



1. Datos Generales de la asignatura

Nombre de la asignatura:	Modelos de Aprendizaje Automático
Clave de la asignatura:	MIC-2602
SATCA¹:	2-2-4
Carreras:	Ingeniería en Sistemas Computacionales

2. Presentación

Caracterización de la asignatura

La asignatura de **Modelos de Aprendizaje Automático** es fundamental para el desarrollo de competencias en la creación, implementación y análisis de sistemas inteligentes que aprenden de datos. Estos sistemas son capaces de realizar predicciones, clasificaciones y decisiones automatizadas, habilidades esenciales en campos como la inteligencia artificial, la ciencia de datos y el desarrollo de aplicaciones basadas en datos.

Este curso proporciona al estudiante los conocimientos teóricos y prácticos sobre diferentes enfoques del aprendizaje automático, tales como modelos supervisados, no supervisados, semi-supervisados y de refuerzo. Los estudiantes aprenden a utilizar herramientas y lenguajes de programación como Python, R o MatLab para desarrollar algoritmos que detecten patrones y tomen decisiones basadas en grandes volúmenes de datos.

Además de comprender los fundamentos de los modelos de aprendizaje automático, el estudiante será capaz de diseñar y entrenar modelos predictivos, validar su rendimiento, y optimizarlos para diferentes problemas y contextos, como el reconocimiento de imágenes, procesamiento de lenguaje natural, análisis de datos financieros, y otros. También se introduce el uso de técnicas avanzadas como redes neuronales, Deep Learning, y métodos de regularización para evitar el sobreajuste de los modelos.

La asignatura guarda una estrecha relación con áreas como minería de datos, inteligencia artificial, análisis de datos y procesamiento masivo de información. Al finalizar el curso, el estudiante estará preparado para aplicar técnicas de aprendizaje automático en la resolución de problemas complejos, proponer mejoras en sistemas existentes y desarrollar soluciones innovadoras en el ámbito tecnológico.

¹ Sistema de Asignación y Transferencia de Créditos Académicos





Para aprovechar al máximo esta asignatura, es necesario contar con competencias previas en las siguientes áreas:

- **Probabilidad y estadística:** para comprender y aplicar los fundamentos matemáticos de los modelos.
- **Álgebra lineal:** para manipular las estructuras de datos que conforman los modelos.
- **Programación y estructuras de datos:** para implementar los algoritmos de aprendizaje de manera eficiente.

El impacto de este curso en las competencias del perfil de egreso es significativo, especialmente en las siguientes áreas:

- Analiza, diseña y optimiza sistemas de procesamiento de datos mediante la aplicación de técnicas de aprendizaje automático y herramientas de análisis de datos.
- Desarrolla e implementa soluciones tecnológicas innovadoras que integran modelos de aprendizaje automático para mejorar la eficiencia y precisión de los procesos en diversas industrias.
- Evalúa y selecciona algoritmos de aprendizaje automático adecuados para resolver problemas específicos, optimizando el uso de recursos computacionales y mejorando la toma de decisiones basadas en datos.

Intención didáctica

La asignatura de **Modelos de Aprendizaje Automático** debe abordarse desde una combinación de enfoques teóricos y prácticos, con el objetivo de que los estudiantes comprendan tanto los fundamentos matemáticos y estadísticos como la implementación práctica de los algoritmos de aprendizaje. Esta integración es fundamental para desarrollar una sólida comprensión de cómo los modelos se diseñan y ajustan, además de cómo se aplican en contextos reales.

