

**FITXA IDENTIFICATIVA****DADES DE L'ASSIGNATURA**

Codi: 36427
Nom: Agrupament i varietats
Cicle: Grau
Crèdits ECTS: 6
Curs acadèmic: 2025-26

TITULACIONS

Titulació	Centre	Curs	Període
1400 - Grau Eng.Informàtica	Escola Tècnica Superior d'Enginyeria	4	Primer quadrimestre
1406 - Grau en Ciència de Dades	Escola Tècnica Superior d'Enginyeria	3	Primer quadrimestre

MATÈRIES

Titulació	Matèria	Caràcter
1400 - Grau Eng.Informàtica	Matèria Optativa	OPTATIVA
1406 - Grau en Ciència de Dades	Aprenentatge automàtic i mineria de dades	OBLIGATÒRIA

COORDINACIÓ

MARTINEZ GIL FRANCISCO

RESUM

L'assignatura 'Agrupaments i Varietats' és el complement natural de l'assignatura 'Aprenentatge Màquina' que s'impartix també en el primer quadrimestre del tercer curs. Es revisen les tècniques més importants per a trobar estructures i patrons en conjunts de dades que no estan etiquetats. L'assignatura es dividix en dos parts. En la primera es tracten les tècniques més esteses d'aprenentatge no supervisat, conegudes també com a tècniques d'agrupament (clustering) . Es revisen l'agrupament jeràrquic, l'agrupament de per particions en les seues variants 'Hard' (K-Means) i 'Soft' (Fuzzy-C-Means) , i models d'agrupaments no compactes com l'agrupament basat en densitat (DBSCAN) i el basat en grafos (agrupament espectral) En la segona part s'amplien els coneixements sobre reducció de la dimensionalitat en dades ja introduïts en l'assignatura de segon curs 'Models Lineals'. Mentre que en esta assignatura s'introduïx PCA com el model lineal més important per a la reducció de dimensionalitat, en 'Agrupaments i Varietats' estendrem esta problemàtica a models no lineals, es a dir, a organitzacions espacials de dades que no poden ser modelades per mitjà de hiperplans. Comença esta segona part amb un model senzill, els Mapes



Autoorganitzatiu. Posteriorment es revisaran algunes tècniques dins del grup conegut com 'Manifold Learning', específicament ISOMAP i Locally Linear Embedding (LLE). Finalment es revisarà la tècnica per a la visualització de dades coneguda com a t-SNE, la qual cosa ens connecta amb l'assignatura 'Visualització de dades' de segon curs. A banda de les diferents tècniques presentades, l'alumne adquirirà /revisarà coneixements sobre conceptes essencials en aprenentatge màquina, com són els conceptes de similaritat, mètriques, espai de característiques, partició, o el problema de l'explosió combinatòria de la dimensionalitat.

A causa dels nombrosos temes que tracta d'abordar esta assignatura quadrimestral, la presentació dels temes serà necessàriament superficial, presentant les idees bàsiques de cada tècnica, els tipus de problemes que pretén resoldre i exposant els algorismes bàsics.

Els coneixements impartits en esta assignatura són la base per a comprendre tècniques d'aprenentatge presentades en les assignatures 'Procesado del Llenguatge Natural' i les diferents optatives d'anàlisi de dades geogràfiques, d'àudio i veu, de salut i Web i xarxes socials.

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 necessari tindre presents els continguts de probabilitat revisats en l'assignatura Probabilitat i Simulació, també el concepte de diagonalització de matrius i espectre d'una matriu donat en l'assignatura de Algebra, així com els continguts en tècniques d'optimització de l'assignatura Optimització així com els continguts de l'assignatura Models Lineals referents a tècniques de reducció de la dimensionalitat.

COMPETÈNCIES / RESULTATS D' APRENENTATGE

-

(CB3) Que els estudiants tinguen la capacitat d'arreglar i interpretar dades rellevants (normalment dins de la seua àrea d'estudi) per emetre judicis que incloguen una reflexió sobre temes rellevants d'índole social, científica o ètica.

(CB4) Que els estudiants puguen transmetre informació, idees, problemes i solucions a un públic tant especialitzat com no especialitzat.

(CE03) Capacitat per resoldre problemes de classificació, modelització, segmentació i predicció a partir d'un conjunt de dades.



(CE06) Capacitat per representar i visualitzar conjunts de dades per a l'extracció de coneixement.

(CE07) Capacitat per modelar la dependència entre una variable resposta i diverses variables explicatives, en conjunts de dades complexes, mitjançant tècniques d'aprenentatge màquina, interpretant els resultats obtinguts.

