

Guia docent

250COD008 - 250COD008 - Optimització

Última modificació: 20/07/2026

Unitat responsable: Escola Tècnica Superior d'Enginyeria de Camins, Canals i Ports de Barcelona

Unitat que imparteix: 751 - DECA - Departament d'Enginyeria Civil i Ambiental.

Titulació: MÀSTER UNIVERSITARI EN ENGINYERIA COMPUTACIONAL I ASSISTIDA PER DADES (Pla 2026).
(Assignatura obligatòria).

Curs: 2026

Crèdits ECTS: 5.0

Idiomes: Anglès

PROFESSORAT

Professorat responsable: Rossi Bernecoli, Riccardo

Altres: Sibuet Ruiz, Nicolás
Zorrilla Martínez, Rubén

CAPACITATS PRÈVIES

master level in mathematics, basic knowledge of programming

METODOLOGIES DOCENTS

Totes les classes inclouran tant material teòric com exercicis pràctics —fets amb ordinador— que els estudiants resoldran de manera interactiva.

OBJECTIUS D'APRENTATGE DE L'ASSIGNATURA

Ensenyar els fonaments de l'optimització matemàtica, especialment amb vista a la seva aplicació a problemes d'enginyeria i mètodes numèrics. Així mateix, el curs impartirà les matemàtiques fonamentals que constitueixen la base de l'aprenentatge automàtic (Machine Learning) modern.

HORES TOTALES DE DEDICACIÓ DE L'ESTUDIANTAT

Tipus	Hores	Percentatge
Hores grup gran	45,0	36.00
Hores aprenentatge autònom	80,0	64.00

Dedicació total: 125 h

CONTINGUTS

Curs de Optimizació

Descripció:

Part I — Optimization Foundations

Lecture 1 — Optimization Problems and Mathematical Preliminaries

Theory

Examples of applications (shape and topology optimization, sizing, etc)

Structure of optimization problems

Objective functions and constraints
Norms and inner products
Gradients and Hessians
Quadratic approximations
Convex vs non-convex problems
Practice
Visualizing objective landscapes
Numerical gradients and Hessians in NumPy

Lecture 2 — Linear Programming
Theory
Linear programs in standard form
Geometry of polyhedra
Extreme points and optimality
Fundamental theorem of LP
Simplex algorithm (conceptual overview)
Interior-point idea
Practice
Modeling LP problems
Solving LPs with `scipy.optimize.linprog`

Lecture 3 — Quadratic Programming
Theory
Quadratic forms
Positive definite matrices
Convex quadratic programs
KKT system for equality constraints
Active-set intuition
Practice
Portfolio optimization with CVXPY

Lecture 4 — Applications in Computational Mechanics
Practice – Application to model problems

Part II — Convex Optimization
Lecture 5 — Convex Sets and Convex Functions
Theory
Convex sets
Convex hull and epigraph
Convex functions
First-order convexity condition
Jensen's inequality
Examples from machine learning losses
Practice
Verifying convexity analytically and numerically

Lecture 6 — Lagrangian Duality and KKT Conditions
Theory
General constrained optimization
Lagrangian formulation
Dual function
Karush–Kuhn–Tucker conditions
Optimality interpretation
Practice
Solving nonlinear constrained problems

Lecture 7 — Duality and Sensitivity Analysis
Theory
Lagrangian of linear programs
Dual problem

Weak and strong duality
Complementary slackness
Interpretation of dual variables
Practice
Solving primal and dual LPs in Python
Verifying complementary slackness

Lecture 8 — Applications in Computational Mechanics
Practice
Practical applications hands-on

Part III — Gradient-Based Optimization

Lecture 9 — Gradient Descent

Theory
Steepest descent
Lipschitz gradients
Convergence guarantees
Step size selection
Conditioning
Practice
Implementing gradient descent
Convergence experiments

Lecture 11 — Newton and Quasi-Newton Methods + (Brief intro to) Krylov Methods

Theory
Newton's method
Quadratic convergence
Hessian approximation
BFGS and quasi-Newton methods
Linear systems in optimization
Krylov subspaces
Conjugate gradient method
GMRES algorithm
Preconditioning
Practice
Comparing Newton vs gradient descent

Part V — Optimization in Machine Learning

Lecture 12 — Stochastic Gradient Methods

Theory
Stochastic gradient descent
Mini-batch optimization
Variance of stochastic gradients
Learning rate schedules
Momentum methods
Adaptive Algorithms (Adam, Adagrad)
Limitations of adaptive optimizers
Practice
Training a neural network using SGD

Lecture 13 — Non-Convex Optimization in Deep Learning

Theory
Landscape of neural network loss functions
Saddle points and flat minima
Overparameterization
Practical training heuristics
Practice



Training a small network and analyzing optimization behavior

Objectius específics:

L'objectiu específic del curs és permetre als estudiants

entendre la terminologia utilitzada en l'optimització matemàtica

formular un problema donat en una forma adequada per emprar tècniques d'optimització matemàtica

comprendre les característiques del problema per triar la tècnica d'optimització "més adequada"

Activitats vinculades:

El curs proposarà diversos "problemes de joguina" de complexitat creixent, per verificar com es comporten les diferents tècniques a l'hora de trobar solucions "òptimes".

Alguns d'aquests problemes es resoldran de manera interactiva a classe, mentre que altres s'assignaran com a tasques i formaran part de l'avaluació final.

Dedicació: 45h

Grup gran/Teoria: 45h

SISTEMA DE QUALIFICACIÓ

50% tasques

50% teoria

NORMES PER A LA REALITZACIÓ DE LES PROVES.

Les tasques s'assignaran durant les sessions del grup amb una data límit associada. Els estudiants hauran de resoldre-les (individualment o en grup) i preparar una presentació del treball realitzat, que serà avaluada en un examen oral.

BIBLIOGRAFIA

Bàsica:

- Stephen P. Boyd . Convex Optimization [en línia]. online. Cambridge University Press, 2004 Disponible a: https://web.stanford.edu/~boyd/cvxbook/bv_cvxbook.pdf.

RECURSOS

Altres recursos:

<https://web.stanford.edu/~boyd/cvxbook/>