA	
BIBLIOGRAFÍA COMPLEMENTARIA	
RECURSOS DE APOYO Y WEBGRAFÍA	



Nombre de la asignatura	DESCUBRIMIENTO DE INFORMACIÓN EN TEXTOS
Código	31101254
Curso académico	2018/2019
Título en que se imparte	MÁSTER UNIVERSITARIO EN I.A. AVANZADA: FUNDAMENTOS, MÉTODOS Y APLICACIONES
Tipo	CONTENIDOS
Nº ETCS	6
Horas	150.0
Periodo	ANUAL
Idiomas en que se imparte	CASTELLANO

PRESENTACIÓN Y CONTEXTUALIZACIÓN

Ficha técnica:

- Tipo: Optativa
- Duración: Anual
- Créditos Totales y Horas: 6 / 150
- Horas de estudio teórico: 70
- Horas de trabajo práctico: 70
- Horas de actividades complementarias: 10

Reseña del Profesorado:

MARTÍNEZ UNANUE, RAQUEL:

Ha realizado la mayor parte de su actividad docente en el campo de la programación, la algoritmia, la documentación electrónica y la minería de textos. Su actividad investigadora reciente se centra en la minería de textos, especialmente en clustering de documentos tanto monolingües como multilingües, aplicada a diversos tipos de textos (páginas web, noticias, redes sociales, ...) y dominios, en particular el dominio médico.

Desde el año 2000 hasta la actualidad ha colaborado en programas de doctorado de tres universidades: la Universidad Complutense de Madrid, la Universidad Rey Juan Carlos y la UNED.

e.mail: raquel@lsi.uned.es

ARAUJO SERNA, LOURDES:

Desde 1990 ha desarrollado en universidades públicas diversa actividad docente relacionada con los lenguajes de programación y la algoritmia. Desde 1994 hasta la actualidad ha colaborado de forma continua en programa de doctorado de la Universidad Complutense de Madrid y de la UNED. Su tema de tesis fue el estudio del paralelismo de Prolog y



posteriormente ha trabajado en programación con restricciones sobre arquitecturas paralelas, ámbito en el que comenzó a aplicar técnicas de programación evolutiva. En la actualidad investiga en procesamiento del lenguaje natural, recuperación de información y en la aplicación de programación evolutiva a dichas áreas.

e.mail: lurdes@lsi.uned.es

FRESNO FERNÁNDEZ, VÍCTOR

Su actividad docente se ha centrado principalmente en el campo de la documentación electrónica y su investigación en el campo de la representación automática de textos, en especial de páginas web, así como en la clasificación y clustering de documentos HTML. Desde el año 2000 hasta la actualidad ha trabajado en el Instituto de Automática industrial (CSIC), la Universidad Rey Juan Carlos (URJC) y la Universidad Nacional de Educación a Distancia (UNED), colaborando en los programas de doctorado de dichas universidades.

e.mail: vfresno@lsi.uned.es

Esta asignatura de carácter optativo se imparte, tanto en el Máster Universitario en "Inteligencia Artificial Avanzada: Fundamentos, Métodos y Aplicaciones" como en el Máster Universitario en "Lenguajes y Sistemas Informáticos" de la ETSI Informática de la UNED. Esta asignatura es de carácter anual con una carga de 6 ECTS.

REQUISITOS Y/O RECOMENDACIONES PARA CURSAR ESTA ASIGNATURA

Ninguno diferente de los generales de acceso a este programa de posgrado orientado a la investigación.