El curso se estructurará en dos componentes principales:

1. **Teoría:** En esta parte, los estudiantes conocerán los conceptos básicos y avanzados del aprendizaje automático, tales como regresión, clasificación, clustering, redes neuronales y aprendizaje profundo. Es esencial que los alumnos comprendan las bases matemáticas y algorítmicas de los modelos, lo que implicará actividades como lecturas, análisis de papers académicos y desarrollo de diagramas conceptuales que permitan conectar los principios con su uso práctico.
2. **Práctica:** Paralelamente, los estudiantes trabajarán en la implementación de estos modelos mediante lenguajes y bibliotecas de programación como Python, Scikit-learn, TensorFlow y PyTorch. Se realizarán proyectos y ejercicios prácticos donde





entrenarán modelos con conjuntos de datos reales, ajustarán hiperparámetros, evaluarán el desempeño de los modelos y compararán resultados. Estas actividades prácticas serán esenciales para el refuerzo de los conceptos teóricos y estarán diseñadas para desarrollar habilidades técnicas como la programación, análisis de datos y optimización de modelos.

El curso se organizará de forma que los contenidos teóricos se presenten durante clases expositivas (2 créditos), seguidos de ejercicios y lecturas para consolidar el aprendizaje fuera del aula. Posteriormente, en las sesiones prácticas, los estudiantes implementarán los conceptos aprendidos mediante la programación y experimentación con distintos modelos. Las actividades de reforzamiento, como tareas de programación o experimentos en notebooks de código, permitirán al estudiante aplicar lo aprendido en situaciones reales y obtener retroalimentación inmediata sobre su desempeño.

La corrección y seguimiento de los ejercicios serán clave para detectar rápidamente áreas donde los estudiantes tengan dificultades, permitiendo ajustes en la enseñanza y el desarrollo de habilidades en aquellos que lo requieran.

Además, se fomentará el desarrollo de competencias relacionadas, como la **síntesis y análisis de datos**, la **programación orientada a objetos** y el **manejo de estructuras de datos**, ya que son esenciales para el diseño y entrenamiento de modelos de aprendizaje automático. Los proyectos finales del curso se centrarán en el desarrollo completo de un sistema de aprendizaje automático que permita a los estudiantes demostrar su capacidad para identificar problemas, aplicar los modelos adecuados y evaluar los resultados.

Finalmente, la práctica con entornos de desarrollo y herramientas como Jupyter Notebooks será una habilidad permanente que los estudiantes utilizarán en futuras asignaturas que involucren ciencia de datos, minería de datos, inteligencia artificial y análisis predictivo, consolidando así su perfil profesional.

Este enfoque didáctico asegura que los estudiantes desarrollen tanto una comprensión profunda de los modelos de aprendizaje automático como las habilidades prácticas necesarias para aplicarlos en el mundo real. Principio del formulario Final del formulario.

3. Participantes en el diseño y seguimiento curricular del programa

Lugar y fecha de elaboración o revisión	Participantes	Observaciones
Instituto Tecnológico de Tuxtla Gutiérrez, 18 de Febrero del 2026	Germán Ríos Toledo Héctor Guerra Crespo	





4. Competencia(s) a desarrollar

Competencia(s) específica(s) de la asignatura

- Desarrollar la capacidad para comprender, diseñar, implementar, optimizar e integrar modelos de aprendizaje automático en solucionar problemas reales, aplicando fundamentos matemáticos y algorítmicos, empleando herramientas especializadas de programación, y valorando las implicaciones éticas, de privacidad y de sesgo en el uso de sistemas inteligentes.

5. Competencias previas

- **Conocimientos en probabilidad y estadística:** El estudiante debe comprender los conceptos básicos de probabilidad, distribuciones, inferencia estadística y análisis de datos, ya que estos son fundamentales para entender cómo funcionan los algoritmos de aprendizaje automático y cómo se evalúan los modelos.
- **Competencia en programación:** Es necesario que el estudiante tenga habilidades en al menos un lenguaje de programación (preferentemente Python) y experiencia en el uso de estructuras de datos y algoritmos. Esto es esencial para implementar y trabajar con modelos de aprendizaje automático en entornos de programación.
- **Conocimientos en álgebra lineal y cálculo:** Los fundamentos matemáticos del aprendizaje automático, especialmente en áreas como redes neuronales y optimización, requieren un buen manejo del álgebra lineal (vectores, matrices) y cálculo (derivadas, gradientes).

