



National University of Engineering (UNI)
School of Computer Science
Syllabus 2026-I

1. COURSE

AI367. Topics in Artificial Intelligence (Mandatory)

2. GENERAL INFORMATION

2.1 Course	: AI367. Topics in Artificial Intelligence
2.2 Semester	: 10 th Semester.
2.3 Credits	: 4
2.4 Hours	: 2 HT; 4 HP;
2.5 Duration of the period	: 16 weeks
2.6 Type of course	: Mandatory
2.7 Learning modality	: Face to face
2.8 Prerequisites	: AI264. Deep Learning. (7 th Sem)

3. PROFESSORS

Meetings after coordination with the professor

4. INTRODUCTION TO THE COURSE

Artificial Intelligence is a rapidly evolving field. This course explores advanced and contemporary topics that are currently shaping the industry and research. Focus is placed on Generative AI, Large Language Models (LLMs), and Advanced Reinforcement Learning. Students will analyze the architectures behind modern AI systems, such as Transformers, and discuss the technical and societal challenges of deploying autonomous intelligent agents at scale.

5. GOALS

- Understand the architecture and training process of Large Language Models.
- Master the principles of Generative AI for text and image synthesis.
- Implement advanced Reinforcement Learning algorithms for decision making.
- Apply prompt engineering and fine-tuning techniques to existing models.
- Critically evaluate the latest research papers and trends in AI.

6. COMPETENCES

AG-C06) Life-long Learning: Recognizes the importance of continuous learning and adaptation to new technologies.
(Usage)

7. TOPICS

Unit 1: Aprendizaje Automático I: Fundamentos (6 hours)	
Competences Expected: AG-C06	
Topics	Learning Outcomes
- Definición y ejemplos de una amplia variedad de tareas de aprendizaje automático: - Aprendizaje supervisado: * Clasificación * Regresión - Aprendizaje por refuerzo - Aprendizaje no supervisado: * Agrupamiento - Ideas fundamentales: - Teorema de no hay almuerzo gratis: ningún aprendiz puede resolver todos los problemas; las decisiones de diseño de representación tienen consecuencias. - Fuentes de error e indecidibilidad en el aprendizaje automático - Un aprendizaje supervisado simple basado en estadísticas como regresión lineal o árboles de decisión: - Enfocarse en cómo funcionan sin entrar en detalles matemáticos o de optimización; suficiente para entender y usar implementaciones existentes correctamente - El problema del sobreajuste/control de la complejidad de la solución (regularización, poda - solo intuición): - El compromiso entre sesgo (subajuste) - varianza (sobreajuste)	- Describir las diferencias entre los tres estilos principales de aprendizaje (supervisado, por refuerzo y no supervisado) y determinar cuál es apropiado para un dominio de problema particular [Explicar] - Diferenciar los términos: IA, aprendizaje automático y aprendizaje profundo [Evaluar] - Formular una aplicación como un problema de clasificación, incluyendo las características de entrada disponibles y la salida a predecir (por ejemplo, identificar caracteres alfabéticos a partir de entrada de cuadrícula de píxeles) [Aplicar] - Identificar el sobreajuste en el contexto de un problema y curvas de aprendizaje y describir soluciones al sobreajuste [Evaluar] - Explicar cómo funciona el aprendizaje automático como un proceso de optimización/búsqueda [Explicar]
Readings : [GBC16], [Fos22]	