EQUIPO DOCENTE

Nombre y Apellidos
Correo Electrónico
Teléfono
Facultad
Departamento

M. LOURDES ARAUJO SERNA
lurdes@lsi.uned.es
91398-7318
ESCUELA TÉCN.SUP INGENIERÍA INFORMÁTICA
LENGUAJES Y SISTEMAS INFORMÁTICOS

Nombre y Apellidos
Correo Electrónico
Teléfono
Facultad
Departamento

RAQUEL MARTINEZ UNANUE
raquel@lsi.uned.es
ESCUELA TÉCN.SUP INGENIERÍA INFORMÁTICA
LENGUAJES Y SISTEMAS INFORMÁTICOS

Nombre y Apellidos
Correo Electrónico
Teléfono
Facultad
Departamento

VICTOR DIEGO FRESNO FERNANDEZ
vfresno@lsi.uned.es
91398-8217
ESCUELA TÉCN.SUP INGENIERÍA INFORMÁTICA
LENGUAJES Y SISTEMAS INFORMÁTICOS



HORARIO DE ATENCIÓN AL ESTUDIANTE

La tutorización de los alumnos se llevará a cabo a través de la plataforma de e-Learning Alf, por teléfono y por correo electrónico:

- Raquel Martínez (coordinadora)

email: raquel@lsi.uned.es

Tfno: 913988725

Horario guardias: Jueves de 11:30 a 13.30 y de 14.30 a 16:30

- Lourdes Araujo

email: lurdes@lsi.uned.es

Tfno: 913987318

Horario de guardias: Jueves de 11 a 13.30 y de 14.30 a 16:00

- Víctor Fresno

email: vfresno@lsi.uned.es

Tfno: 913988217

Horario guardias: Jueves de 15:00 a 19:00

COMPETENCIAS QUE ADQUIERE EL ESTUDIANTE

RESULTADOS DE APRENDIZAJE

El objetivo del curso es proporcionar al alumno una visión global de las técnicas y tecnologías involucradas en el descubrimiento de información en textos.

El aprendizaje está diseñado para permitir que el alumno adquiera una serie de *destrezas y competencias* que se enumeran a continuación:

- Saber lo que es un corpus y conocer los criterios por los que se clasifican, los tipos de anotaciones más comunes y los estándares utilizados.
- Conocer los modelos de representación comúnmente utilizados, así como los métodos de selección y reducción del número de rasgos.
- Saber distinguir los diversos niveles de información lingüística que se pueden utilizar en la representación de textos.
- Saber qué se entiende por minería de textos y conocer las principales técnicas y tecnologías implicadas.
- Saber qué es la clasificación automática de textos y sus características y tipos.
- Conocer diversos tipos de técnicas de aprendizaje automático que se pueden utilizar en la clasificación automática de textos.



- Conocer los modelos estadísticos más utilizados en el procesamiento del lenguaje.
- Saber utilizar las herramientas disponibles de clasificación automática de textos y tener criterios para seleccionar las más adecuadas.
- Saber qué es el clustering de textos y sus características y tipos.
- Conocer diversos tipos de algoritmos de clustering.
- Saber utilizar las herramientas disponibles de clustering de textos y tener criterios para seleccionar las más adecuadas.
- Conocer algoritmos de etiquetado léxico y análisis sintáctico.

CONTENIDOS

Tema 1. Introducción.

1. Definiciones preliminares.
2. Interés y aplicaciones.

Este primer tema es introductorio, motiva al estudio de la asignatura e introduce los conceptos básicos que se desarrollarán a continuación.

Tema 2. Corpus: definiciones y tipología.

1. ¿Qué es un corpus?
2. Tipos de anotación
3. Tipos de corpus
4. Ejemplos de corpus
5. Utilidades de un corpus

En este capítulo se proporciona una introducción a las compilaciones de textos o corpus utilizados en el procesamiento del lenguaje natural. Estos textos pueden estar o no anotados con información lingüística. Se describen distintos tipos de corpus y anotaciones, y se presentan ejemplos.

Tema 3. Estándares de anotaciones.

1. Introducción
2. Lenguajes de anotaciones. XML
 1. Generalidades
 2. Componentes de un documento XML
 3. Modelado de datos
 4. Fundamentos de las DTD



5. Corrección de un documento XML
3. Estándares de anotaciones en XML
1. TEI
2. XCES
4. Anotaciones *stand-off* en XML.

En este capítulo se proporciona una introducción sobre los tipos de anotaciones más comunes en corpus textuales. Este tipo de anotaciones facilitan diversas tareas relacionadas con la minería de textos. El lenguaje más común utilizado hoy en día para anotar corpus es XML. Se proporciona una introducción que podrán saltarse aquellos alumnos que ya dispongan de conocimientos al respecto.