(CE13) Saber dissenyar, aplicar i avaluar algorismes de Ciència de Dades per a la resolució de problemes complexos.

(CG02) Capacitat de resoldre problemes amb iniciativa, creativitat, i de comunicar i transmetre coneixements, habilitats i destreses, comprenent la responsabilitat ètica i professional de l'activitat del Científic de Dades.

(CG03) Capacitat per a la realització de models, càlculs, informes, planificació de tasques i altres treballs anàlegs en l'àmbit específic de la Ciència de Dades.

(CT03) Habilitat per defensar el seu treball amb rigor i arguments, exposant-ho de forma adequada i precisa, recolzant-se en els mitjans necessaris.

(CT05) Capacitat per avaluar els avantatges i inconvenients de diferents alternatives metodològiques i/o tecnològiques en diferents àmbits d'aplicació.

C1 - Capacitat per conèixer els fonaments, els paradigmes i les tècniques propis dels sistemes intel·ligents, i analitzar, dissenyar i construir sistemes, serveis i aplicacions informàtiques que utilitzen aquestes tècniques en qualsevol àmbit d'aplicació.

C2 - Capacitat per adquirir, obtenir, formalitzar i representar el coneixement humà en una forma computable per a la resolució de problemes mitjançant un sistema informàtic en qualsevol àmbit d'aplicació, particularment els relacionats amb aspectes de computació, percepció i actuació en ambients o entorns intel·ligents.

C3 - Capacitat per conèixer i desenvolupar tècniques d'aprenentatge computacional i dissenyar i implementar aplicacions i sistemes que les utilitzen, incloent-hi les dedicades a extracció automàtica d'informació i de coneixement a partir de grans volums de dades.

SI3 - Capacitat per participar activament en l'especificació, el disseny, la implementació i el manteniment dels sistemes d'informació i comunicació.

DESCRIPCIÓ DE CONTINGUTS

1. Introducció

1.1 Aprenentatge no supervisat

1.2 Noció de similaridad. Concepte de mètrica. Tipus de mètriques

1.3 Conceptos bàsics: espai de característiques, vector de característiques, partició, matriu de proximitat

1.4 Concepte d'agrupament. Taxonomia



2. Agrupament jeràrquic

- 2.1 Idees bàsiques. Agrupaments aglomeratiu i divisiu
- 2.2 Tipus de Linkage
- 2.3 Algoritmes bàsics
- 2.4 Dendogramas. Interpretació
- 2.5 Propietats. Mesures de qualitat

3. Agrupament per particions

- 3.1 El model esperança-maximització (EM)
- 3.2 Idees bàsiques. Agrupaments Soft i Hard
- 3.3 Agrupament 'hard'. Algoritme de K-Means
- 3.4 Problemes associats. Inicialització. Elecció del nombre de clusters
- 3.5 Agrupament 'soft'. Algoritme Fuzzy-C-Means
- 3.6 Problemes associats.

4. Agrupament basat en grafos

- 4.1 Agrupament basat en grafos. Agrupament espectral
- 4.2 Idees bàsiques. Representació de dades en grafos
- 4.3 Laplaciana del grafo. Descomposició espectral
- 4.4 Algoritmes . Implementacions amb llibreries

5. Agrupament basat en densitat

- 5.1 Idees bàsiques. Conceptes de densitat
- 5.2 Algoritme DBSCAN
- 5.3 Implementacions en llibreries i exemples

6. Introducció a les tècniques de reducció de dimensionalitat

- 6.1 El problema de la maledicció de la dimensionalidad
- 6.2 Concepte de Manifold i problemàtica dels agrupaments no lineals
- 6.3 Concepte de dimensionalidad intrínseca

7. Mapes auto-organitzatius



- 7.1 Concepte d'aprenentatge competitiu. Concepte de SOM
- 7.2 Algoritme. Punts forts i dèbils de l'aproximació. Implementacions en llibreries
- 7.3 Exemples

8. Aprenentatge en varietats

- 8.1 Introducció. Idees bàsiques sobre les tècniques de Manifold Learning
- 8.2 Algoritme ISOMAP. Punts forts i dèbils. Paràmetres
- 8.3 Algoritme Locally Linear Embedding (LLE) . Punts forts i dèbils. Paràmetres
- 8.4 Exemples

9. Reducció de dimensionalidad per a visualització

- 9.1 Introducció al problema
- 9.2 Algoritme t-SNE. Punts forts i dèbils. Comportament
- 9.3 Implementacions en llibreries
- 9.4 Exemples

VOLUM DE TREBALL (HORES)

ACTIVITATS PRESENCIALS

Activitat	Hores
Teoria	32,00
Pràctiques a l'aula	8,00
Laboratori	20,00
Total hores	60,00

