

**FITXA IDENTIFICATIVA****DADES DE L'ASSIGNATURA****Codi:** 36516**Nom:** Dades no estructurades**Cicle:** Grau**Crèdits ECTS:** 6**Curs acadèmic:** 2026-27**TITULACIONS**

Titulació	Centre	Curs	Període
1332 - Grau en Intel·ligència i Anàlisi de Negocis/BIA	Facultat d'Economia	4	Primer quadrimestre, Sin determinar

**MATÈRIES**

Titulació	Matèria	Caràcter
1332 - Grau en Intel·ligència i Anàlisi de Negocis/BIA	Eines i Tècniques d'Anàlisi de Dades	OBLIGATÒRIA

**COORDINACIÓ**

MONTALVA CANDEL IGNACIO

MONTALVA CANDEL IGNACIO

MONTALVA CANDEL IGNACIO

**RESUM**

Amb el desenvolupament de la Web 2.0 i les Xarxes Socials van arribar les dades massives. La majoria d'aquestes dades sense una estructura inicial prefixada. Ens referim a documents, fotos, vídeos, correus electrònics, tuits, etc. La major part d'aquestes dades els generen els propis usuaris. Tots els dies s'envien correus electrònics, es publiquen tuits o es pugen fotos o vídeos a les diferents xarxes socials. Totes aquestes dades faciliten molta informació sobre les persones que l'estan generant. No obstant això, en ser dades No estructurades s'haurà de transformar la informació que generen per a poder analitzar-la i convertir-la en coneixement. Un exemple és la informació d'una empresa en la xarxa social Twitter. Es poden recopilar tots els tuits que esmenten una empresa, i mitjançant una transformació en una base de dades estructurada es podrà fer anàlisi de sentiment i saber què opinen les persones d'aquesta empresa. També es poden descarregar els tuits de la competència per a saber l'opinió sobre aqueixes empreses i poder modificar l'estratègia de l'empresa. Les dades No estructurades precisaran de bases de dades no relacionals, com poden ser MongoDB (basada en documents), Neo4j (basada en grafs), etc. Les noves bases de dades permetran realitzar una anàlisi diferent de la que es realitza amb les bases de dades relacionals. L'objectiu de l'assignatura serà que els alumnes coneguen i puguin treballar amb aquestes



dades no estructurades i realitzar anàlisis d'aquestes per a tindre un millor coneixement de l'empresa i de la competència.

## CONEXIMENTS PREVIS

### RELACIÓ AMB ALTRES ASSIGNATURES DE LA MATEIXA TITULACIÓ

No s'ha especificat restriccions de matrícula amb altres assignatures del pla d'estudis.

### ALTRES TIPUS DE REQUISITS

És recomanable tindre coneixements del programari R i RStudio, així com Estadística Bàsica, Inferència Estadística i Aprenentatge Automàtic (machine Learning).

## COMPETÈNCIES / RESULTATS D' APRENTATGE

### 1332 - Grau en Intel·ligència i Analítica de Negocis/BIA

Aplicar, utilitzant programari, tècniques d'aprenentatge automàtic (machine learning) no supervisat i semisupervisat.

Aplicar, utilitzant programari, tècniques d'aprenentatge automàtic (machine learning) supervisat.

Aplicar mètodes i tècniques d'anàlisis, síntesis i representació gràfica mitjançant programes informàtics.

Aplicar mineria de dades mitjançant programes informàtics.

Capacitat d'aprenentatge autònom.

Capacitat per a analitzar i buscar informació provinent de fonts diverses.

Capacitat per a definir, resoldre i exposar de forma sistemàtica problemes complexos.

Capacitat per a treballar en equip, amb el compromís per la qualitat, l'ètica, la igualtat entre persones i la responsabilitat social.

Capacitat per a utilitzar les TIC, tant en l'àmbit d'estudi com en el desenvolupament professional.

Manejar aplicacions de descàrrega, capturar i manipular valors de dades no estructurades.

Que els estudiants puguen transmetre informació, idees, problemes i solucions a un públic tant especialitzat com no especialitzat.

Reorganitzar i reestructurar variables i bases de dades.

## DESCRIPCIÓ DE CONTINGUTS



## 1. Introducció

- a. Dades, Informació i Aprofitament
- b. Dades estructurades vs no estructurades
- c. La il·lusió de l'anàlisi de dades no estructurades
- d. Estàndards de marcatge: XML, JSON,...