A continuación se presentan dos de los estándares XML más utilizados por la comunidad científica así como por profesionales. Uno es muy general, TEI, y el otro, XCES, más específico de las anotaciones con información lingüística. Ambos se utilizan en Ingeniería Lingüística y en aplicaciones de Procesamiento de Lenguaje Natural.

Por último, se presenta una arquitectura de anotaciones que cada vez se utiliza más, las anotaciones *stand-off* en XML, que permite superar algunas de las limitaciones intrínsecas de XML y facilitar el procesamiento de textos anotados. Se añade información sobre las tecnologías XML que permiten implementar esta arquitectura, genéricamente se denominan XLink. Aquellos alumnos familiarizados con ellas podrán revisar los ejemplos que se proporcionan sin necesidad de repasarlas.

Tema 4. Modelos estadísticos para la caracterización de textos: Etiquetado léxico

1. Motivación
2. Herramientas matemáticas
1. Nociones de teoría de la probabilidad
2. Introducción a la Teoría de la Información
3. Modelos Ocultos de Markov y Etiquetado Léxico
1. Modelos de Markov Ocultos (HMMs)
2. Etiquetado Léxico
3. Algoritmo de Viterbi
4. HMMs: entrenamiento
4. Gramáticas probabilísticas y Análisis sintáctico
1. Gramáticas probabilísticas (PCFGs)
2. Análisis sintáctico con PCFGs
3. Analizador tipo chart

En este capítulo se proporciona una introducción dos de los modelos estadísticos más utilizados en el procesamiento del lenguaje natural: Los modelos de Markov ocultos y las gramáticas probabilísticas. Estos modelos se aplican a dos problemas fundamentales del



procesamiento del lenguaje: el etiquetado léxico y el análisis sintáctico. El etiquetado léxico consiste en asignar a cada palabra la categoría que le corresponde (verbo, nombre, etc.) resolviendo los casos ambiguos. El análisis sintáctico consiste en buscar la estructura en la que se organizan las partes de una oración.

Tema 5. Representación de textos: Modelos y funciones de pesado y de reducción de rasgos.

1. Introducción.
2. Modelos de representación vectorial.
 1. Antecedentes.
 2. Modelo de espacio vectorial (VSM) y *Latent Semantic Indexing* (LSI).
3. Funciones de pesado (*term weighting functions*).
 1. Funciones locales y globales.
4. Selección y reducción de rasgos (*feature selection*).
 1. Truncado (*stemming*) y lematización.
 2. Eliminación de stop-words.
 3. Funciones de selección de rasgos.

En este capítulo se proporciona una introducción a la representación automática de textos. En general, ésta deberá ser fiel, en primer lugar, al contenido del documento, incluyendo la información necesaria para poder extraer el conocimiento útil que se espera obtener y, a la vez, deberá adecuarse a las especificaciones de los algoritmos que se empleen a continuación.

Sea cual sea el modelo de representación que se quiera emplear, casi todos ellos coinciden en considerar la palabra como elemento fundamental. Así, en ultima instancia, una representación será un conjunto de cadenas que, de una u otra forma, representen el contenido del documento a representar. Se proporciona una introducción a los modelos de representación vectoriales, muy utilizados en sistemas de Recuperación de Información, Clasificación y *Clustering* de documentos.

A continuación, se presentan funciones de ponderación empleadas para calcular la importancia o relevancia de una cadena en el contenido de un texto. Estas funciones pueden emplear parámetros diferentes según los casos; desde la frecuencia de aparición en el documento o en la colección, hasta probabilidades condicionadas en problemas de clasificación automática.

Por último, se introducen aspectos relacionados con la selección de rasgos (conjunto de cadenas con el que se va a representar) como elementos de transformación de una información que inicialmente es de carácter cualitativo.