Unit 2: Aprendizaje Automático II: Datos, Representaciones y Evaluación (5 hours)	
Competences Expected: AG-C06	
Topics	Learning Outcomes
• Trabajar con Datos: – Preprocesamiento de datos: * Importancia y peligros de las elecciones de preprocesamiento – Manejo de valores faltantes (imputación, marcar como faltante): * Implicaciones de imputar versus marcar como faltante – Codificación de variables categóricas, codificación de datos de valor real – Normalización/estandarización – énfasis en datos reales, no ejemplos de libros de texto • Representaciones: – Espacios de hipótesis y complejidad – Expansión de características de base simple, como elevar al cuadrado características univariadas – Representaciones de características aprendidas • Evaluación del aprendizaje automático: – Separación de conjuntos de entrenamiento, validación y prueba – Métricas de rendimiento para clasificadores – Estimación del rendimiento en prueba en datos retenidos – Ajuste de los parámetros de un modelo de aprendizaje automático con un conjunto de validación – Importancia de entender qué está haciendo un modelo, dónde están sus peligros/limitaciones y las implicaciones de sus decisiones	• Aplicar dos o más algoritmos de aprendizaje estadístico simple a una tarea de clasificación y medir la precisión de los clasificadores [Aplicar] • Implementar un algoritmo de aprendizaje estadístico y el proceso de optimización correspondiente para entrenar el clasificador y obtener una predicción en nuevos datos [Aplicar] • Explicar los procedimientos adecuados de evaluación de AA, incluyendo las diferencias entre rendimiento en entrenamiento y prueba, y qué puede salir mal con el proceso de evaluación llevando a informes inexactos del rendimiento de AA [Explicar] • Comparar dos algoritmos de aprendizaje automático en un conjunto de datos, implementando la metodología de preprocesamiento de datos y evaluación (por ejemplo, métricas y manejo de divisiones entrenamiento/prueba) desde cero [Aplicar]
Readings : [GBC16], [Fos22]	

Unit 3: Aprendizaje Automático III: Redes Neuronales y Ética (5 hours)	
Competences Expected: AG-C06	
Topics	Learning Outcomes
• Redes neuronales básicas: – Fundamentos de comprensión de cómo funcionan las redes neuronales y su proceso de entrenamiento, sin detalles de los cálculos – Introducción básica a redes neuronales generativas (por ejemplo, modelos de lenguaje grandes) • ética para el Aprendizaje Automático: – Enfocarse en datos reales, escenarios reales y estudios de caso – Sesgo de conjunto de datos/algorítmico/de evaluación y consecuencias no deseadas	• Describir el proceso de entrenamiento de redes neuronales y las representaciones aprendidas resultantes [Explicar]
Readings : [GBC16], [Fos22]	

Unit 4: Formulación del Aprendizaje Automático y Evaluación (3 hours)	
Competences Expected:	
Topics	Learning Outcomes
• Formulación del aprendizaje automático simple como un problema de optimización, como regresión lineal por mínimos cuadrados o regresión logística: – Función objetivo – Descenso de gradiente – Regularización para evitar sobreajuste (formulación matemática) • Conjuntos de modelos: – Combinación de mayoría ponderada simple • Evaluación de rendimiento: – Otras métricas para clasificación (por ejemplo, error, precisión, exhaustividad) – Métricas de rendimiento para regresores – Matriz de confusión – Validación cruzada: * Ajuste de parámetros (búsqueda en cuadrícula/aleatoria, mediante validación cruzada)	• Comparar y contrastar varias técnicas de aprendizaje (por ejemplo, árboles de decisión, regresión logística, Bayes ingenuo, redes neuronales y redes de creencia), proporcionando ejemplos de cuándo cada estrategia es superior [Comparar] • Evaluar el rendimiento de un sistema de aprendizaje simple en un conjunto de datos del mundo real [Evaluar] • Caracterizar el estado del arte en teoría del aprendizaje, incluyendo sus logros y limitaciones [Explicar] • Explicar el problema del sobreajuste, junto con técnicas para detectar y manejar el problema [Explicar] • Explicar el triple compromiso entre el tamaño de un espacio de hipótesis, el tamaño del conjunto de entrenamiento y la precisión del rendimiento [Explicar]
Readings : [GBC16]	

