



1. Datos Generales de la asignatura

Nombre de la asignatura:	Aprendizaje Automático Profundo
Clave de la asignatura:	MID-2606
SATCA¹:	2-3-5
Carreras:	Ingeniería en Sistemas Computacionales

2. Presentación

Caracterización de la asignatura

La asignatura de **Aprendizaje Automático Profundo** está diseñada para proporcionar a los estudiantes de **Ingeniería en Sistemas Computacionales** una sólida base teórica y práctica en el campo del Deep Learning. El curso aborda los conceptos fundamentales, algoritmos y técnicas avanzadas del aprendizaje profundo, y su aplicación en la solución de problemas empresariales. A lo largo del curso, los estudiantes aprenderán a implementar soluciones tecnológicas basadas en redes neuronales profundas para optimizar procesos, mejorar la toma de decisiones y generar valor en contextos de negocio. El enfoque de la asignatura combina la teoría subyacente a los modelos de aprendizaje profundo con casos prácticos aplicados al ámbito empresarial, permitiendo a los estudiantes adquirir las competencias necesarias para desarrollar y desplegar soluciones en entornos reales. Se pondrá énfasis en el uso de plataformas modernas de desarrollo y computación en la nube para llevar a cabo estas implementaciones.

Para este propósito, se requiere de las competencias adquiridas en asignaturas que contengan temas como:

- Lenguajes y Autómatas II
- Sistemas Operativos
- Tópicos Avanzados de Programación
- Administración de Bases de Datos
- Probabilidad y Estadística

Su contenido impacta en las siguientes competencias del perfil de egreso.

- Coordina y participa en equipos multidisciplinarios para la aplicación de soluciones innovadoras en diferentes contextos.

¹ Sistema de Asignación y Transferencia de Créditos Académicos





- Diseña, implementa y administra bases de datos optimizando los recursos disponibles, conforme a las normas vigentes de manejo y seguridad de la información.
- Desarrolla y administra software para apoyar la productividad y competitividad de las organizaciones cumpliendo con estándares de calidad.
- Detecta áreas de oportunidad empleando una visión empresarial para crear proyectos aplicando las Tecnologías de la Información y Comunicación.

Intención didáctica

La asignatura de Aprendizaje Profundo está diseñada para los estudiantes de la carrera de Ingeniería en Sistemas Computacionales, con el objetivo de proporcionar una sólida base teórica y práctica en los métodos y aplicaciones del Deep Learning, preparándolos para los desafíos tecnológicos de 2026-2028. A lo largo de las seis unidades del temario, los estudiantes desarrollarán competencias en la construcción, adaptación (fine-tuning), optimización y despliegue de modelos complejos.

El objetivo de la asignatura es que los estudiantes no solo conozcan los algoritmos, sino que sean capaces de seleccionar la herramienta adecuada para cada problema, implementarla de forma eficiente y ponerla a disposición de los usuarios finales. La asignatura se estructura en seis unidades. La primera unidad sienta las bases teóricas y la diferenciación clave entre Machine Learning y Deep Learning. La segunda unidad brinda a los estudiantes las habilidades para crear modelos avanzados como el Perceptrón Multicapa (MLP) y redes convolucionales (CNN), tecnologías clave en áreas como el reconocimiento de patrones. La tercera unidad introduce el manejo de datos secuenciales con RNN y LSTM, y explora los modelos generativos modernos, como los modelos de difusión. La cuarta unidad, se centra en la revolución de los Grandes Modelos de Lenguaje (LLMs). Aquí los estudiantes aprenderán a comunicarse eficazmente con estos modelos mediante Prompt Engineering y a conectarlos con fuentes de datos externas mediante RAG, habilitando asistentes virtuales inteligentes y contextualizados. La quinta unidad es el puente hacia la industria real: MLOps. Los estudiantes aprenderán a contenerizar, desplegar y monitorear modelos en producción, una habilidad crítica para cualquier ingeniero de IA. Finalmente, la sexta unidad aborda un tema de creciente importancia: la IA responsable, donde se analizan y mitigan sesgos y se aprende a explicar las decisiones de los modelos.

El presente temario forma una estructura que integra conocimientos avanzados en Deep Learning, habilidades técnicas aplicadas y un enfoque en las necesidades actuales del mercado tecnológico. Al completar esta asignatura, los estudiantes de Ingeniería en Sistemas Computacionales estarán preparados para enfrentar los desafíos de las





empresas e industria, desarrollando soluciones basadas en inteligencia artificial que transformen la manera en que las empresas manejan datos y automatizan procesos.

