

Guia docent

295922 - FDLE - Fonaments del Deep Learning per a l'Enginyeria

Última modificació: 14/07/2026

Unitat responsable: Escola d'Enginyeria de Barcelona Est
Unitat que imparteix: 749 - MAT - Departament de Matemàtiques.

Titulació: GRAU EN ENGINYERIA BIOMÈDICA (Pla 2009). (Assignatura optativa).
GRAU EN ENGINYERIA DE L'ENERGIA (Pla 2009). (Assignatura optativa).
GRAU EN ENGINYERIA ELÈCTRICA (Pla 2009). (Assignatura optativa).
GRAU EN ENGINYERIA ELECTRÒNICA INDUSTRIAL I AUTOMÀTICA (Pla 2009). (Assignatura optativa).
GRAU EN ENGINYERIA MECÀNICA (Pla 2009). (Assignatura optativa).
GRAU EN ENGINYERIA QUÍMICA (Pla 2009). (Assignatura optativa).
GRAU EN ENGINYERIA DE MATERIALS (Pla 2010). (Assignatura optativa).

Curs: 2026 **Crèdits ECTS:** 6.0 **Idiomes:** Anglès

PROFESSORAT

Professorat responsable: Alférez Baquero, Edwin Santiago
Mujica Delgado, Luis Eduardo
Ruiz Ordoñez, Magda Liliana

Altres:

CAPACITATS PRÈVIES

Durant la formació de grau, els estudiants han adquirit competències bàsiques de programació i conceptes matemàtics fonamentals. En aquesta assignatura s'aplicarà la utilitat pràctica d'aquestes competències al camp de l'aprenentatge profund.

1. Python: coneixements bàsics de programació, incloent-hi variables, tipus de dades, instruccions, expressions, operadors i precedència. S'espera que l'estudiantat sigui capaç d'implementar algorismes senzills i gestionar estructures de dades.
2. Conceptes matemàtics: l'assignatura es basa en els fonaments de programació i anàlisi adquirits durant el grau i els aplica a problemes pràctics d'aprenentatge profund en enginyeria. Els conceptes matemàtics més rellevants inclouen:
 - Estadística: mesures estadístiques bàsiques (mitjana, mediana, desviació estàndard), probabilitat condicionada i contrast d'hipòtesis.
 - Càlcul: conceptes fonamentals de diferenciació i integració, especialment en relació amb problemes d'optimització en ciència de dades.
 - Àlgebra: àlgebra lineal bàsica, incloent-hi operacions amb matrius i espais vectorials, ja que són essencials per comprendre representacions de dades i models d'aprenentatge automàtic.

Tot i que una bona comprensió d'aquests conceptes matemàtics ajudarà a seguir els continguts, l'avaluació detallada d'aquestes competències específiques no formarà part central de l'avaluació de l'assignatura, que se centrarà en la síntesi i aplicació de models d'aprenentatge profund.

REQUISITS

Cap requisit formal. És imprescindible tenir interès per aprendre a analitzar dades, així com entusiasme i disposició per abordar conceptes de noves tecnologies aplicades a la resolució de problemes complexos.

METODOLOGIES DOCENTS

L'assignatura adopta un model d'aprenentatge integrat, en què els conceptes teòrics i l'aplicació pràctica s'entrellacen durant quatre hores setmanals. Cada sessió es realitza en un laboratori informàtic. Després de la introducció de cada concepte teòric, se n'explora immediatament la implementació pràctica mitjançant programació en Python, fomentant un entorn d'aprenentatge actiu. Al començament de cada classe es proporcionaran els materials de Python, de manera que el focus se situarà en l'aprenentatge i l'aplicació de nous conceptes.