Unit 5: Aprendizaje Profundo, RL y Ética (3 hours)	
Competences Expected:	
Topics	Learning Outcomes
• Aprendizaje profundo: – Redes feed-forward profundas (solo intuición, sin matemáticas) – Redes neuronales convolucionales (solo intuición, sin matemáticas) – Visualización de representaciones de características aprendidas de redes profundas – Otras arquitecturas (NN generativas, NN recurrentes, transformers, etc.) • Visión general de los métodos de aprendizaje por refuerzo • Dos o más aplicaciones de algoritmos de aprendizaje automático: – Por ejemplo, medicina y salud, economía, visión, lenguaje natural, robótica, juego • ética para el Aprendizaje Automático: – Continuar enfocándose en datos reales, escenarios reales y estudios de caso – Privacidad – Equidad – Propiedad intelectual – Explicabilidad	• Visualizar el progreso del entrenamiento de una red neuronal a través de curvas de aprendizaje en un kit de herramientas establecido (por ejemplo, TensorBoard) y visualizar las características aprendidas de la red [Aplicar] • Dada una aplicación real de aprendizaje automático, describir problemas éticos respecto a las elecciones de datos, pasos de preprocesamiento, selección de algoritmo y visualización/presentación de resultados [Aplicar]
Readings : [GBC16]	

Unit 6: Procesamiento del Lenguaje Natural (20 hours)	
Competences Expected: AG-C06	
Topics	Learning Outcomes
• Gramáticas deterministas y estocásticas • Algoritmos de análisis sintáctico: – CFGs y analizadores de tabla (por ejemplo, CYK) – CFGs probabilísticos y CYK ponderado • Representación del significado/Semántica: – Representaciones del conocimiento basadas en lógica – Roles semánticos – Representaciones temporales – Creencias, deseos e intenciones • Métodos basados en corpus • N-gramas y HMMs • Suavizado y retroceso • Ejemplos de uso: Etiquetado POS y morfología • Recuperación de información: – Modelo de espacio vectorial: * TF & IDF – Precisión y exhaustividad • Extracción de información • Traducción de lenguaje • Clasificación de texto, categorización: – Modelo de bolsa de palabras • Aprendizaje profundo para PLN: – RNNs – Transformers – Incrustaciones multimodales (por ejemplo, imágenes + texto) – Modelos de lenguaje generativos	• Definir y contrastar gramáticas deterministas y estocásticas, proporcionando ejemplos para mostrar la adecuación de cada una [Definir] • Simular, aplicar o implementar algoritmos clásicos y estocásticos para analizar lenguaje natural [Aplicar] • Identificar los desafíos de representar el significado [Analizar] • Listar las ventajas de usar corpus estándar. Identificar ejemplos de corpus actuales para una variedad de tareas de PLN [Listar/Enumerar] • Identificar técnicas para recuperación de información, traducción de lenguaje y clasificación de texto [Analizar] • Implementar una transformación TF/IDF, usarla para extraer características de un corpus, y entrenar un algoritmo de aprendizaje automático estándar usando esas características para hacer clasificación de texto [Aplicar]
Readings : [TWW22], [RN20]	

Unit 7: Aprendizaje Automático I: Fundamentos (6 hours)	
Competences Expected: AG-C06	
Topics	Learning Outcomes
- Definición y ejemplos de una amplia variedad de tareas de aprendizaje automático: - Aprendizaje supervisado: - Clasificación - Regresión - Aprendizaje por refuerzo - Aprendizaje no supervisado: - Agrupamiento - Ideas fundamentales: - Teorema de no hay almuerzo gratis: ningún aprendiz puede resolver todos los problemas; las decisiones de diseño de representación tienen consecuencias. - Fuentes de error e indecidibilidad en el aprendizaje automático - Un aprendizaje supervisado simple basado en estadísticas como regresión lineal o árboles de decisión: - Enfocarse en cómo funcionan sin entrar en detalles matemáticos o de optimización; suficiente para entender y usar implementaciones existentes correctamente - El problema del sobreajuste/control de la complejidad de la solución (regularización, poda - solo intuición): - El compromiso entre sesgo (subajuste) - varianza (sobreajuste)	- Describir las diferencias entre los tres estilos principales de aprendizaje (supervisado, por refuerzo y no supervisado) y determinar cuál es apropiado para un dominio de problema particular [Explicar] - Diferenciar los términos: IA, aprendizaje automático y aprendizaje profundo [Evaluar] - Formular una aplicación como un problema de clasificación, incluyendo las características de entrada disponibles y la salida a predecir (por ejemplo, identificar caracteres alfabéticos a partir de entrada de cuadrícula de píxeles) [Aplicar] - Identificar el sobreajuste en el contexto de un problema y curvas de aprendizaje y describir soluciones al sobreajuste [Evaluar] - Explicar cómo funciona el aprendizaje automático como un proceso de optimización/búsqueda [Explicar]
Readings : [SB18]	