ACTIVITATS NO PRESENCIALS

Activitat	Hores
Assistència a altres activitats	0,00
Elaboració de treballs individuals o en grup	20,00
Estudi i treball autònom	30,00
Preparació de classes	20,00
Preparació d'activitats d'avaluació	15,00
Resolució de casos pràctics	5,00
Total hores	90,00

METODOLOGIA DOCENT

En les activitats teòriques es desenrotllaran els temes exposant-los el professor utilitzant mitjans audiovisuals, proporcionant una visió global i integradora dels continguts. Es fomentarà la participació de l'estudiant en classe a través de preguntes durant l'exposició i la realització de qüestions simples per a



fixar els conceptes que es presenten. (CB3, CB4, CG2, CG3, CT03, CT05, CE03, CE13)

En les classe de resolució de problemes es resoldran preferentment per estudiants els problemes plantejats amb una setmana d'antelació , de tal manera que l'alumno/a tinga temps suficient per a treballar-ho a casa. S'incentivarà la discussió dels problemes en l'aula. (CB3, CB4, CG2, CG3, CT03, CT05, CE03, CE13)

En els laboratoris es plantejaran tasques de major complexitat i envergadura que les proposades en les activitats de l'aula. Es fomentarà el treball en grup, per parelles, de les pràctiques proposades. També l'alumno/a es familiaritzarà amb les llibreries de càlcul científic de Python així com amb ferramentes de presentació de codi com és Jupyter Notebook. (CB5, CT03, CT05, CE03, CE13)

AVALUACIÓ

Primera convocatòria:

Es realitzarà almenys una prova objectiva parcial durant el quadrimestre d'impartició del curs.

Es realitzarà un examen final en la primera convocatòria.

El valor de les proves parcials podrà arribar fins al 50% de la nota de teoria (SE1) .

La resta del percentatge se li assignarà a la prova final.

El percentatge sobre la nota final d'esta part (SE1) serà 50%. (CB5, CT03, CT05, CE03, CE13)

El valor de les pràctiques de laboratori (SE2) representarà un 35% de la nota total de l'assignatura (CB5, CT03, CT05, CE03, CE13)

El valor de l'avaluació contínua (SE3) representarà el 15% de la nota total (CB5, CT03, CT05, CE03, CE13)

És necessari traure una nota mínima de 4.5 en cada una de les parts anteriors (SE1, SE2, SE3) per a poder superar l'assignatura.

Segona convocatòria



La nota d'avaluació contínua (SE3), per ser activitats presencials, es considera no recuperable en la segona convocatòria. Encara que no s'imposa la restricció de la nota mínima de la primera convocatòria.

Per a la nota de pràctiques de laboratori, es plantejarà la defensa d'una pràctica o pràctiques resum dels continguts o bé es realitzarà un exam pràctic al terminar l'exam de teoria que suposarà el 100% de la nota (SE2) en segona convocatòria.

La restricció de nota mínima es manté per a la teoria.

La nota de teoria serà únicament la nota de l'examen final de segona convocatòria (sense considerar els parcials realitzats en el curs).

La nota final s'obtindrà com 50% SE1, 35% SE2, 15% SE3.

En qualsevol cas, el sistema d'avaluació es regirà pel que s'estableix en el Reglament d'Avaluació i Qualificació de la Universitat de València per a Graus i Màsters (<https://webges.uv.es/uvTaeWeb/MuestraInformacionEdictoPublicoFrontAction.do?accion=inicio&idEdictoSeleccionado=5639>)

La còpia o plagi manifest de qualsevol activitat que forma part de l'avaluació suposarà la impossibilitat de superar l'assignatura, sotmetent-se seguidament als procediments disciplinaris oportuns indicats en el **PROTOCOL D'ACTUACIÓ DAVANT PRÀCTIQUES FRAUDULENTES A LA UNIVERSITAT DE VALÈNCIA** ([ACGUV 123/2020](#))

BIBLIOGRAFIA

- Scikit-Learn Users Guide (Hay versión electrónica)
- Python Data science handbook. Jacob Vanderplas. O'Reilly. (2016)
- Introduction to Data Mining. Pang-Ning Tan, Michael Steinbach, Vipin Kumar. Pearson (2006)
- An introduction to Statistical Learning . Gureth James, Daniela Witten, Trevor Hastie, Robert Tibshirani. Springer (2013)



- Pattern Recognition. Sergios Theodoridis. AP (2009) Hay versió electrònica
- Data Mining. Concepts and Techniques. Jiawei Han, Micheline Kamber, Jian Pei. Morgan Kaufmann.(2012)