

PROCESAMIENTO DEL LENGUAJE NATURAL

Curso 2013/2014

(Código:31101269)

1.PRESENTACIÓN

Este curso introductorio al procesamiento computacional del lenguaje natural aborda el diseño y la construcción de programas que pueden tratar, comprender y generar lenguaje natural. Se estudiarán los problemas y soluciones (modelos y técnicas) básicas en los niveles sintáctico, semántico y pragmático. Un capítulo de introducción y otro de áreas de aplicación, situarán la asignatura desde una perspectiva histórica, y permitirán conocer el estado actual de las realizaciones en este campo. La realización de un proyecto permitirá poner en práctica los conocimientos adquiridos.

Ficha técnica:

Tipo	Optativa
Cuatrimestre	Primero
Créditos/horas totales	6/150
Horas de estudio teórico	44
Horas de prácticas	40
Horas complementarias	66

Profesorado

Coordinador: Felisa Verdejo Maillo
(Dpto. Lenguajes y Sistemas Informáticos, UNED)

Profesores: Enrique Amigó Cabrera
(Dpto. Lenguajes y Sistemas Informáticos, UNED)

2.CONTEXTUALIZACIÓN

Esta asignatura está encuadrada en el Módulo ESP-IA-1: Sistemas Inteligentes de diagnóstico, planificación y control (30 créditos, 1er. semestre), línea de especialización optativa que incluye materias que describen la aplicación de los fundamentos y métodos en diferentes áreas, tales como la Visión Artificial y la Robótica Perceptual y Autónoma, la Minería de Datos, el Descubrimiento de Información en Textos y el Procesamiento del Lenguaje Natural.

Permitirá por tanto al alumno poner en práctica los fundamentos y métodos adquiridos en IA, para el procesamiento del Lenguaje Natural. A su vez le proporcionará conocimiento y tecnología para valorar la incorporación del lenguaje natural en diferentes aplicaciones interactivas, o que hagan uso de de información textual.



3. REQUISITOS PREVIOS RECOMENDABLES

Es importante una lectura fluida del inglés y disponer de conexión a internet. En cuanto a contenidos, este curso tiene relación estrecha con las siguientes asignaturas de la carrera de Ingeniería Informática: Teoría de autómatas, Procesadores de Lenguaje, e Introducción a la Inteligencia Artificial, que proporcionan la base en cuanto a formalismos y técnicas computacionales. Así mismo las asignaturas de programación, y especialmente aquellas en que se estudian paradigmas declarativos, constituyen un complemento interesante para cursar Procesamiento de Lenguaje Natural.

4. RESULTADOS DE APRENDIZAJE

En la primera parte del curso, mediante el estudio de la bibliografía el alumno adquirirá una visión amplia de las técnicas de procesamiento de lenguaje natural en los niveles léxico, sintáctico y semántico y sus aplicaciones. Los conocimientos adquiridos a nivel teórico se pondrán en práctica mediante la realización de ejercicios en un entorno WEB, que pondrá a disposición del alumno las herramientas necesarias para la elaboración de un analizador morfológico y un analizador sintáctico y semántico sobre un subdominio abordable del lenguaje. Paralelamente, los conocimientos adquiridos a nivel global y la capacidad de síntesis se pondrán en práctica mediante el desarrollo de una serie de resúmenes guiados por cuestionarios. En la segunda parte del curso el alumno adquirirá la destreza necesaria para elaborar un sistema de procesamiento de lenguaje orientado a una tarea específica. Con este curso el alumno asimilará tanto el potencial de las técnicas existentes de procesamiento de lenguaje como de sus limitaciones, siendo capaz de analizar en qué casos es factible aplicar estas técnicas en la resolución de un problema.

5. CONTENIDOS DE LA ASIGNATURA

Estructura y contenido teórico

Tema 1. Introducción

Se identifican algunos de los problemas más importantes que se plantean en el estudio y tratamiento computacional del lenguaje natural, y se da una breve descripción histórica del desarrollo de esta disciplina.

Tema 2. Autómatas finitos, procesamiento de unidades morfológico-léxicas, N-gramas

Se fijan los conceptos de expresiones regulares y los operadores asociados además de autómatas finitos y lenguajes regulares. Se introduce además el concepto de morfología en inglés y, mediante lecturas complementarias, morfología castellana. El tema aborda a continuación las técnicas de procesamiento morfológico basadas en lexicones, transductores y la aproximación de stemming. Finalmente se estudian los N-gramas.

Tema 3. Etiquetado sintáctico

En este tema se establece un puente entre los niveles léxico y sintáctico. Se describe la taxonomía de palabras aplicables a diferentes lenguas, y las diferentes técnicas de etiquetado sintáctico existentes.

Tema 4. Gramáticas de contexto libre para el análisis de lenguaje natural

Se introducen las estructuras de la oración, incluyendo los conceptos de constituyente, sintagmas nominales y verbales, oraciones coordinadas, y su representación mediante gramáticas de contexto libre.

Tema 5. Parsing



Este tema se centra en las técnicas fundamentales de análisis sintáctico: descendente ("top-down") y ascendente ("bottom-up").