6. Temario

No.	Temas	Subtemas
1	Introducción al Algebra Lineal.	1.1 Matrices y vectores 1.2 Suma y multiplicación escalar 1.3 Multiplicación de matrices y vectores 1.4 Multiplicación de matrices con matrices 1.5 Propiedades de la multiplicación de matrices 1.6 Inversa y transpuesta de una matriz





2	Regresión Lineal y Regresión Logística	2.1 Representación del modelo 2.2 Función de costo 2.3 Descenso de gradiente 2.4 Descenso de gradiente para regresión lineal 2.5 Clasificación 2.6 Representación de hipótesis 2.7 Límite de decisión 2.8 Optimización avanzada 2.9 Clasificación multiclase: uno contra todos
3	Representación del conocimiento, razonamiento y los Aspectos Metodológicos en Inteligencia Artificial.	3.1 Paradigmas de la Inteligencia Artificial. 3.2 Mapas conceptuales. 3.3 Redes semánticas. 3.4 Razonamiento monótono. 3.5 Razonamiento probabilístico. 3.6 Teorema de Bayes.
4	Sugerencias para el diseño de aplicaciones de aprendizaje automático.	4.1 Evaluación de una hipótesis 4.2 Selección de modelos y conjuntos de entrenamiento/validación/prueba 4.3 Diagnóstico de sesgo frente a varianza 4.4 Regularización y sesgo/varianza 4.5 Curvas de aprendizaje 4.6 Priorización de lo que se debe trabajar 4.7 Análisis de errores 4.8 Métricas de error para clases sesgadas 4.9 Compensación entre precisión y recuperación 4.10 Datos para aprendizaje automático
5	Aplicaciones de los algoritmos de aprendizaje automático.	5.1 Algoritmos Supervisados: 5.1.1. Regresión lineal y logística. 5.1.2. Árboles de decisión. 5.1.3. Máquinas de vectores soporte (SVM). 5.1.4. Redes neuronales básicas. 5.1.5. Aplicaciones prácticas: predicción de precios, clasificación de correos electrónicos, detección de fraudes. 5.2. Algoritmos No Supervisados:





		5.2.1. Análisis de componentes principales (PCA). 5.2.2. Clustering (K-Means, DBSCAN). 5.2.3. Aplicaciones prácticas: segmentación de clientes, reducción de dimensionalidad. 5.3. Evaluación y Selección de Modelos: 5.3.1. Métricas de evaluación: precisión, recall, F1-score, curva ROC. 5.3.2. Validación cruzada y regularización. 5.3.3. Selección y ajuste de hiperparámetros (Grid Search, Random Search). 5.3.4. Comparación de modelos y técnicas para evitar el sobreajuste. 5.3.5. Implementación con scikit-learn, TensorFlow, y Keras. 5.3.6. Entrenamiento, validación y prueba de modelos en datasets reales.
--	--	--

7. Actividades de aprendizaje de los temas

1. Introducción al álgebra lineal	
Competencias	Actividades de aprendizaje
Específica(s): Aplica los fundamentos del álgebra lineal, mediante el uso de vectores y matrices, para representar y manipular datos en problemas de aprendizaje automático, utilizando herramientas computacionales que faciliten la modelación y análisis de datos. Genérica(s): • Capacidad de análisis y síntesis. • Capacidad de comunicación oral y escrita. • Capacidad de investigación. • Capacidad de trabajo en equipo.	• Experimentar con la biblioteca NumPy de Python para realizar operaciones básicas con vectores y matrices, como la suma, multiplicación, transposición y cálculo de la norma de un vector. • Visualizar transformaciones lineales (rotación, escalado, traslación) utilizando herramientas de software como Python con Matplotlib o GeoGebra • Resolver sistemas de ecuaciones lineales utilizando álgebra matricial y lo conectarán con la implementación de modelos de regresión lineal. • Experimentar con conjuntos de datos multidimensionales y calcularán distancias





