

PLANIFICACIÓN DE CURSO

Primer Semestre académico 2025

**I. ACTIVIDAD CURRICULAR Y CARGA HORARIA**

Asignatura: Introducción a la Inteligencia artificial	Código: COM4402
Semestre de la Carrera: 8	
Carrera: Ingeniería en computación	
Escuela: Escuela de Ingeniería	
Docente(s): Gabriel Cabas	
Ayudante(s):	
Horario: Cátedras: Miercoles-Viernes: 8:30-10:00	

<b>Créditos SCT:</b>	<b>6</b>
<b>Carga horaria semestral</b>	<b>180 horas</b>
<b>Carga horaria semanal</b>	<b>10.6 horas</b>

<b>Tiempo de trabajo directo semanal</b>	<b>3 horas</b>
<b>Tiempo de trabajo del estudiante semanal</b>	<b>7.6 horas</b>

**II. RESULTADOS U OBJETIVOS DE APRENDIZAJE ESPERADOS ESTE SEMESTRE**

1)	Comprender los fundamentos matemáticos y computacionales del machine learning.
2)	Conocer las diferencias fundamentales entre los distintos tipos de aprendizaje y algoritmos.
3)	Plantear, desarrollar y evaluar un proyecto de inteligencia artificial.
4)	Conocer prácticas de MLOPs y aplicarlas en el despliegue de modelos a producción.

<sup>1</sup> Considere que 1 crédito SCT equivale a 30 horas de trabajo total (presencial/sincrónico y autónomo/asincrónico) en el semestre.

### III. UNIDADES, CONTENIDOS Y ACTIVIDADES

UNIDAD 1: Fundamentos, modelos lineales y reducción de dimensionalidad					
Semana	Contenidos	Actividades de enseñanza y aprendizaje			Actividades de evaluación
		Cátedra expositiva	Práctica	Trabajo autónomo	
1	Presentación del curso Fundamentos	2:30 horas	30 min	7.6 horas	Prueba escrita
2	Modelos lineales para regresión				
3	Modelos lineales para clasificación				
4	Reducción de dimensionalidad				

UNIDAD 2: Aprendizaje supervisado y no supervisado					
Semana	Contenidos	Actividades de enseñanza y aprendizaje			Actividades de evaluación
		Cátedra expositiva	Práctica	Trabajo autónomo	
5	K-means Agglomerative Clustering	2:30 horas	30 min	7.6 horas	Prueba escrita
6	Gaussian Mixture DBSCAN				
7	Naive Bayes K-Nearest Neighbors				
8	Decision Trees Bagging y Random Forest				
9	Support Vector Machines Multi Layer Perceptron				

UNIDAD 3: Deep Learning y MLOPs					
Semana	Contenidos	Actividades de enseñanza y aprendizaje			Actividades de evaluación
		Cátedra expositiva	Práctica	Trabajo autónomo	
10	Introducción a Deep Learning Introducción a Pytorch/Tensorflow	2:30 horas	30 min	7.6 horas	Prueba escrita
11	Fundamentos matemáticos de las redes neuronales artificiales				
12	Convolucional Neural Networks				
13	Generative Deep Learning Variational Autoencoders				
14	Modelos preentrenados MLOPs y conclusión del curso				

#### **IV. CONDICIONES Y POLÍTICAS DE EVALUACIÓN**

##### **DISPOSICIONES GENERALES Y PONDERACIONES**

La nota final del curso (NF) está compuesta por 3 unidades (Ni) y un proyecto grupal a desarrollar durante el semestre (NP) de forma asincrónica y aprovechando horarios de ayudantía.

$$NF = 0.25 N1 + 0.25 N2 + 0.25 N3 + 0.25 NP$$

Es requisito de aprobación el tener nota  $\geq$  a 4.0 en cada una de las unidades y el proyecto por separado.

##### **SOBRE EVALUACIONES Y PROYECTO**

Cualquier tipo de plagio o copia resultará en nota 1.0 en la evaluación correspondiente. Además, será reportado mediante informe a la Escuela de Ingeniería, y podrá derivar en sumario. En caso de sospecha de uso no solicitado de inteligencia artificial (chatgpt, deepseek, etc) en las evaluaciones, es posible realizar interrogaciones privadas en cualquier momento del semestre. En caso positivo, se seguirá el conducto anteriormente señalado.

##### **SOBRE EL EXAMEN RECUPERATIVO**

Si el estudiante no cumple en primera instancia con alguno de los criterios de aprobación, y el criterio de reprobación se encuentra entre 3.7 y 3.9, podrá optar a un examen recuperativo. En caso de aprobar dicha evaluación, la nota final del curso será 4.0.

#### **V. BIBLIOGRAFÍA Y RECURSOS OBLIGATORIOS**

- Practical Statistics for data scientists, Andrew Bruce
- Machine Learning and Pattern Recognition, Christopher Bishop
- Deep Learning with Python, Francois Chollet
- Generative Deep Learning, David Foster

#### **VI. BIBLIOGRAFÍA Y RECURSOS COMPLEMENTARIOS**

- Mathematics for Machine Learning, Aldo Faisal
- Deep Learning, Ian Goodfellow
- Introducing MLOPs, Mark Treveil