

Guía docente

250COD008 - 250COD008 - Optimización

Última modificación: 20/07/2026

Unidad responsable: Escuela Técnica Superior de Ingeniería de Caminos, Canales y Puertos de Barcelona
Unidad que imparte: 751 - DECA - Departamento de Ingeniería Civil y Ambiental.

Titulación: MÁSTER UNIVERSITARIO EN INGENIERÍA COMPUTACIONAL Y ASISTIDA POR DATOS (Plan 2026).
(Asignatura obligatoria).

Curso: 2026 **Créditos ECTS:** 5.0 **Idiomas:** Inglés

PROFESORADO

Profesorado responsable: Rossi Bernecoli, Riccardo

Otros: Sibuet Ruiz, Nicolás
Zorrilla Martínez, Rubén

CAPACIDADES PREVIAS

master level in mathematics, basic knowledge of programming

METODOLOGÍAS DOCENTES

Todas las clases incluirán tanto material teórico como ejercicios prácticos —realizados en ordenador— que los estudiantes resolverán de manera interactiva.

OBJETIVOS DE APRENDIZAJE DE LA ASIGNATURA

Enseñar los fundamentos de la optimización matemática, especialmente orientados a su aplicación en problemas de ingeniería y métodos numéricos. Asimismo, el curso impartirá las matemáticas fundamentales que constituyen la base del aprendizaje automático (Machine Learning) moderno.

HORAS TOTALES DE DEDICACIÓN DEL ESTUDIANTE

Tipo	Horas	Porcentaje
Horas grupo grande	45,0	36.00
Horas aprendizaje autónomo	80,0	64.00

Dedicación total: 125 h

CONTENIDOS

Curso de Optimización

Descripción:

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

Objetivos específicos:

El objetivo específico del curso es permitir a los estudiantes

entender la terminología utilizada en la optimización matemática

formular un problema dado en una forma adecuada para emplear técnicas de optimización matemática

Actividades vinculadas:

El curso propondrá varios "problemas de juguete" de complejidad creciente, para verificar cómo se comportan las diferentes técnicas al encontrar soluciones "óptimas".

Algunos de estos problemas se resolverán de manera interactiva en clase, mientras que otros se asignarán como tareas y formarán parte de la evaluación final.

Dedicación: 45h

Grupo grande/Teoría: 45h

SISTEMA DE CALIFICACIÓN

50% tareas

50% teoría

NORMAS PARA LA REALIZACIÓN DE LAS PRUEBAS.

Las tareas se asignarán durante las sesiones del grupo con una fecha límite asociada. Los estudiantes deberán resolverlas (individualmente o en grupo) y preparar una presentación del trabajo realizado, que será evaluada en un examen oral.

BIBLIOGRAFÍA

Básica:

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

RECURSOS

Otros recursos:

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