A més, l'assignatura incorpora parcialment el model de classe inversa, assignant el 60% del recorregut d'aprenentatge al treball autònom. S'espera que l'estudiantat desenvolupi aprenentatge autodirigit, recerca independent i consolidació dels coneixements. Aquest component afavoreix un entorn centrat en l'aprenent, en què l'estudiant assumeix responsabilitat sobre el seu progrés i desenvolupa habilitats d'autoregulació, especialment rellevants en l'àmbit de la intel·ligència artificial i la ciència de dades.

La distribució orientativa dels pesos d'aprenentatge és:

- Coneixement teòric: 20%
- Tasques i projectes de laboratori informàtic: 20%
- Aprenentatge autònom: 60%

Com a marc d'avaluació, es desenvoluparan activitats i projectes orientats a fomentar la implicació continuada i l'aplicació dels conceptes, assegurant una experiència d'aprenentatge rigorosa i contextualitzada.

OBJECTIUS D'APRENTATGE DE L'ASSIGNATURA

- Adquirir una comprensió sòlida dels principis fonamentals de l'aprenentatge profund i de la representació no lineal, anant més enllà dels models lineals clàssics.
- Aprendre a formular i contextualitzar reptes complexos de dades en diferents entorns d'enginyeria i ciència, identificant quan les arquitectures profundes aporten un avantatge clar.
- Comprendre un conjunt d'algorismes per al processament de dades d'alta dimensionalitat, incloent-hi CNN, RNN i Transformers, així com els seus avantatges matemàtics i limitacions estructurals.
- Aplicar aquests coneixements a la resolució de problemes d'enginyeria de complexitat moderada, reforçant el domini de Python i dels entorns d'aprenentatge profund.
- Desenvolupar capacitat d'avaluació crítica dels resultats, especialment en la interpretació d'espais latents i de les dinàmiques d'optimització de xarxes profundes.
- Fomentar habilitats d'aprenentatge autònom per navegar en un camp d'IA en evolució ràpida i dominar noves arquitectures de manera independent.
- Promoure un entorn de treball col·laboratiu en què l'intercanvi d'idees i la participació constructiva en el disseny de models siguin valorats.
- Desenvolupar una mentalitat orientada a la recerca, amb capacitat per explorar literatura recent i sintetitzar informació de fonts tècniques diverses.
- Capacitar l'estudiantat per comparar críticament diverses tècniques neuronals i recomanar les més adequades segons l'estructura de les dades: espacials, seqüencials o generatives.

HORES TOTALES DE DEDICACIÓ DE L'ESTUDIANTAT

Tipus	Hores	Percentatge
Hores grup gran	30,0	50.00
Hores grup petit	30,0	50.00

Dedicació total: 60 h

CONTINGUTS

Introducció

Descripció:

Les sessions ofereixen una visió general del desenvolupament de la intel·ligència artificial i estableixen les bases per comprendre el paper del processament automàtic en l'anàlisi contemporània de dades i imatges. S'examinarà la importància de la generalització i el full de ruta de l'aprenentatge profund, juntament amb models fonamentals per a la representació i interpretació de dades en contextos d'enginyeria.

Objectius específics:

Familiaritzar-se amb els fonaments conceptuals de l'aprenentatge profund i la seva aplicació en diferents camps de l'enginyeria. Això inclou comprendre la importància de l'adquisició de dades, la transició de l'aprenentatge automàtic clàssic cap a arquitectures profundes, i una introducció als tipus d'algorismes i entorns de treball que es trobaran al llarg del curs.

Activitats vinculades:

Classes de teoria: presentació del curs i introducció al full de ruta de l'aprenentatge profund.

Sessions de laboratori: introducció a l'entorn de treball (Jupyter/Colab). Revisió de Python per a ciència de dades: Matplotlib, NumPy, Pandas i exploració inicial de dades mitjançant tensors de PyTorch.