	euclidianas y productos punto entre vectores de características.
--	--

2. Regresión lineal y regresión logística	
Competencias	Actividades de aprendizaje
Específica(s): - Implementa modelos de regresión lineal y regresión logística para resolver problemas de predicción y clasificación, utilizando algoritmos de optimización y herramientas de programación que permitan analizar el comportamiento y desempeño de los modelos. Genérica(s): - Capacidad de análisis y síntesis. - Capacidad de investigación. - Habilidad para buscar, procesar y analizar información procedente de fuentes diversas.	- Implementar un modelo de regresión lineal desde cero usando Python, sin recurrir a bibliotecas de machine learning - Comprender los conceptos de sobreajuste y regularización en la regresión lineal. Implementarán los métodos de regularización Ridge y Lasso usando Scikit-learn - Implementar un modelo de regresión logística para resolver un problema de clasificación binaria. - Compararán la regresión lineal y la regresión logística a través de una serie de problemas. - Experimentar el ajuste de hiperparámetros en modelos de regresión lineal y logística con la búsqueda en cuadrícula (Grid Search) y la búsqueda aleatoria (Random Search).
3. Representación del conocimiento, razonamiento y los Aspectos Metodológicos en Inteligencia Artificial.	
Competencias	Actividades de aprendizaje
Específica(s): Analiza y representa conocimiento mediante modelos de razonamiento lógico y probabilístico, utilizando estructuras como redes semánticas, sistemas basados en reglas y redes bayesianas, con el fin de resolver	- Implementar un sistema experto sencillo utilizando un enfoque basado en reglas y hechos. - Diseñar una red semántica o una ontología básica para representar el conocimiento en un dominio específico.





problemas de inferencia en sistemas inteligentes. Genérica(s): • 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.	• Resolver problemas de razonamiento lógico utilizando lógica proposicional y lógica de predicados. • Investigar y comparar diferentes enfoques de razonamiento en IA, tales como razonamiento basado en reglas, razonamiento probabilístico (redes bayesianas), razonamiento no monótono, y razonamiento basado en casos. • Implementar un modelo de razonamiento probabilístico utilizando redes bayesianas para diagnóstico o predicción (como detección de fallos en sistemas o diagnóstico médico).
--	---

4. Sugerencias para el diseño de aplicaciones de aprendizaje automático.	
Competencias	Actividades de aprendizaje
Específica(s): • Diseña soluciones basadas en aprendizaje automático mediante la selección adecuada de modelos, conjuntos de datos y métricas de evaluación, aplicando técnicas de validación, regularización y análisis de errores para optimizar el desempeño de los modelos. 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	• Identificar un problema en el que pueda aplicarse aprendizaje automático y determinar el tipo de aprendizaje (supervisado, no supervisado o por refuerzo). • Trabajar con un conjunto de datos real para realizar el preprocesamiento necesario en un modelo de Modelo de Aprendizaje Automático. • Evaluar el modelo utilizando métricas apropiadas como precisión, recall, F1-score, o área bajo la curva ROC (AUC), según el tipo de problema (clasificación, regresión, etc.). • Preparar el modelo para desplegarlo en un entorno de producción (un servidor como Flask o FastAPI)





comunicación Capacidad de investigación. Habilidad para buscar, procesar y analizar información procedente de fuentes diversas.	
5. Aplicaciones de los algoritmos de aprendizaje automático.	
Competencias	Actividades de aprendizaje
Específica(s): - Desarrolla soluciones de análisis predictivo y reconocimiento de patrones mediante la implementación de algoritmos supervisados y no supervisados, utilizando herramientas de programación y bibliotecas especializadas para resolver problemas reales en distintos dominios de aplicación. 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	- Aplicar algoritmos de aprendizaje supervisado como regresión lineal, árboles de decisión y máquinas de soporte vectorial (SVM). - Aplicar algoritmos de aprendizaje no supervisado, como K-means, DBSCAN o clustering jerárquico, para agrupar un conjunto de datos no etiquetados. - Entrenar un modelo de red neuronal utilizando TensorFlow o PyTorch para resolver un problema de clasificación de imágenes. - Diseñar un sistema de recomendación utilizando algoritmos de filtrado colaborativo o basado en contenido. - Aplicar algoritmos de aprendizaje automático en el procesamiento del lenguaje natural (NLP) como la clasificación de texto o la detección de sentimientos.