Tema 6. Unificación de rasgos

Se describe el análisis sintáctico mediante la unificación de rasgos, su implementación y el diseño de restricciones de unificación.

Tema 7. Semántica y análisis semántico

Este tema aborda en general las diferentes técnicas de procesamiento a nivel semántico del lenguaje. Se introducen los conceptos de nivel semántico, predicados de primer orden y análisis semántico dirigido por sintaxis, entre otros. Incluye además el nivel léxico semántico en el que se describen relaciones semánticas entre palabras, y bases de datos léxico semánticas.

Tema 8. Discurso, extracción de información y resúmenes

Este tema incluye el estudio de conceptos básicos de nivel de discurso como son la segmentación y resolución de correferencias. Finalmente nos centraremos en dos tipos de aplicaciones que son hoy día muy utilizadas: la extracción de información y los resúmenes, para estudiar la clase de problemas que se plantean y el alcance de las técnicas para tratarlos. A partir de esta base, se propone un trabajo personal de carácter teórico y práctico, que pone en juego los conocimientos adquiridos en la asignatura.

Objetivos por tema y orientaciones breves

Tema 1. Introducción

Objetivos: Entender el procesamiento de lenguaje natural desde una perspectiva global.

Orientaciones: Lectura del capítulo 1 del libro base y bibliografía complementaria.

Tema 2: Autómatas finitos, procesamiento de unidades morfológico-léxicas, N-gramas

Objetivos: Refrescar los conocimientos sobre expresiones regulares y autómatas finitos. Aprender los conceptos fundamentales del análisis morfológico y las técnicas algorítmicas que permiten implementarlo.

Orientaciones: Lectura del capítulo 2 del libro base (debe suponer un refresco de conceptos conocidos) estudio del capítulo 3 (3.1 a 3.8, 3.9 solo la introducción), 4 (hasta el 4.8 inclusive), y lecturas complementarias. Para la puesta en práctica de estas técnicas se pondrá a disposición del alumno un entorno de prácticas en donde se proponen: una serie de ejercicios prácticos para familiarizarse con los transductores, un glosario de términos y conceptos relacionados con el análisis morfológico y una pequeña práctica. Además, se pondrá a disposición del alumno sitios WEB en donde testear analizadores existentes.

Tema 3: Etiquetado sintáctico

Objetivos: Asimilar los conceptos de etiquetado sintáctico y las dos técnicas básicas de etiquetado: por reglas y técnicas estocásticas.

Orientaciones: Capítulo 5 (hasta el 5.7) del libro base y lecturas complementarias para el etiquetado en castellano. Con carácter opcional se recomienda estudiar el capítulo 6



Tema 4: Gramáticas de contexto libre

Objetivos: Repaso de conceptos relativos a las gramáticas de contexto libre y estructuras de la oración.

Orientaciones: Capítulo 12 (hasta 12.7) del libro base y referencias a herramientas accesibles vía WEB.

Tema 5: Parsing

Objetivos: Estudio a fondo de las técnicas de análisis sintáctico.

Orientaciones: Capítulo 13 del libro y bibliografía complementaria

Tema 6: Estructuras de rasgos y unificación.

Objetivos: Comprender en profundidad el concepto de unificación y su aplicación en el procesamiento de lenguaje.

Orientaciones: Capítulo 15 (hasta 15.5) del libro base Para este capítulo vamos a utilizar la herramienta PC-PATR que es una implementación de PATR-II. En el entorno de prácticas se incluye un pequeño manual que describe la herramienta y el formalismo. Así mismo se incluyen como ejemplos 4 gramáticas de sucesivo nivel de complejidad.

Tema 7: Semántica y análisis semántico

Objetivos: Conocer las diferentes técnicas de procesamiento a nivel semántico del lenguaje y los recursos léxico semánticos.

Orientaciones: Capítulos 17, 18, 19 (hasta 19.4) y 20.1 del libro base. Los conocimientos adquiridos en este tema serán también puestos en práctica mediante la realización de ejercicios en un entorno WEB, para lo que será necesario a su vez el acceso a bases de datos léxico semánticas.

Tema 8: Nivel de discurso, tareas de extracción de información y resúmenes

Objetivos: Estudio de conceptos básicos de nivel de discurso, y de las tareas mencionada

Orientaciones: Epígrafes de los capítulos 21.1, 21.4, 22.1, 22.2, 22.3.3, 23.3, 23.4, 23.5, 23.6, y 23.7 del libro base.

Actividades prácticas programadas

Aplicación de técnicas de análisis morfológico y sintáctico mediante un entorno WEB. Realización de 3 resúmenes orientados por unas cuestiones. Desarrollo de un proyecto que se definirá sobre la base de los conocimientos adquiridos en los temas teóricos utilizando un entorno de aplicaciones PLN.

Plan de trabajo

- Tema 1. Introducción: 3 horas (semana 1)
- Tema 2: Autómatas finitos, procesamiento de unidades morfológico-léxicas: 6 horas (semanas 2, 3 y 4)
- Ejercicios de análisis morfológico: 10 horas.
- Temas 3: Etiquetado 3 horas (semana 5)
- Entrega del resumen correspondiente a temas 2 y 3, y ejercicios de morfología. El plazo de



entrega se notificará en el entorno.