Dedicació: 10h

Grup gran/Teoria: 2h

Grup petit/Laboratori: 2h

Aprenentatge autònom: 6h

Variables latents

Descripció:

Les sessions se centraran en el descobriment d'estructures ocultes dins de les dades mitjançant models de variables latents. Aquest mòdul va més enllà de les etiquetes supervisades per explorar com s'organitzen les dades en espais d'alta dimensionalitat. S'examinaran variables latents discretes mitjançant models de mescla i lògica d'agrupament, i variables latents contínues mitjançant l'estudi de la reducció de dimensionalitat i les varietats. Es posarà èmfasi en la comprensió dels fonaments matemàtics de la representació i en la transició de les projeccions clàssiques cap a la visualització no lineal de dades.

Objectius específics:

Proporcionar a l'estudiantat les habilitats necessàries per identificar, modelar i visualitzar estructures subjacents en conjunts de dades complexos. L'estudiantat aprendrà a interpretar espais latents com a prerrequisit per a l'aprenentatge profund, aplicant aquestes tècniques a conjunts de dades d'enginyeria i avaluant les implicacions de la reducció de dimensionalitat en l'anàlisi de dades d'alta dimensionalitat.

Activitats vinculades:

Classes de teoria i sessions de laboratori: variables latents discretes i contínues; models de mescla, varietats i projeccions.

Implementació d'algorismes d'agrupament i tècniques de reducció de dimensionalitat. Visualització d'espais latents per comprendre la topologia de les dades mitjançant Python.

Dedicació: 10h

Grup gran/Teoria: 2h

Grup petit/Laboratori: 2h

Aprenentatge autònom: 6h

Fonaments neuronals i retropropagació

Descripció:

Aquesta unitat estableix la transició dels models lineals a les arquitectures neuronals. Les sessions cobriran xarxes d'una sola capa tant per a regressió com per a classificació, examinant models de funcions base lineals i fronteres de decisió per a classes discretes. Posteriorment, el mòdul introdueix el perceptró multicapa (MLP) com a aproximador universal, centrant-se en la formalització matemàtica de la retropropagació de l'error. S'analitzarà la regla de la cadena per a l'estimació del gradient, el paper de les funcions d'activació i la importància de les aplicacions no lineals en espais d'alta dimensionalitat.

Objectius específics:

Proporcionar una base matemàtica sobre com flueix la informació a través d'una xarxa. L'estudiantat aprendrà a distingir entre les capacitats d'una sola capa i de múltiples capes, implementant l'algorisme de retropropagació per comprendre com els gradients actualitzen els paràmetres del model durant el procés d'aprenentatge.

Activitats vinculades:

Models d'una sola capa per a regressió i classificació. Arquitectures multicapa i algorisme de retropropagació. Anàlisi comparativa de fronteres de decisió lineals i no lineals. Implementació d'una xarxa neuronal bàsica i verificació manual del flux de gradients.

Dedicació: 20h

Grup gran/Teoria: 4h

Grup petit/Laboratori: 4h

Aprenentatge autònom: 12h

Regularització i optimització

Descripció:

Les sessions se centraran en el doble repte de garantir la generalització del model i aconseguir una convergència eficient en espais d'alta dimensionalitat. S'examinaran tècniques de regularització dissenyades per mitigar el sobreajust i gestionar la complexitat del model, com ara Dropout, Weight Decay (L1/L2) i el paper crític de les capes de normalització (Batch Norm i Layer Norm). Posteriorment, la unitat cobreix la dinàmica d'optimització, analitzant l'evolució des del descens del gradient estocàstic (SGD) i Momentum fins a algorismes de taxa d'aprenentatge adaptativa com RMSProp i Adam.

Objectius específics:

Dotar l'estudiantat de les habilitats diagnòstiques i tècniques per estabilitzar el procés d'entrenament d'arquitectures profundes. En finalitzar aquesta unitat, l'estudiantat hauria de ser capaç d'identificar les causes matemàtiques de fallades comunes d'entrenament, com ara gradients que s'esvaeixen o exploten, i seleccionar estratègicament les eines de regularització i optimització adequades per a diversos problemes d'enginyeria.

