Universidad Nacional de Ingeniería (UNI)
Escuela Profesional de
Ciencia de la Computación
Sílabo 2027-I

1. CURSO

AI261. Probabilidad y Estadistica para IA (Electivo)

2. INFORMACIÓN GENERAL

2.1 Curso	:	AI261. Probabilidad y Estadistica para IA
2.2 Ciclo	:	CS300 Ciclo.
2.3 Créditos	:	4
2.4 Horas	:	2 HT; 4 HP;
2.5 Duración del periodo	:	16 semanas
2.6 Condición	:	Electivo
2.7 Modalidad de aprendizaje	:	Presencial
2.8 Prerrequisitos	:	▪ BMA102. Cálculo Diferencial. (1er Sem) ▪ BMA101. Algebra Lineal. (1er Sem) ▪ STA251. Estadística y Probabilidades. (2do Sem)

3. PROFESORES

Atención previa coordinación con el profesor

4. INTRODUCCIÓN AL CURSO

Este curso proporciona las bases probabilísticas y estadísticas esenciales para el desarrollo de sistemas de Inteligencia Artificial. Cubre distribuciones clave, inferencia bayesiana y métodos estadísticos aplicados directamente a problemas de aprendizaje automático, visión por computadora y procesamiento de lenguaje natural.

5. OBJETIVOS

- Comprender las distribuciones de probabilidad fundamentales en modelos de IA.
- Aplicar métodos de inferencia estadística en el entrenamiento de modelos.
- Implementar soluciones probabilísticas usando bibliotecas modernas (NumPy, SciPy).

6. RESULTADOS DEL ESTUDIANTE

AG-C07) Conocimientos de Computación: Aplica conocimientos de matemáticas, ciencias y computación. (Usage)

7. TEMAS

Unidad 1: Fundamentos Probabilísticos (15 horas)	
Resultados esperados: AG-C07	
Temas	**Aprendizaje esperado (*Learning Outcomes*)**
▪ Espacios de probabilidad y variables aleatorias ▪ Distribuciones clave: Normal, Poisson, Binomial, Multinomial ▪ Teorema de Bayes y aplicaciones en IA	▪ Calcular probabilidades en modelos discretos/continuos [Usar] ▪ Explicar el rol de distribuciones en algoritmos de ML [Familiarizarse]
Lecturas : [Bis06], [Mur12]	

Unidad 2: Estadística para IA (15 horas)	
Resultados esperados: AG-C07	
Temas	**Aprendizaje esperado (*Learning Outcomes*)**
▪ Estimación de parámetros (MLE, MAP) ▪ Intervalos de confianza y pruebas de hipótesis ▪ Análisis de correlación y regresión lineal	▪ Implementar MLE/MAP en Python [Usar] ▪ Evaluar significancia estadística en resultados de modelos [Evaluar]
Lecturas : [DS14], [Was04]	

Unidad 3: Cadenas de Markov y Procesos Estocásticos (15 horas)	
Resultados esperados: AG-C07	
Temas	**Aprendizaje esperado (*Learning Outcomes*)**
▪ Procesos de Markov ocultos (HMMs) ▪ Cadenas de Markov Monte Carlo (MCMC) ▪ Aplicaciones en NLP y visión computacional	▪ Simular procesos estocásticos básicos [Usar] ▪ Relacionar teoría con arquitecturas de redes neuronales [Familiarizarse]
Lecturas : [Ros19], [Bis06]	

Unidad 4: Herramientas Computacionales (15 horas)	
Resultados esperados: AG-C07	
Temas	**Aprendizaje esperado (*Learning Outcomes*)**
▪ NumPy para operaciones probabilísticas ▪ SciPy para tests estadísticos ▪ Visualización con Matplotlib/Seaborn	▪ Programar simulaciones probabilísticas [Usar] ▪ Generar visualizaciones estadísticas [Evaluar]
Lecturas : [Van16], [McK22]	

8. PLAN DE TRABAJO

8.1 Metodología

Se fomenta la participación individual y en equipo para exponer sus ideas, motivándolos con puntos adicionales en las diferentes etapas de la evaluación del curso.

8.2 Sesiones Teóricas

Las sesiones de teoría se llevan a cabo en clases magistrales donde se realizarán actividades que propicien un aprendizaje activo, con dinámicas que permitan a los estudiantes interiorizar los conceptos.

8.3 Sesiones Prácticas

Las sesiones prácticas se llevan en clase donde se desarrollan una serie de ejercicios y/o conceptos prácticos mediante planteamiento de problemas, la resolución de problemas, ejercicios puntuales y/o en contextos aplicativos.

9. SISTEMA DE EVALUACIÓN

Sesiones Teóricas:
Las sesiones de teoría se llevan a cabo en clases magistrales donde se realizarán actividades que propicien un aprendizaje activo, con dinámicas que permitan a los estudiantes interiorizar los conceptos.

Sesiones de Laboratorio:
Para verificar que los alumnos hayan alcanzado el logro planteado para cada una de las unidades de aprendizaje, realizarán actividades que les permita aplicar los conocimientos adquiridos durante las sesiones de teoría y se les propondrá retos que permitan evaluar el desempeño de los alumnos.

Exposiciones individuales o grupales:
Se fomenta la participación individual y en equipo para exponer sus ideas, motivándolos con puntos adicionales en las diferentes etapas de la evaluación del curso.

Lecturas:
A lo largo del curso se proporcionan diferentes lecturas, las cuales podrían ser evaluadas. El uso de herramientas Online

permite a cada estudiante acceder a la información del curso, e interactuar fuera de aula con el profesor y con los otros estudiantes.

La nota final NF depende de de las siguientes notas:

- EP: Examen Parcial.
- EF: Examen Final.
- P: Evaluacion permanente (Promedio de prácticas y Trabajos calificados).

La nota final NF se calcula así:

$$NF = \frac{EP + EF + P}{3}$$

10. BIBLIOGRAFÍA BÁSICA

[Was04] Larry Wasserman. *All of Statistics: A Concise Course in Statistical Inference*. Aunque es de 2004, sigue siendo referencia estándar. Springer, 2004.

[Bis06] Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.

[Mur12] Kevin P. Murphy. *Machine Learning: A Probabilistic Perspective*. MIT Press, 2012.

[DS14] Morris H. DeGroot y Mark J. Schervish. *Probability and Statistics*. 4th. Pearson, 2014.

[Van16] Jake VanderPlas. *Python Data Science Handbook*. O'Reilly, 2016.

[Ros19] Sheldon M. Ross. *Introduction to Probability Models*. 12th. Academic Press, 2019.

[McK22] Wes McKinney. *Python for Data Analysis*. 3rd. O'Reilly, 2022.