


<p>UNIVERSIDAD AUTÓNOMA DE CHIHUAHUA</p>  <p>UNIDAD ACADÉMICA: FACULTAD DE INGENIERÍA</p> <p>PROGRAMA ANALÍTICO DE LA UNIDAD DE APRENDIZAJE:</p> <p><u>MACHINE LEARNING</u></p>	DES:	INGENIERÍA
	Programa académico	Ingeniería en Computación
	Tipo de materia (Obli/Opta):	Obligatoria
	Clave de la materia:	MC602
	Semestre:	Sexto
	Área en plan de estudios:	Específica
	Total de horas por semana:	7
	<i>Teoría: Presencial o Virtual</i>	5
	<i>Laboratorio o Taller:</i>	0
	<i>Prácticas:</i>	0
	<i>Trabajo extra-clase:</i>	2
	Créditos Totales:	7
	Total de horas semestre (x sem):	112
	Fecha de actualización:	Octubre 2024
<i>Prerrequisito (s):</i>	N/A	

DESCRIPCIÓN:

La materia tiene como propósito introducir a los estudiantes en los conceptos fundamentales de Machine Learning para el análisis de datos. A través de explicaciones teóricas y prácticas guiadas, los estudiantes desarrollarán una comprensión de los diferentes tipos de algoritmos, cómo se entrenan y evalúan, y cómo se pueden aplicar para extraer información de conjuntos de datos. Al final del curso, los estudiantes estarán familiarizados con librerías de Python como TensorFlow y scikit-learn, y serán capaces de implementar modelos básicos de clasificación, regresión y agrupamiento. El enfoque será equilibrar la teoría con la práctica, para que los estudiantes adquieran habilidades en el pre procesamiento de datos, entrenamiento de modelos, evaluación y optimización.

COMPETENCIAS PARA DESARROLLAR:

B4. Transformación Digital

Transforma la cultura digital en la sociedad, en las organizaciones e instituciones educativas para aprovechar al máximo el potencial de las tecnologías y herramientas digitales; propiciar su uso responsable y ético que estimule la creatividad, innovación, la comunicación efectiva y el trabajo colaborativo e interdisciplinar en la solución de problemas de la sociedad digital; promoviendo la privacidad y la seguridad, así como el respeto a los derechos de autor y la propiedad intelectual.

P2. Desarrollo de Proyectos de Ingeniería. Desarrolla proyectos de ingeniería complejos en sus etapas de planeación, análisis y diseño, utilizando las tecnologías y los principios de la administración para la optimización de los recursos con base en procesos de calidad, mejora continua y teniendo en cuenta la seguridad, el costo del ciclo de vida, el carbono neto cero y la salud según sea necesario, atendiendo las necesidades de sostenibilidad.

E3. Inteligencia Artificial y Análisis de Datos. Se desarrolla en el campo de la inteligencia artificial y el análisis de datos, aplicando algoritmos de aprendizaje automático y herramientas de Big Data para generar perspectivas significativas y soluciones innovadoras. Engloba la habilidad para manejar y analizar grandes volúmenes de datos, así como la creatividad para aplicar la IA en la solución de problemas y desafíos contemporáneos en diversos sectores.

DOMINIOS	OBJETOS DE ESTUDIO	RESULTADOS DE APRENDIZAJE (Se plantean de los dominios y contenidos)	METODOLOGÍA (Estrategias, secuencias, recursos didácticos)	EVIDENCIAS (Productos tangibles que permiten valorar los resultados de aprendizaje)
<p>P2 DPI. Desarrollo de Proyectos de Ingeniería.</p> <p>3. Identifica los principales factores involucrados en la solución de problemas de ingeniería para desarrollar propuestas utilizando herramientas de ciencias básicas e ingeniería aplicada.</p> <p>E3 IAD. Inteligencia Artificial y Análisis de Datos.</p> <p>1. Aplicar técnicas de aprendizaje automático y procesamiento de datos para desarrollar soluciones en el campo de la inteligencia artificial.</p>	<p>UNIDAD I. INTRODUCCIÓN AL MACHINE LEARNING</p> <p>1.1. Tipos de aprendizaje.</p> <p>1.2. Generación de conjuntos de entrenamiento, validación y prueba.</p> <p>1.3. Estratificación de datos.</p> <p>1.4. Métricas de evaluación de modelos supervisados.</p> <p>1.5. Validación cruzada.</p>	<p>Entiende los diferentes tipos de aprendizaje en modelos de machine learning, comprende la correcta realización de la partición de datos y las métricas de evaluación que comúnmente se utilizan para medir el desempeño de los modelos.</p>	<p>1. Para cada tema, se presenta una introducción por parte del maestro apoyándose de un lenguaje de programación (python) para explicar su implementación en código.</p> <p>2. En algunos temas, el maestro deja una tarea donde se aplican los conceptos vistos en clase para la resolución de problemas.</p> <p>La tarea requiere que el alumno revise las técnicas y conceptos vistos en clase, aclare dudas y aplique las técnicas ya sea manualmente o las implemente utilizando un lenguaje de programación.</p>	<p>Tareas Exámenes Ponencias</p>
	<p>UNIDAD II. REDES NEURONALES ARTIFICIALES</p> <p>2.1. La neurona de McCulloch y Pitts.</p> <p>2.2. El perceptrón.</p> <p>2.3. Funciones de activación.</p>	<p>Implementa modelos de redes neuronales perceptrón multicapa utilizando diferentes funciones de activación, funciones de pérdida, optimizadores,</p>		