8. Práctica(s)

- Programar códigos para operaciones con vectores y matrices.
- Programar códigos para implementar la regresión lineal.
- Programar un sistema experto basado en reglas.
- Programar una ontología mediante la herramienta ProTeGe
- Programar algoritmos de aprendizaje supervisado.





- Programar algoritmos de aprendizaje no supervisado.
- Programar un modelo de red neuronal utilizando TensorFlow o PyTorch para clasificar imágenes.
- Programar un modelo para el procesamiento del lenguaje natural (NLP).

9. Proyecto de asignatura

El objetivo del proyecto que planteé el docente que imparta esta asignatura, es demostrar el desarrollo y alcance de la(s) competencia(s) de la asignatura, considerando las siguientes fases:

Fundamentación: marco referencial (teórico, conceptual, contextual, legal) en el cual se fundamenta el proyecto de acuerdo con un diagnóstico realizado, mismo que permite a los estudiantes lograr la comprensión de la realidad o situación objeto de estudio para definir un proceso de intervención o hacer el diseño de un modelo.

Planeación: con base en el diagnóstico en esta fase se realiza el diseño del proyecto por parte de los estudiantes con asesoría del docente; implica planificar un proceso: de intervención empresarial, social o comunitario, el diseño de un modelo, entre otros, según el tipo de proyecto, las actividades a realizar los recursos requeridos y el cronograma de trabajo.

Ejecución: consiste en el desarrollo de la planeación del proyecto realizada por parte de los estudiantes con asesoría del docente, es decir en la intervención (social, empresarial), o construcción del modelo propuesto según el tipo de proyecto, es la fase de mayor duración que implica el desempeño de las competencias genéricas y específicas a desarrollar.

Evaluación: es la fase final que aplica un juicio de valor en el contexto laboral-profesión, social e investigativo, ésta se debe realizar a través del reconocimiento de logros y aspectos a mejorar se estará promoviendo el concepto de “evaluación para la mejora continua”, la metacognición, el desarrollo del pensamiento crítico y reflexivo en los estudiantes.

El proyecto deberá contemplar la capacidad de conocimiento del funcionamiento del sistema operativo, la selección y aplicación de los métodos y paradigmas y su fundamentación.

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.

En esta asignatura se requerirá la revisión del portafolio de evidencias, de las soluciones computarizadas.

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

Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow* (3rd ed.). O'Reilly Media.

Chollet, F. (2021). *Deep learning with Python* (2nd ed.). Manning Publications.

Raschka, S., & Mirjalili, V. (2020). *Python machine learning: Machine learning and deep learning with Python, Scikit-learn, and TensorFlow 2* (3rd ed.). Packt Publishing.

Aggarwal, C. C. (2020). *Linear algebra and optimization for machine learning: A textbook*. Springer.

Müller, A. C., & Guido, S. (2017). *Introduction to machine learning with Python: A guide for data scientists*. O'Reilly Media.

Boehmke, B., & Greenwell, B. (2019). *Hands-on machine learning with R*. CRC Press.

Grus, J. (2019). *Data science from scratch: First principles with Python* (2nd ed.). O'Reilly Media.

Gulli, A., & Kapoor, A. (2019). *Deep learning with TensorFlow 2 and Keras* (2nd ed.). Packt Publishing.

Singh, R. P., & Singh, M. (2021). *Machine learning with PyTorch and Scikit-Learn*. Packt Publishing.

Zhang, Z. (2020). *A hands-on introduction to machine learning*. Cambridge University Press.





Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Tuxtla Gutiérrez
Departamento de Sistemas y Computación



2026
año de
**Margarita
Maza**



Carretera Panamericana Km. 1080, C.P. 29050, Tuxtla Gutiérrez, Chiapas Tel. (961) 615 0461, 615 0138, 615 4808,
ext. 000. e-mail: sistemas@tecnm.mx tecnm.mx tuxtla.tecnm.mx