Activitats vinculades:

Classes de teoria i sessions de laboratori: estratègies de generalització i regularització. Paisatges d'optimització i mètodes de taxa d'aprenentatge adaptativa. Experimentació comparativa amb diferents optimitzadors i tècniques de regularització. Ajust d'hiperparàmetres i seguiment de la dinàmica d'entrenament mitjançant eines de visualització.

Dedicació: 30h

Grup gran/Teoria: 6h

Grup petit/Laboratori: 6h

Aprenentatge autònom: 18h

Visió per computador: xarxes neuronals convolucionals (CNN)

Descripció:

Les sessions se centraran en arquitectures dissenyades específicament per processar dades amb una topologia de graella, com ara imatges. S'estudiarà la transició de connexions denses a capes convolucionals, examinant els principis de connectivitat local i compartició de paràmetres. El mòdul explora com aquestes xarxes aconseguen invariància i equivariància a translacions, el paper dels mecanismes de pooling i el disseny d'arquitectures modernes de visió profunda.

Objectius específics:

Proporcionar a l'estudiantat la capacitat de dissenyar i implementar models per a l'anàlisi automàtica d'imatges. L'estudiantat comprendrà la lògica matemàtica de les operacions convolucionals i aprendrà a aplicar aquestes tècniques a tasques de classificació i extracció de característiques en contextos d'enginyeria.

Activitats vinculades:

Classes de teoria i sessions de laboratori: fonaments de les xarxes neuronals convolucionals. Patrons arquitectònics: filtres, strides, padding i pooling. Implementació d'una CNN per al reconeixement d'imatges. Comparació entre MLP tradicionals i CNN en tasques de visió. Introducció al transfer learning.

Dedicació: 20h

Grup gran/Teoria: 4h

Grup petit/Laboratori: 4h

Aprenentatge autònom: 12h

Fonaments estocàstics i mostreig bàsic

Descripció:

Aquesta unitat introdueix els mecanismes estocàstics necessaris per extreure mostres de distribucions apreses. Les sessions se centren en mostreig ancestral, mostreig per rebuig i mostreig d'importància. S'examinarà com aquestes tècniques permeten passar d'un espai latent determinista a un procés generatiu.

Objectius específics:

Comprendre la mecànica matemàtica de la generació de dades. L'estudiantat aprendrà a extreure informació de distribucions complexes, proporcionant les eines necessàries per implementar i avaluar arquitectures generatives.

Activitats vinculades:

Classes de teoria i sessions de laboratori: principis de mostreig ancestral, per rebuig i d'importància. Implementació pràctica d'algorismes de mostreig per visualitzar la cobertura de distribucions.

Dedicació: 10h

Grup gran/Teoria: 2h

Grup petit/Laboratori: 2h

Aprenentatge autònom: 6h

Modelatge de seqüències

Descripció:

Les sessions exploraran com les xarxes neuronals processen dades seqüencials i temporals. Es començarà amb xarxes neuronals recurrents (RNN) i les seves versions evolucionades, com les LSTM, dissenyades per capturar dependències de llarg termini. La unitat introduirà després el modelatge seqüència-a-seqüència i discutirà les limitacions del processament estrictament recurrent, preparant l'estudiantat per a l'estudi posterior d'arquitectures basades en atenció.

Objectius específics:

Capacitar l'estudiantat per tractar dades amb estructura temporal o seqüencial. En finalitzar aquesta unitat, l'estudiantat serà capaç d'implementar models recurrents i seqüència-a-seqüència, comprendre els seus punts forts i limitacions, i identificar per què els mecanismes d'atenció són necessaris per a un processament de seqüències més escalable.

Activitats vinculades:

Classes de teoria i sessions de laboratori: fonaments de xarxes recurrents i LSTM. Models seqüència-a-seqüència i processament de dades temporals. Implementació de models recurrents en Python i anàlisi del seu comportament en dades seqüencials d'enginyeria.