Tema 6. Técnicas de minería de textos. Clustering.

1. Introducción
2. Métodos de clustering
 1. No jerárquicos
 2. Jerárquicos
3. Otros
3. Trabajos comparativos
4. Herramientas

Se trata de un tema introductorio a una particular manera de organización de objetos, el clustering o agrupación automática. En este caso nos referimos al clustering de documentos, por lo que el contenido se particulariza a este tipo concreto de objetos. Se revisan las principales familias de algoritmos de clustering analizando sus características. Por último, se presentan estudios comparativos entre diferentes tipos de algoritmos y algunas herramientas de clustering de libre distribución.

Tema 7. Técnicas de minería de textos. Clasificación automática.

1. Introducción.
2. Clasificación automática de documentos
3. Aprendizaje automático.
4. Tipos de clasificación automática.
 1. Single label / multilabel
 2. Document pivoted / category pivoted
 3. Hard / ranking
 4. Fast-feature / full-feature
 5. Lean / rich categories
5. Técnicas de clasificación automática supervisada.
 1. Naïve Bayes
 2. Árboles de decisión.
 3. Clasificadores basados en reglas.
 4. Máquinas de vectores de soporte (*Support Vector Machines*).
6. Técnicas de clasificación semisupervisada.
 1. Autoentrenamiento (bootstrapping)
 2. Máquinas de vectores de soporte semisupervisadas (S3VM).
 3. Algoritmo de expectacion-maximización (EM)
7. Evaluación de sistemas de clasificación automática de documentos.
8. Exactitud (Accuracy).



9. Precisión (Precision) y cobertura (Recall).

10. Medida-F (F-measure).

En este capítulo se proporciona una introducción a la clasificación automática de documentos dentro del *Aprendizaje Automático*. En este contexto, y dependiendo de si se dispone o no de datos etiquetados para realizar la tarea de aprendizaje, se distingue entre *aprendizaje supervisado* y *semisupervisado*.

Se describen los diferentes tipos de clasificación automática, así como las principales técnicas tanto en el aprendizaje supervisado como semisupervisado. Por último, se presentan las funciones de evaluación más usadas dentro de los sistemas de clasificación automática de documentos.

METODOLOGÍA

La metodología es la general del programa de postgrado; junto a las actividades y enlaces con fuentes de información externas, existe material didáctico propio preparado por el equipo docente. Se trata de una metodología adaptada a las directrices del EEES, de acuerdo con el documento del IUED. La asignatura no tiene clases presenciales. Los contenidos teóricos se impartirán a distancia, de acuerdo con las normas y estructuras de soporte telemático de la enseñanza en la UNED.

El temario de la asignatura se estructura en siete temas y ha sido planteado de tal forma que el alumno pueda introducirse en los contenidos de la asignatura de una manera gradual, adquiriendo los conocimientos necesarios, y con un enfoque basado en la práctica de los mismos. La búsqueda y estudio de referencias bibliográficas forma parte fundamental del curso.

En cada unidad didáctica elaborada por el equipo docente hay una parte de "Planificación y orientaciones" con la siguiente información:

- Introducción general al contenido.
- Objetivos específicos.
- Esquema de los contenidos.
- Orientaciones sobre la forma de llevar a cabo el estudio del tema.
- Temporización recomendada.
- Indicación de si el tema tiene o no asociada una práctica obligatoria.

El estudiante debe en primer lugar leer esta parte de la unidad didáctica. Como se trata de un máster orientado a la investigación, las actividades de aprendizaje se estructuran en torno al estado del arte en cada una de las materias del curso y a los problemas en los que se van a focalizar las tareas teórico-prácticas que el alumno deberá realizar.

Las actividades formativas de la asignatura son:

1. Actividades teóricas interaccionando con equipos docentes, tutores y compañeros.

Resolución de dudas de contenido teórico de forma presencial, vía telefónica o en línea sobre la metodología, los contenidos o las actividades a realizar. Intercambio de



información a través de un foro virtual.