3. Participantes en el diseño y seguimiento curricular del programa

Lugar y fecha de elaboración o revisión	Participantes	Observaciones
Instituto Tecnológico de Tuxtla Gutiérrez	Néstor Antonio Morales Navarro Germán Ríos Toledo	

4. Competencia(s) a desarrollar

Competencia(s) específica(s) de la asignatura
El estudiante será capaz de diseñar, implementar y desplegar soluciones basadas en modelos de aprendizaje profundo mediante el uso de redes neuronales avanzadas, modelos generativos y sistemas de inteligencia artificial aplicados a problemas empresariales.

5. Competencias previas

- Diseñar y desarrollar aplicaciones mediante programación orientada a objetos - Comprende, aplica e implementa algoritmos de manera computarizada utilizando herramientas y lenguajes de programación. - Comprender y aplicar algoritmos básicos de aprendizaje automático y de optimización - Seleccionar y manejar estructuras de datos adecuadas (listas, matrices, vectores) que optimicen la manipulación de grandes volúmenes de datos en el entrenamiento y predicción de modelos de aprendizaje profundo. - Conocer de arquitecturas de hardware, como el uso de GPU y CPU para el procesamiento paralelo y aceleración del entrenamiento de redes neuronales profundas.





6. Temario

No.	Temas	Subtemas
1	Introducción al Aprendizaje Profundo	1.1 Conceptos básicos de Aprendizaje Automático (supervisado, no supervisado, por refuerzo). 1.2 Diferencias entre Machine Learning y Deep Learning. 1.3 Aplicaciones empresariales actuales de Deep Learning. 1.4 Herramientas y bibliotecas modernas (TensorFlow, Keras, PyTorch, Hugging Face).
2	Redes Neuronales Artificiales	2.1 Fundamentos de redes neuronales: el Perceptrón. 2.2 Perceptrón Multicapa (MLP): Propagación, funciones de activación y optimización. 2.3 Redes Neuronales Convolucionales (CNN): 2.3.1 Capas de convolución y pooling. 2.3.2 Arquitecturas modernas (ej. ResNet, EfficientNet). 2.4 Casos de uso: Clasificación de imágenes, detección de objetos para inventario y marketing.
3	Datos secuenciales y Modelos Generativos	3.1 Redes Neuronales Recurrentes (RNN) y LSTM: 3.1.1 Arquitectura y manejo de secuencias. 3.1.2 Aplicaciones en predicción de series temporales (ventas, demanda). 3.2 Modelos Generativos Modernos: 3.2.1 Introducción a los Modelos de Difusión (Stable Diffusion, DALL-E). 3.2.2 Autocodificadores Variacionales (VAE). 3.2.3 Aplicaciones en generación de contenido y simulación
4	Modelos de Lenguaje Grandes e Ingeniería de prompts	4.1 Introducción a los Transformers y la atención. 4.2 Modelos Pre-entrenados (BERT, GPT, Llama). 4.3 Ingeniería de Prompts (Prompt Engineering):





		4.3.1 Técnicas: Zero-shot, Few-shot, Chain-of-Thought. 4.4 Generación Aumentada por Recuperación (RAG): 4.4.1 Conectar LLMs con bases de datos externas. 4.4.2 Creación de chatbots contextualizados para la empresa. 4.5 Aplicaciones: Análisis de sentimientos, resumen de documentos, atención al cliente.
5	MLOps: Despliegue y Operación de Modelos en Producción	5.1 Ciclo de vida de un proyecto de ML: Experimentación, empaquetado, despliegue, monitoreo. 5.2 Herramientas de MLOps: 5.2.1 Contenerización con Docker. 5.2.2 Seguimiento de experimentos con MLflow. 5.3 Estrategias de despliegue: 5.3.1 APIs REST con FastAPI. 5.3.2 Inferencia por lotes (batch). 5.4 Optimización para producción: Cuantización y destilación de modelos (TinyML / Edge Computing). 5.5 Plataformas en la nube: Google Cloud (Vertex AI), AWS (SageMaker) y Azure (ML).
6	IA Responsable: Ética, Sesgo y Explicabilidad	6.1 Ética en Inteligencia Artificial. 6.2 Detección y mitigación de sesgos (Bias) en datos y modelos. 6.3 Explicabilidad del modelo (XAI): Uso de herramientas como SHAP y LIME para entender predicciones. 6.4 Privacidad de datos: Introducción a la privacidad diferencial y generación de datos sintéticos. 6.5 Marco regulatorio emergente (Ej. Ley de IA de la UE).