Dedicació: 20h

Grup gran/Teoria: 4h

Grup petit/Laboratori: 4h

Aprenentatge autònom: 12h

Atenció i Transformers

Descripció:

La unitat final se centra en arquitectures basades en atenció, amb èmfasi en el model Transformer. Les sessions cobreixen self-attention, multi-head attention, codificació posicional i blocs Transformer, connectant aquests conceptes amb els grans models de llenguatge moderns (LLM) i altres aplicacions d'enginyeria amb dades d'alta dimensionalitat.

Objectius específics:

Dominar els mecanismes centrals de les arquitectures Transformer. L'estudiantat serà capaç d'implementar mecanismes d'atenció i blocs Transformer bàsics, interpretar mapes d'atenció i comprendre per què els Transformers s'han convertit en una eina estàndard per processar dades seqüencials i no seqüencials d'alta dimensionalitat.

Activitats vinculades:

Classes de teoria i sessions de laboratori: mecanismes d'atenció, self-attention i arquitectura Transformer completa.

Implementació d'un bloc basat en Transformer. Experiència pràctica amb mapes d'atenció i anàlisi del comportament del model.

Dedicació: 30h

Grup gran/Teoria: 6h

Grup petit/Laboratori: 6h

Aprenentatge autònom: 18h

SISTEMA DE QUALIFICACIÓ

L'assignatura es basa en un sistema d'avaluació orientat a projectes, que garanteix la implicació continuada i l'aplicació pràctica dels conceptes d'aprenentatge profund mitjançant dues fites principals i verificacions periòdiques. Sis proves conceptuais breus al llarg del semestre representaran el 20% de la qualificació. El 80% restant es dividirà en dos projectes integradors: el primer cobreix les unitats 1 a 4 i culmina amb la presentació d'un pòster científic; el segon cobreix les unitats 5 a 8 i requereix una implementació tècnica i una defensa oral.

NORMES PER A LA REALITZACIÓ DE LES PROVES.

L'avaluació es realitzarà mitjançant dos grans projectes col·laboratius i una sèrie de proves conceptuals individuals. Per als projectes, els participants formaran grups de dos o tres estudiants. La composició dels grups podrà canviar entre el primer i el segon projecte. Els projectes són col·laboratius, mentre que les proves conceptuals són individuals, per garantir que cada estudiant domini els principis matemàtics fonamentals de l'assignatura.

BIBLIOGRAFIA

Bàsica:

- Bishop, Christopher M; Bishop, Hugh. Deep learning : foundations and concepts. Cham: Springer, [2024]. ISBN 9783031454677.
- James, Gareth. An Introduction to statistical learning : with applications in R [en línia]. New York: Springer, 2013 [Consulta: 29/07/2026]. Disponible a: <https://link-springer-com.recursos.biblioteca.upc.edu/book/10.1007/978-1-4614-7138-7>. ISBN 9781461471370.
- Raschka, Sebastian; Liu, Yuxi (Hayden); Mirjalili, Vahid; Dzhuigakov, Dmytro. Machine learning with PyTorch and Scikit-Learn. Second edition. Packt Publishing, 2022. ISBN 9781801816380.
- Géron, Aurélien. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow : concepts, tools, and techniques to build intelligent systems. Second edition. Sebastopol, CA: O'Reilly Media, Inc, 2019. ISBN 9781492032649.

Complementària:

- Hastie, Trevor; Tibshirani, Robert; Friedman, Jerome. The Elements of statistical learning : data mining, inference, and prediction. 2nd ed. New York [etc.]: Springer, cop. 2009. ISBN 0387952845.
- Goodfellow, Ian; Bengio, Yoshua; Courville, Aaron. Deep learning. Cambridge, MassachusettsThe MIT Press: The MIT Press, 2016. ISBN 9780262035613.