2. Actividades prácticas interaccionando con equipos docentes, tutores y compañeros.

Resolución de dudas de contenido práctico de forma presencial, vía telefónica o en línea sobre la metodología, los contenidos o las actividades a realizar. Intercambio de información a través de un foro virtual.

3. Actividades teóricas desempeñadas autónomamente.

Lectura reflexiva y crítica de las orientaciones metodológicas de la asignatura. Estudio de los materiales didácticos.

4. Actividades prácticas desempeñadas.

Elaboración de prácticas o tareas obligatorias de forma individual y en su caso la práctica o tarea opcional.

SISTEMA DE EVALUACIÓN

TIPO DE PRIMERA PRUEBA PRESENCIAL

Tipo de examen

No hay prueba presencial

TIPO DE SEGUNDA PRUEBA PRESENCIAL

Tipo de examen2

No hay prueba presencial

CARACTERÍSTICAS DE LA PRUEBA PRESENCIAL Y/O LOS TRABAJOS

Requiere Presencialidad

No

Descripción

No hay prueba presencial y las prácticas no requieren presencialidad.

Criterios de evaluación

Ponderación de la prueba presencial y/o los trabajos en la nota final

Fecha aproximada de entrega

Comentarios y observaciones

PRUEBAS DE EVALUACIÓN CONTINUA (PEC)

¿Hay PEC?

Si,PEC no presencial

Descripción



En esta asignatura no se realiza una prueba presencial, la evaluación se realiza **mediante evaluación continua a partir de las siguientes pruebas:**

Las prácticas obligatorias a lo largo del curso.

La práctica opcional para subir nota, una vez que se han realizado las prácticas obligatorias.

Aquellos alumnos que deseen obtener una mayor calificación en la convocatoria de junio, podrán elegir uno de entre los trabajos optativos que se irán proponiendo. En estos casos la calificación final dependerá de la calidad del trabajo realizado.

Las tareas obligatorias se deberán entregar en los plazos que se vayan indicando. La no entrega de las tareas en el plazo previsto supondrá suspender la asignatura en la convocatoria de junio. El trabajo optativo para subir nota también tendrá una fecha límite de entrega. Habrá otro plazo de entrega de tareas para la convocatoria de septiembre.

Criterios de evaluación

Todos los temas del programa de la asignatura a partir del Tema 2 tienen asociada una práctica obligatoria cuya entrega es un requisito imprescindible para aprobar la asignatura. La realización correcta de todas las prácticas obligatorias asegura una nota de APROBADO, que podría llegar hasta NOTABLE (7) dependiendo de la calidad de las soluciones en su conjunto.

Aquellos estudiantes que deseen obtener una mayor calificación podrán elegir uno de entre los trabajos optativos que se proponen por parte del equipo docente, normalmente se ofertan 3 ó 4 trabajos optativos. En estos casos la calificación final dependerá de la calidad del trabajo realizado.

Ponderación de la PEC en la nota final

El promedio de las calificaciones obtenidas en las prácticas obligatorias y en su caso en la práctica opcional constituye la nota final de la asignatura.

Fecha aproximada de entrega

Comentarios y observaciones

Las prácticas obligatorias tienen un plazo de entrega fijo, que suele ser de unas tres semanas después de haber finalizado el tema correspondiente, de acuerdo con la temporización de la asignatura y los periodos vacacionales. Esta temporización permite al estudiante su ficiente margen de tiempo para poder organizar su trabajo de acuerdo con sus circunstancias personales.

Los estudiantes que no entreguen las tareas en el plazo establecido para la convocatoria de junio tendrán otro plazo de entrega en la convocatoria de septiembre.

La práctica o tarea opcional también tiene un plazo de entrega acorde con la temporización de la asignatura.



OTRAS ACTIVIDADES EVALUABLES

¿Hay otra/s actividad/es evaluable/s? No

Descripción

Criterios de evaluación

Ponderación en la nota final

Fecha aproximada de entrega

Comentarios y observaciones

¿CÓMO SE OBTIENE LA NOTA FINAL?