## 2. Captura de Dades a la Web I

- a. Captura de dades de llocs web: captura directa
- b. Una aplicació a obtenir un índex: IPC
- c. Captura de dades mitjançant API's
- d. Bones pràctiques

## 3. Web Scraping: Captura de Dades a la Web II

- a. Estructura d'una pàgina web: HTML
- b. HTML dinàmic: JavaScript
- c. Fulles d'estil: CSS, W3-CSS, Bootstrap(CSS)
- d. Captura completa d'un lloc web
- e. Captura específica de dades de la web
- f. Scripts que imiten la intervenció humana: Bots

## 4. Mineria de Text

- a. Tipus i usos de les tècniques d'anàlisi de text
- b. Enfocaments: bag of words (BoW) i natural language processing (NLP)
- c. El flux de treball bàsic
- d. Preparació i estructures de dades
- e. Visualitzacions i anàlisi descriptiu

## 5. Anàlisi de Sentiments

- a. Contingut subjectiu en textos, polaritat i emocions
- b. Enfocament basat en diccionaris vs aprenentatge automàtic
- c. Diccionaris de sentiments en Espanyol
- d. Aplicacions de l'anàlisi de sentiments

- a. Tècniques d'aprenentatge supervisat i no supervisat
- b. Modelització probabilística de temes (topic modeling)



## 6. Aprenentatge Automàtic i Analítica de Text

- a. Tècniques d'aprenentatge supervisat i no supervisat
- c. Classificació de textos
- d. Modelització predictiva
- e. Tècniques avançades per a l'anàlisi de text

## 7. Sistemes de Recomanació

- a. Tipus de sistemes de recomanació
- b. Preferències implícites i explícites
- c. Construcció d'un sistema de recomanació
- d. Avaluació d'un sistema de recomanació
- e. Aplicacions

## 8. Xarxes i Xarxes Socials

- a. Definició i Tipologies
- b. Models estadístics de xarxes socials
- c. Models de grafs aleatoris
- d. Xarxes socials i segmentació
- e. Xarxes neuronals aplicades

## VOLUM DE TREBALL (HORES)

### ACTIVITATS PRESENCIALS

Activitat	Hores
Teoria	15,00
Aula informàtica	45,00
<b>Total hores</b>	<b>60,00</b>

### ACTIVITATS NO PRESENCIALS

Activitat	Hores
Assistència a altres activitats	0,00
Elaboració de treballs individuals o en grup	20,00
Estudi i treball autònom	0,00
Preparació de classes	50,00
Preparació d'activitats d'avaluació	10,00
Resolució de casos pràctics	10,00
<b>Total hores</b>	<b>90,00</b>

## METODOLOGIA DOCENT



- Classe teòrica presencial per a presentar els continguts teòrics essencials de la matèria.
- Classes pràctiques presencials, relatives a la resolució de problemes, estudis de casos, amb aplicació de tècniques, presentacions orals, debats, individualment i/o en equip.
- Treball autònom supervisat i basat en la realització d'exercicis, casos pràctics i qüestions a debatre o experiments en línia, amb suport tutorial.

uport tutorial.

## AVALUACIÓ

Durant el curs es realitzaran diverses pràctiques i proves d'avaluació, mitjançant les quals l'alumnat podrà posar de manifest els conceptes adquirits, tant teòrics com pràctics. El conjunt de les pràctiques i proves realitzades suposarà el 60% de la nota final.

Com a projecte final de curs, l'alumnat haurà de realitzar un treball en què haurà de plasmar els coneixements adquirits en l'assignatura. Este informe s'haurà de lliurar, com a màxim, en la data fixada per a l'examen de primera convocatòria (40% de la nota final).

Encara que les pràctiques no són recuperables, l'alumnat que no supere l'assignatura en primera convocatòria podrà recuperar l'informe final, que s'haurà de lliurar, com a màxim, en la data fixada per a l'examen de segona convocatòria.

Per a poder aplicar els percentatges anteriorment esmentats serà necessari obtindre, almenys, una qualificació de 5 en el projecte final de curs.

## BIBLIOGRAFIA

- Anandarajan, M.; Hill, C. y Nolan, T. (2019) Practical Text Analytics. Maximixing the Value of Text Data. Spinger Nature, Switzerland.
- Bali, R. Sarkar, D. y Sharma, T. (2017) Learning Social Media Analytics with R. Pack Publishing, Birmingham, UK.
- Gorakala, S.K. y Usuelli, M. (2015) Building a Recommendation System with R. Pack Publishing, Birmingham, UK.
- Kwartler, T. (2017). Text mining in practice with R. John Wiley & Sons.
- Munzert, S.; Rubba, C.; Meißner, P. y Nyhuis, D. (2015) Automated data collection with R: a practical guide to web scraping and text mining. John Wiley & Sons, UK.
- Rusell, Matthew A. (2013) Mining the Social Web. O'Reilly Media, CA.