Unit 8: Aprendizaje Automático II: Datos, Representaciones y Evaluación (5 hours)	
Competences Expected: AG-C06	
Topics	Learning Outcomes
• Trabajar con Datos: – Preprocesamiento de datos: * Importancia y peligros de las elecciones de preprocesamiento – Manejo de valores faltantes (imputación, marcar como faltante): * Implicaciones de imputar versus marcar como faltante – Codificación de variables categóricas, codificación de datos de valor real – Normalización/estandarización – énfasis en datos reales, no ejemplos de libros de texto • Representaciones: – Espacios de hipótesis y complejidad – Expansión de características de base simple, como elevar al cuadrado características univariadas – Representaciones de características aprendidas • Evaluación del aprendizaje automático: – Separación de conjuntos de entrenamiento, validación y prueba – Métricas de rendimiento para clasificadores – Estimación del rendimiento en prueba en datos retenidos – Ajuste de los parámetros de un modelo de aprendizaje automático con un conjunto de validación – Importancia de entender qué está haciendo un modelo, dónde están sus peligros/limitaciones y las implicaciones de sus decisiones	• Aplicar dos o más algoritmos de aprendizaje estadístico simple a una tarea de clasificación y medir la precisión de los clasificadores [Aplicar] • Implementar un algoritmo de aprendizaje estadístico y el proceso de optimización correspondiente para entrenar el clasificador y obtener una predicción en nuevos datos [Aplicar] • Explicar los procedimientos adecuados de evaluación de AA, incluyendo las diferencias entre rendimiento en entrenamiento y prueba, y qué puede salir mal con el proceso de evaluación llevando a informes inexactos del rendimiento de AA [Explicar] • Comparar dos algoritmos de aprendizaje automático en un conjunto de datos, implementando la metodología de preprocesamiento de datos y evaluación (por ejemplo, métricas y manejo de divisiones entrenamiento/prueba) desde cero [Aplicar]
Readings : [SB18]	

Unit 9: Aprendizaje Automático III: Redes Neuronales y Ética (5 hours)	
Competences Expected: AG-C06	
Topics	Learning Outcomes
• Redes neuronales básicas: – Fundamentos de comprensión de cómo funcionan las redes neuronales y su proceso de entrenamiento, sin detalles de los cálculos – Introducción básica a redes neuronales generativas (por ejemplo, modelos de lenguaje grandes) • ética para el Aprendizaje Automático: – Enfocarse en datos reales, escenarios reales y estudios de caso – Sesgo de conjunto de datos/algorítmico/de evaluación y consecuencias no deseadas	• Describir el proceso de entrenamiento de redes neuronales y las representaciones aprendidas resultantes [Explicar]
Readings : [SB18]	

Unit 10: Aplicaciones e Impacto Social (Parte I) (6 hours)	
Competences Expected: AG-C06	
Topics	Learning Outcomes
• Al menos una aplicación de IA a un problema y campo específico, como medicina, salud, sostenibilidad, redes sociales, economía, educación, robótica, etc. (elegir al menos uno para el Núcleo CS): – Formular y evaluar una aplicación específica como un problema de IA: * Cómo lidiar con problemas mal especificados o mal planteados – Disponibilidad/escasez y limpieza de datos: * Limpieza y preprocesamiento básico de datos * Sesgo del conjunto de datos – Sesgo algorítmico – Sesgo de evaluación – Evaluación de las implicaciones sociales de la aplicación • Modelos generativos profundos desplegados: – Visión general de alto nivel de modelos generativos de imágenes profundas (por ejemplo, a 2023, DALL-E, Midjourney, Stable Diffusion, etc.), sus usos y sus limitaciones/peligros. – Visión general de alto nivel de modelos de lenguaje grandes (por ejemplo, a 2023, ChatGPT, Bard, etc.), sus usos y sus limitaciones/peligros. • Visión general del impacto social de la IA: – ética – Equidad – Confianza/explicabilidad – Privacidad y uso de datos de entrenamiento – Autonomía humana y supervisión/regulaciones/requisitos legales – Sostenibilidad	• Dado un dominio de aplicación y problema del mundo real, formular una solución de IA para ello, identificando datos/entrada apropiados, preprocesamiento, representaciones, técnicas de IA y métricas/metodología de evaluación [Aplicar]
Readings : [RN20], [Bos14]	