<p>B4.1 Desarrolla habilidades digitales de forma crítica que impacten positivamente en la vida cotidiana y en las organizaciones e instituciones para la comunicación efectiva en entornos digitales.</p>	<p>2.4. Backpropagation. 2.5. Funciones de pérdida. 2.6. Optimizadores. 2.7. Perceptrón multicapa.</p>	<p>realizando ajustes en el número de neuronas en el modelo para explorar y adaptar eficazmente su arquitectura</p>		
	<p>UNIDAD III. APENDIZAJE PROBABILÍSTICO 3.1. Modelos de mezcla gaussiana. 3.2. K vecinos cercanos.</p>	<p>Implementa modelos probabilísticos y compara su desempeño usando datos conocidos</p>		
	<p>UNIDAD IV. SUPPORT VECTOR MACHINE 4.1. Hiperplano de separación y margen. 4.2. Vectores de soporte. 4.3. Truco kernel para conjuntos no separables linealmente.</p>	<p>Comprende y aplica conceptos relacionados con SVM para lograr buenos resultados con conjuntos de datos que no son linealmente separables</p>		
	<p>UNIDAD V. ALGORITMOS DE ENSAMBLE 5.1. Árbol de Decisión como clasificador o regresor. 5.2. Algoritmos de metodología bagging. 5.3. Algoritmos de metodología Boosting. 5.4. Metamodelos. 5.5. Algoritmos de metodología Stacking.</p>	<p>Implementa modelos basados en algoritmos de ensamble, desde árboles de decisión hasta la construcción de metamodelos y técnicas de stacking</p>		
	<p>UNIDAD VI. ALGORITMOS DE APRENDIZAJE NO SUPERVISADO 1.1. Principal Components Analysis. 1.2. K-medias. 1.3. Kernel K-medias. 1.4. DBSCAN 6.5 Métricas de evaluación para modelos no supervisados.</p>	<p>Conoce e implementa diferentes algoritmos de aprendizaje no supervisado y los evalúa utilizando métricas apropiadas.</p>		

FUENTES DE INFORMACIÓN (Bibliografía, direcciones electrónicas)	EVALUACIÓN DE LOS APRENDIZAJES (Criterios, ponderación e instrumentos)
<ul style="list-style-type: none"> Wheeler, J. P. (2023). <i>An Introduction to Optimization with Applications in Machine Learning and Data Analytics</i>. CRC Press. ISBN: 9780367425500 Chen, Z., & Liu, B. (2022). <i>Lifelong machine learning</i> (2nd ed., reprinted). Springer Nature. ISBN 9783031004537. Deisenroth, M. P., Faisal, A. A., & Ong, C. S. (2020). <i>Mathematics for machine learning</i> (Illustrated ed.). Cambridge University Press. ISBN 978-1108470049. Marsland, S. (2011). <i>Machine learning: an algorithmic perspective</i>. Chapman and Hall/CRC. Bishop, C. (2006). <i>Pattern recognition and machine learning</i>. Springer google scholar, 2, 531-537. 	<p>Parcial 1 (30%)</p> <ul style="list-style-type: none"> Tareas. (50%) Examen. (50%) <p>Parcial 2 (30%)</p> <ul style="list-style-type: none"> Tareas. (50%) Examen. (50%) <p>Parcial 3 (40%)</p> <ul style="list-style-type: none"> Tareas. (50%) Proyecto. (50%) <p>Criterios de evaluación: Repositorio con scripts y cuadernos virtuales con actividades y tareas de clase. Exposición de un proyecto final de clase donde se utilicen los conocimientos adquiridos durante el curso con sección de preguntas y respuestas.</p> <p>Instrumentos: Listas de cotejo. Rúbricas de evaluación para la exposición</p> <p>La calificación mínima es 7.0.</p> <p>Se usará rúbrica para la entrega de actividades o tareas a realizar.</p>

CRONOGRAMA

Objetos de estudio	Semanas																
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	
INTRODUCCIÓN AL MACHINE LEARNING																	
REDES NEURONALES ARTIFICIALES																	
APRENDIZAJE PROBABILÍSTICO																	
SUPPORT VECTOR MACHINE																	
ALGORITMOS DE ENSAMBLE																	
ALGORITMOS DE APRENDIZAJE NO SUPERVISADO																	