7. Actividades de aprendizaje de los temas

1. Introducción al Aprendizaje Automático Profundo	
Competencias	Actividades de aprendizaje
Específica(s): Comprende los fundamentos del aprendizaje automático y sus principales tipos (supervisado, no supervisado, por refuerzo). Genérica(s): • Capacidad de análisis y síntesis. • Capacidad de comunicación oral y escrita. • Capacidad de investigación. • Capacidad de trabajo en equipo.	• Investigar cómo empresas líderes utilizan Deep Learning en la actualidad. • Elaborar un mapa conceptual que relacione los conceptos de ML, DL, NN y las principales bibliotecas. • Configurar un entorno de desarrollo con Python, TensorFlow/PyTorch y Hugging Face.
2. Redes Neuronales Artificiales	
Competencias	Actividades de aprendizaje
Específica(s): Diseña e implementa modelos MLP y CNN para resolver problemas de clasificación y predicción en entornos empresariales. Genérica(s): • Capacidad de análisis y síntesis. • Capacidad de investigación. • Habilidad para buscar, procesar y analizar información procedente de fuentes diversas.	• Implementar una red MLP desde cero con NumPy para comprender la retropropagación. • Utilizar Keras/TensorFlow para construir una CNN y clasificar un dataset de imágenes (ej. CIFAR-10). • Investigar y presentar un caso de éxito de CNN en la industria (ej. diagnóstico por imágenes, control de calidad en fábricas).
3. Datos secuenciales y Modelos Generativos	
Competencias	Actividades de aprendizaje
Específica(s): Aplica RNN y LSTM para series temporales. Comprende el potencial de los modelos generativos modernos. Genérica(s):	• Implementar una LSTM para predecir las ventas futuras de una empresa usando un dataset de series temporales.





• Capacidad de análisis y síntesis. • Capacidad de aplicar los conocimientos en la práctica. • Habilidad para buscar, procesar y analizar información procedente de fuentes diversas. • Capacidad de comunicación oral y escrita.	• Utilizar una API de un modelo de difusión (ej. Stable Diffusion) para generar imágenes de producto a partir de descripciones textuales. • Debatir sobre el impacto de la generación de contenido en el marketing y la creatividad.
4. Modelos de Lenguaje Grandes e Ingeniería de prompts	
Competencias	Actividades de aprendizaje
Específica(s): Domina las técnicas de <i>Prompt Engineering</i> para guiar a los LLMs. Implementa sistemas de recuperación (RAG) para contextualizar los LLMs con datos propios de la empresa. Genérica(s): • Capacidad de aplicar los conocimientos en la práctica • Capacidad de comunicación oral y escrita • Habilidades en el uso de las tecnologías de la información y comunicación Capacidad de investigación. • Habilidad para buscar, procesar y analizar información procedente de fuentes diversas.	• Diseñar prompts efectivos para tareas específicas: resumir un contrato, extraer entidades, traducir lenguaje técnico. • Implementar un sistema RAG simple que permita a un LLM "hablar" sobre el contenido de un PDF corporativo. • Evaluar diferentes LLMs (GPT, Llama, Gemini) en una tarea de análisis de sentimientos y comparar su rendimiento y costo.
5. MLOps: Despliegue y Operación de Modelos en Producción	
Competencias	Actividades de aprendizaje
Específica(s): Despliega y monitorea modelos de Deep Learning en entornos de producción, aplicando principios de MLOps.	• Contenerizar un modelo entrenado (ej. la CNN de la unidad 2) en un contenedor Docker. • Crear una API REST con FastAPI para servir el modelo y consumirla desde un cliente simple.





Genérica(s): • Capacidad de análisis y síntesis • Habilidad para buscar, procesar y analizar información procedente de fuentes diversas • Capacidad para identificar, plantear y resolver problemas • Habilidad para buscar, procesar y analizar información procedente de fuentes diversas	• Utilizar MLflow para registrar las métricas de diferentes experimentos de entrenamiento. • Investigar y comparar los servicios de MLOps de las principales nubes (AWS SageMaker vs. Google Vertex AI).
6. IA Responsable: Ética, Sesgo y Explicabilidad	
Competencias	Actividades de aprendizaje
Específica(s): Identifica y mitiga sesgos en modelos de IA, y aplica herramientas de explicabilidad. Genérica(s): • Capacidad de análisis y síntesis • Habilidad para buscar, procesar y analizar información procedente de fuentes diversas • Capacidad crítica y reflexiva	• Analizar un dataset histórico para identificar posibles sesgos(por ejemplo: por género o código postal). • Utilizar la librería SHAP para explicar por qué un modelo de MLP rechazó una solicitud. • Debatir sobre las implicaciones éticas del uso de reconocimiento facial en espacios públicos. • Investigar sobre las Leyes de IA vigentes (por ejemplo de la Unión Europea) y su impacto en las empresas tecnológicas.