Unit 11: Aplicaciones e Impacto Social (Parte II) (6 hours)	
Competences Expected: AG-C06	
Topics	Learning Outcomes
• Una o más aplicaciones adicionales de IA a un amplio conjunto de problemas y diversos campos, como medicina, salud, sostenibilidad, redes sociales, economía, educación, robótica, etc. (elegir un área diferente de la elegida para el Núcleo CS): – Formular y evaluar una aplicación específica como un problema de IA: * Cómo lidiar con problemas mal especificados o mal planteados – Disponibilidad/escasez y limpieza de datos: * Limpieza y preprocesamiento básico de datos * Sesgo del conjunto de datos – Sesgo algorítmico – Sesgo de evaluación – Evaluación de las implicaciones sociales de la aplicación • Profundidad adicional sobre modelos generativos profundos desplegados: – Introducción a cómo funcionan los modelos generativos de imágenes profundas (por ejemplo, a 2023, DALL-E, Midjourney, Stable Diffusion) incluyendo discusión de atención – Introducción a cómo funcionan los modelos de lenguaje grandes (por ejemplo, a 2023, Chat-GPT, Bard) incluyendo discusión de atención – Idea de modelos fundamentales, cómo usarlos, y los beneficios/problemas con entrenarlos a partir de grandes datos • Análisis y discusión del impacto social de la IA: – ética – Equidad – Confianza/explicabilidad – Privacidad y uso de datos de entrenamiento – Autonomía humana y supervisión/regulaciones/requisitos legales – Sostenibilidad	• Analizar el impacto social de una o más aplicaciones específicas de IA del mundo real, identificando problemas respecto a ética, equidad, sesgo, confianza y explicabilidad [Evaluar] • Describir algunos de los modos de falla de los modelos generativos profundos actuales para lenguaje o imágenes, y cómo esto podría afectar su uso en una aplicación [Describir]
Readings : [RN20], [Bos14]	

8. WORKPLAN

8.1 Methodology

Individual and team participation is encouraged to present their ideas, motivating them with additional points in the different stages of the course evaluation.

8.2 Theory Sessions

The theory sessions are held in master classes with activities including active learning and roleplay to allow students

to internalize the concepts.

8.3 Practical Sessions

The practical sessions are held in class where a series of exercises and/or practical concepts are developed through problem solving, problem solving, specific exercises and/or in application contexts.

9. EVALUATION SYSTEM

***** EVALUATION MISSING *****

10. BASIC BIBLIOGRAPHY

- [Bos14] Nick Bostrom. *Superintelligence: Paths, Dangers, Strategies*. Oxford University Press, 2014.
- [GBC16] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep Learning*. MIT Press, 2016.
- [SB18] Richard S. Sutton and Andrew G. Barto. *Reinforcement Learning: An Introduction*. 2nd. MIT Press, 2018.
- [RN20] Stuart Russell and Peter Norvig. *Artificial Intelligence: A Modern Approach*. 4th. Pearson, 2020.
- [Fos22] David Foster. *Generative Deep Learning*. 2nd. O'Reilly Media, 2022.
- [TWW22] Lewis Tunstall, Leandro von Werra, and Thomas Wolf. *Natural Language Processing with Transformers*. O'Reilly Media, 2022.