

Codigo de asignatura: 4787B4

Nombre del programa académico	Maestría en Ingeniería Eléctrica		
Nombre completo de la asignatura	Inteligencia Artificial para Ingeniería		
Número de créditos ECTS por categoría	Ciencias naturales y matemáticas	Módulos profesionales y especiales	Humanidades y ciencias sociales y económicas
	3	3	1
Semestre y año de actualización	2026-1		
Semestre y año en que se imparte	2026-1		
Tipo de asignatura	[] Obligatoria [X] Electiva		
Director o contacto del programa	Andrés Escobar Mejía		
Coordinador o contacto de la asignatura	Germán Andrés Holguín Londoño		

Descripción y contenidos**1. Breve descripción**

Esta asignatura introduce a los estudiantes en la Inteligencia Artificial (IA) moderna desde una perspectiva probabilística y aplicada a la ingeniería. A lo largo del curso, los participantes desarrollarán competencias teóricas y prácticas para comprender cómo las máquinas aprenden a partir de datos, cómo se construyen modelos predictivos y cómo se toman decisiones bajo incertidumbre. El curso combina fundamentos matemáticos del aprendizaje de máquina, inferencia estadística y modelos de IA con programación en Python y experimentación práctica, permitiendo a los estudiantes implementar algoritmos, analizar datos reales y desarrollar soluciones a problemas de ingeniería. Un énfasis especial se pone en la lectura crítica e interpretación de artículos científicos del estado del arte, preparando a los estudiantes para interactuar con literatura académica y tecnologías emergentes en inteligencia artificial. Al finalizar la asignatura, los estudiantes no solo sabrán usar técnicas de IA, sino también entenderlas, explicarlas y evaluarlas, adquiriendo una base sólida para proyectos avanzados, investigación aplicada o estudios de posgrado.

2. Objetivo del curso:

Formar en el estudiante una comprensión profunda de los fundamentos probabilísticos y computacionales del aprendizaje de máquina, desarrollando competencias para diseñar, implementar y analizar modelos de inteligencia artificial aplicados a problemas de ingeniería, así como para interpretar críticamente investigaciones académicas en el área.

3. Resultados de aprendizaje. Los propósitos de formación en el estudiante de posgrado son:

Al finalizar el curso, el estudiante será capaz de:

- RAA-1: Explicar los principios teóricos que sustentan los métodos de aprendizaje de máquina probabilístico. Se corresponde con los RAP: RAP8, RAP11, RAP13.
- RAA-2: Implementar modelos de aprendizaje supervisado y no supervisado utilizando herramientas computacionales. Se corresponde con los RAP: RAP3, RAP7, RAP8.
- RAA-3: Evaluar y comparar modelos de IA mediante técnicas de validación y análisis de desempeño. Se corresponde con los RAP: RAP8, RAP10, RAP11.
- RAA-4: Formular soluciones de ingeniería apoyadas en modelos de IA, seleccionando metodologías apropiadas. Se corresponde con los RAP: RAP2, RAP3, RAP8, RAP9.
- RAA-5: Analizar y comunicar resultados de investigaciones y artículos científicos en el campo de la IA. Se corresponde con los RAP: RAP10, RAP11, RAP12, RAP13.
- RAA-6: Trabajar colaborativamente en proyectos de desarrollo de modelos inteligentes aplicados. Se corresponde con los RAP: RAP7, RAP9, RAP10.

4. Contenido

- T-1. Introducción a la Inteligencia Artificial: Historia, motivaciones, campos de aplicación, IA simbólica vs estadística, noción de agente inteligente.
- T-2. Bases del aprendizaje I: Aprendizaje supervisado y no supervisado, datos, funciones de pérdida, riesgo empírico, noción de generalización.
- T-3. Bases del aprendizaje II: Modelos paramétricos vs no paramétricos, regularización, optimización, gradiente descendente.
- T-4. Aprendiendo de los datos: MLE y MAP Inferencia estadística, estimación puntual, máxima verosimilitud, estimación bayesiana y prior gaussiano.
- T-5. Generalización y Validación cruzada: Partición de datos, sesgo y varianza, métodos de validación (holdout, k-fold, leave-one-out), métricas de desempeño.
- T-6. Regresión logística: Clasificación binaria y multiclase, función sigmoide y softmax, interpretación probabilística, evaluación.
- T-7. Métodos no paramétricos de clasificación: k-NN, árboles de decisión, bosques aleatorios, ventajas y limitaciones.
- T-8. Métodos de Kernel y SVM: Máquinas de soporte vectorial, márgenes máximos, kernels lineales y no lineales, regresión con SVM.
- T-9. Aprendizaje no supervisado y reducción de dimensionalidad: k-Means, modelos de mezcla gaussiana (MoG), PCA, autoencoders.
- T-10. Redes neuronales clásicas: Perceptrón, redes multicapa, retropropagación, activaciones y regularización.
- T-11. Redes neuronales profundas: Arquitecturas convolucionales y recurrentes, aprendizaje profundo, optimización, overfitting.
- T-12. Modelos generativos y transformadores: GAN, autoencoders variacionales, modelos de difusión, transformers y atención.
- T-13. Tendencias y proyectos en IA moderna: Modelos fundacionales y LLMs, ética y responsabilidad en IA, presentación de proyectos finales.