- Temas 4 y 5 : Gramáticas de contexto libre y parsing: 8 horas (semanas 6 y 7)
- Tema 6: Estructuras de rasgos y unificación: 4 horas (semana 8)
- Tema 7: Semántica y análisis semántico: 12 horas (semanas 9, 10 y 11)
- Ejercicios de análisis sintáctico y semántico: 30 horas. El plazo de realización de los ejercicios de sintaxis y semántica y la entrega del resumen correspondiente a los temas 4, 5, 6 y 7 se notificará en el entorno.
- Tema 8: Nivel de discurso y aplicaciones de extracción y resumen: 8 horas (semana 12 y 13)
- Proyecto: 66 horas (semanas 14-22)

6.EQUIPO DOCENTE

- [MARIA FELISA VERDEJO MAILLO](#)
- [ENRIQUE AMIGO CABRERA](#)

7.METODOLOGÍA

El curso consta de un conjunto de temas cuyo estudio se realiza con la siguiente metodología dentro de un paradigma de construcción de conocimiento:

Para cada tema, el alumno debe acceder al material propuesto por el equipo docente. Este material consta de:

- Bibliografía básica común a todos los temas. Se trata un libro con un conocimiento ya estructurado facilitando la introducción del alumno en la materia.
- Artículos científicos. Se propone la lectura de algunos artículos de carácter científico. Su contenido es más específico. Aparte de conocer su contenido, el alumno se familiarizará con la estructura y formato que deben seguir los textos de estas características.
- Enlaces web que apuntan a recursos y herramientas relacionados con el tema.

A partir de este material y con la guía de unas preguntas, el alumno debe realizar dos breves resúmenes de 5-10 páginas, correspondiendo cada uno a un bloque de temas, con el objetivo de sintetizar el conocimiento que ha adquirido. La elaboración del resumen se dirige a:

- Estimular la lectura detenida del material propuesto.
- Provocar la necesidad de buscar información que complete el material propuesto inicialmente. Esta búsqueda es un entrenamiento necesario en la formación del alumno como investigador. Con cada trabajo tendrá mayor capacidad para encontrar y discriminar fuentes de información relevantes, requisito para desarrollar cualquier trabajo de investigación posterior.
- Estimular una reflexión sobre el material estudiado, necesaria para poder realizar una síntesis de calidad.
- Aprender a sintetizar y escribir informes científicos

Junto con la elaboración de resúmenes guiados, el alumno deberá realizar una serie de ejercicios para los que dispondrá de herramientas en el entorno virtual de la asignatura. De esta forma, el alumno podrá centrarse en aspectos del lenguaje y diseño de gramáticas sin necesidad de implementar desde un principio autómatas y mecanismos de unificación.

Los últimos meses del curso se dirigen a afianzar los conocimientos adquiridos mediante la elaboración de un proyecto en el que se pondrán en práctica las técnicas aprendidas con datos y herramientas similares a los utilizados en la practica profesional

8.BIBLIOGRAFÍA BÁSICA

ISBN(13): 9780135041963



Título: SPEECH AND LANGUAGE PROCESSING (segunda)
Autor/es: Jurafsky, Daniel ; Martin, James H. ;
Editorial: PEARSON EDUCATION

Buscarlo en librería virtual UNED

Buscarlo en bibliotecas UNED

Buscarlo en la Biblioteca de Educación

Buscarlo en Catálogo del Patrimonio Bibliográfico

Comentarios y anexos:

La primera edición del libro de bibliografía básica no incluye algunos contenidos del curso.

9.BIBLIOGRAFÍA COMPLEMENTARIA

Comentarios y anexos:

En el entorno virtual de la asignatura se pone a disposición de los alumnos material de estudio complementario (artículos, recopilaciones y referencias a otro material disponible en la web)

10.RECURSOS DE APOYO AL ESTUDIO

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

Se dispondrá también de un entorno WEB con las herramientas necesarias para la implementación de transductores y gramáticas de unificación para el análisis morfológico, sintáctico y semántico.

Para el proyecto se facilitará el acceso a los datos y herramientas necesarias para llevarlo a cabo.

11.TUTORIZACIÓN Y SEGUIMIENTO

La tutorización de los alumnos se llevará a cabo a través de una plataforma de aprendizaje en internet, que incluye comunicación electrónica con el equipo docente, acceso a herramientas para los ejercicios, y áreas de compartición de trabajo. Los trabajos que se proponen se evalúan a lo largo del curso.

12.EVALUACIÓN DE LOS APRENDIZAJES

La evaluación se realizará a partir de los ejercicios y resúmenes realizados así como del proyecto personal. Es necesario entregar en cada plazo tanto los resúmenes como los ejercicios y el proyecto. No hay más que un único plazo de entrega para cada elemento. No hay examen final.

13.COLABORADORES DOCENTES

Véase equipo docente.