El promedio de las calificaciones obtenidas en las prácticas obligatorias y en su caso en la práctica opcional constituye la nota final de la asignatura.

BIBLIOGRAFÍA BÁSICA

El equipo docente ha elaborado unidades didácticas para todos los temas de la asignatura.

Cada unidad didáctica se compone de:

- Planificación y orientaciones del tema.
- Contenidos teórico-prácticos con enlaces a material disponible en la Web, si es pertinente.
- En caso necesario indica qué capítulos o partes de la bibliografía básica o complementaria se debe consultar.

Como bibliografía de la asignatura se deberán estudiar capítulos seleccionados de las siguientes referencias:

- Gordon, A.D. Classification. 2nd Edition. Chapman & Hall/CRC, 1999.
- McEnery, T., Wilson, A. Corpus Linguistics. Edinburgh University Press, 1996.
- Manning, C.D., and Schütze, H. Foundations of Statistical Natural Language Processing. The MIT Press (2000).
- Mitchell, T. Machine Learning. McGraw Hill, 1997. (Nuevos capítulos creados en 2006 y disponibles en <http://www.cs.cmu.edu/%7Etom/mlbook.html>)
- S. Weiss; N. Indurkha; T. Zhang; F. Damerau. Text Mining: Predictive Methods for Analyzing Unstructured Information, 2004.

BIBLIOGRAFÍA COMPLEMENTARIA

La bibliografía complementaria es específica de cada capítulo e incluye partes de libros y artículos. A modo de muestra se presentan aquí algunos de ellos:

- [Morrison 2000] Morrison, M. y Fraguas, S. tr. XML al descubierto. Pearson Educación, 2000.
- [Allen 1994] J. Allen Natural Language Understanding. The Benjamin/Cumming Publishing Company, Inc., 1994.



- [Goldberg 1989] Goldberg, D. E. Genetic Algorithms in search, optimization and machine learning. Addison Wesley, 1989.
- [Manning et al. 2008] Manning, C.D., Raghavan, p. y Schütze, H. Introduction to Information Retrieval. Cambridge University Press, 2008.
- [Salton 1989] Salton, G. Automatic text processing: the transformation, analysis, and retrieval of information by computer. Addison-Wesley Longman Publishing Co., Inc., 1989.
- [Zhao & Karypis 2002] Zhao, Y. y Karypis, G. Evaluation of Hierarchical Clustering Algorithms for Document Datasets. Data Mining and Knowledge Discovery, pag. 515 524, ACM Press, 2002.
- [Milligan & Cooper 1985] Milligan, G. y Cooper, M. An examination of procedures for determining the number of clusters in a data set . Psychometrika, 50(2), pag. 159 179, 1985.
- [Sebastiani 2002] Sebastiani, F. Machine learning in automated text categorization. ACM Comput. Surv., 34(1), pag. 1 47, 2002.
- [Joachims 1998] Joachims, T. Text categorization with support vector machines: learning with many relevant features. Proceedings of ECML-98, 10th European Conference on Machine Learning, pag. 137 142, 1998.

RECURSOS DE APOYO Y WEBGRAFÍA

La plataforma de e-Learning Alf proporcionará el adecuado interfaz de interacción entre el alumno y sus profesores. Alf es una plataforma de e-Learning y colaboración que permite impartir y recibir formación, gestionar y compartir documentos, crear y participar en comunidades temáticas, así como realizar proyectos online.

Se ofrecerán las herramientas necesarias para que, tanto el equipo docente como el alumnado, encuentren la manera de compaginar tanto el trabajo individual como el aprendizaje cooperativo.

IGUALDAD DE GÉNERO

En coherencia con el valor asumido de la igualdad de género, todas las denominaciones que en esta Guía hacen referencia a órganos de gobierno unipersonales, de representación, o miembros de la comunidad universitaria y se efectúan en género masculino, cuando no se hayan sustituido por términos genéricos, se entenderán hechas indistintamente en género femenino o masculino, según el sexo del titular que los desempeñe.