5. Requisitos. Los definidos en requisito de admisión de la IES.

6. Recursos

Hamientas informáticas:

- Python, PyCharm, VScode. Todas herramientas de software libre.

Bibliografía

- [1] Bishop, C. M. Pattern Recognition and Machine Learning. Springer, 2006.
- [2] Murphy, K. P. Probabilistic Machine Learning: An Introduction. MIT Press, 2012.
- [3] Murphy, K. P. Probabilistic Machine Learning: Advanced Topics. MIT Press, 2012.
- [4] Goodfellow, I., Bengio, Y., & Courville, A. Deep Learning. MIT Press, 2016.
- [5] Géron, A. Hands-on Machine Learning with Scikit-Learn, Keras & TensorFlow. 2nd Edition. O'Reilly, 2019.

7. Herramientas técnicas de soporte para la enseñanza

- Lenguaje Python con bibliotecas: NumPy, Pandas, Scikit-learn, Matplotlib, PyTorch o TensorFlow.
- Plataforma virtual de aprendizaje (Moodle o Classroom).
- Notebooks de Jupyter y Google Colab para laboratorios prácticos.
- Repositorio GitHub para entrega y revisión de proyectos.

8. Trabajos en laboratorio y proyectos

- Laboratorios individuales: ejercicios guiados de implementación (MLE/MAP, validación cruzada, regresión logística, SVM, clustering, redes neuronales).
- Proyecto final grupal: desarrollo de un modelo de IA aplicado a un problema real de ingeniería (ej. predicción, diagnóstico, optimización). Incluye reporte técnico y sustentación.
- Análisis de paper: lectura y discusión crítica de un artículo científico actual en IA.

9. Métodos de aprendizaje

- Clases magistrales y talleres prácticos.
- Aprendizaje basado en proyectos (ABP).
- Trabajo colaborativo en pequeños grupos.
- Estudio de casos reales.
- Seminarios de lectura de papers y discusión guiada.

10. Métodos de evaluación

La evaluación se realiza mediante actividades prácticas de programación, análisis teórico–conceptual, lectura crítica de artículos científicos y desarrollo de proyectos aplicados en inteligencia artificial. Se promueve tanto el trabajo individual como colaborativo, priorizando la aplicación de modelos probabilísticos de aprendizaje de máquina a problemas reales de ingeniería.

- Primera evaluación: Se aplica al finalizar los temas T-0 a T-4. Tiene un valor del 25% e involucra los resultados de aprendizaje RAA-1 y RAA-2.

Evalúa los fundamentos del aprendizaje de máquina, inferencia probabilística (MLE y MAP), preparación de datos y técnicas de validación cruzada, mediante laboratorios prácticos de implementación.

- Segunda evaluación: Se realiza al concluir los temas T-5 a T-8. Tiene un valor del 30% e involucra los resultados de aprendizaje RAA-1, RAA-2 y RAA-3. Incluye un examen parcial teórico–práctico y ejercicios de análisis de desempeño de modelos de clasificación supervisada, métodos kernel y aprendizaje no supervisado.

- Tercera evaluación: Se realiza durante el desarrollo y cierre de los temas T-9 a T-12. Tiene un valor del 45% e involucra los resultados de aprendizaje RAA-3, RAA-4, RAA-5 y RAA-6. Comprende el proyecto final aplicado (35%) y el análisis crítico de un artículo científico del estado del arte en inteligencia artificial (10%). Evalúa el diseño, implementación, validación de modelos avanzados de redes neuronales y la capacidad de interpretación técnica de literatura académica.

Cada evaluación contempla entregas individuales y grupales, fomentando buenas prácticas de programación científica, documentación técnica, reproducibilidad experimental y comunicación efectiva de resultados.