8. Práctica(s)

• Implementar una red neuronal simple en Python con NumPy que utilice propagación hacia adelante y retropropagación para comprender los fundamentos. • Visión por Computador: Implementar una CNN para la clasificación de imágenes de productos en un catálogo de e-commerce usando Keras o PyTorch. • Modelos Generativos: Utilizar una API de modelos de difusión (como Stable Diffusion) para generar variantes de diseño de un producto a partir de prompts de texto. • Ingeniería de Prompts y RAG: Desarrollar un chatbot para el área de RH que responda preguntas basándose en el manual del empleado de una empresa, utilizando un LLM y un sistema RAG.





- **MLOps:** Contenerizar el chatbot anterior con Docker y desplegarlo como una API en un servicio en la nube (como Render, Railway o Cloud Run).
- **IA Responsable:** Tomar el modelo de clasificación de la práctica de visión y utilizar SHAP para generar reportes de explicabilidad que muestren qué píxeles de la imagen influyeron en la decisión.

9. Proyecto de asignatura

El objetivo del proyecto es demostrar el desarrollo y alcance de la(s) competencia(s) de la asignatura, integrando todas las fases de un proyecto real de IA, desde la concepción hasta el despliegue y la evaluación ética.

Fundamentación: El equipo deberá identificar un problema empresarial real (real o simulado) que pueda ser abordado con Deep Learning. Deberá justificar la elección del tipo de modelo (CNN, LSTM, LLM, etc.) en función de las necesidades del negocio y realizar un diagnóstico de los datos disponibles.

Planeación: Diseñar la solución completa. Definir la arquitectura del modelo, las fuentes de datos, las herramientas a utilizar (frameworks, nube) y el cronograma de trabajo. Este plan deberá incluir una sección de "IA Responsable" donde se anticipen posibles sesgos y se planee cómo mitigarlos.

Desarrollo del proyecto:

1. **Construcción/Adaptación:** Entrenar un modelo desde cero o, más probablemente, adaptar un modelo pre-entrenado mediante fine-tuning o RAG.
2. **Evaluación:** Evaluar el modelo con métricas de negocio, no solo técnicas (ej. reducción de costos, mejora en la satisfacción del cliente).
3. **Despliegue:** Poner el modelo a disposición de un "usuario" mediante una API o una interfaz simple (como Gradio o Streamlit).

Evaluación: La evaluación final se realizará mediante una presentación y defensa del proyecto. Se evaluará no solo la funcionalidad técnica, sino también:

- **Originalidad e innovación** de la solución.
- **Funcionalidad** y robustez del despliegue.
- **Comprensión profunda** del equipo sobre el modelo y sus limitaciones.
- **Integración de la ética:** Análisis de sesgos y explicabilidad del modelo.
- **Calidad del código y documentación.**

El proyecto deberá demostrar la capacidad del estudiante para aplicar el ciclo completo de vida de un proyecto de Deep Learning, desde la idea hasta un producto mínimo viable (MVP).





10. Evaluación por competencias

Para evaluar las actividades de aprendizaje se recomienda solicitar: mapas conceptuales, reportes de investigación, estudios de casos, exposiciones en clase, reportes de visitas, portafolio de evidencias, tablas comparativas, glosarios, entre otros.

Para verificar el nivel del logro de las competencias del estudiante se recomienda utilizar: listas de cotejo, listas de verificación, matrices de valoración, rúbricas, entre otros, mediante la heteroevaluación, coevaluación y autoevaluación.

Utilizar una rúbrica que contenga los niveles de alcance del estudiante:

- **Completo:** Que cubra todos los requisitos y que posea innovación y añadiduras de investigación
- **Original:** Que sea una solución no copiada ni existente en internet u otras fuentes de conocimiento.
- **Funcional:** Que tenga las capacidades operativas mínimas
- **Comprendido:** Que el estudiante conozca de fondo el proyecto y sea capaz de identificar todo lo realizado.

11. Fuentes de información

1. Restrepo Leal, D., Vilorio Porto, J., Robles Algarín, C. (2021). El camino a las redes neuronales artificiales. Editorial: Editorial Unimagdalena. ISBN: 9789587464306
2. Bobadilla, Jesús (2020). Machine Learning y Deep Learning: Usando Python, Scikit y Keras. Editorial: RA-MA Editorial. ISBN: 9788499648903
3. Zalama Casanova, E., Gómez García, B., Duque Domingo, J. (2024). Visión artificial: componentes de los sistemas de visión y nuevas tendencias en Deep Learning. RA-MA Editorial. ISBN: 9788410360075, 9788410181670
4. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
5. Geron, A. (2023). Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow. O'Reilly.

