

<p style="text-align: center;">UNIVERSIDAD AUTÓNOMA DE CHIHUAHUA</p>  <p style="text-align: center;">FACULTAD DE INGENIERÍA</p> <p style="text-align: center;">PROGRAMA ANALÍTICO DE LA UNIDAD DE APRENDIZAJE:</p> <p style="text-align: center;">REDES NEURONALES</p>	DES:	Ingeniería
	Programa académico	Doctorado en Ingeniería
	Tipo de materia (Obli/Opta):	Optativa
	Clave de la materia:	DI24OP26
	Semestre:	1, 2, 3
	Área en plan de estudios (B, P y E):	G, E
	Total de horas por semana:	4
	<i>Teoría: Presencial o Virtual</i>	2
	<i>Laboratorio o Taller:</i>	0
	<i>Prácticas:</i>	2
	<i>Trabajo extra-clase:</i>	6
	Créditos Totales:	10
	Total de horas semestre (x 16 sem):	160
	Fecha de actualización:	Marzo 2024
<i>Prerrequisito (s):</i>	Ninguno	
DESCRIPCIÓN DEL CURSO		
<p>El curso se centra en el análisis, evaluación y propuesta de diversas arquitecturas de redes neuronales, desde modelos básicos como el perceptrón multicapa hasta modelos más complejos que incluyen capas de convolución y modelos recurrentes. Se explorarán aplicaciones relacionadas con la visión por computadora y el procesamiento de lenguaje natural. Los participantes desarrollarán habilidades prácticas a través de proyectos aplicados, lo que les permitirá implementar modelos de redes neuronales en situaciones del mundo real. Además, se fomentará la comprensión crítica de la literatura científica relevante y la capacidad para adaptar y optimizar redes neuronales para diversos escenarios.</p> <p>La habilidad que se espera que el estudiante desarrolle le permitirá aplicar los conocimientos adquiridos en problemas computacionales en una variedad de contextos de aplicación, mejorando así sus habilidades cognitivas y su capacidad para resolver problemas en entornos del mundo real.</p>		
COMPETENCIAS A DESARROLLAR		
GESTIÓN DEL CONOCIMIENTO		
Demuestra conocimientos y habilidades para la búsqueda, análisis crítico, síntesis y procesamiento de información para su transformación en conocimiento, con actitud ética.		
INVESTIGACIÓN		
Desarrolla investigación original, tecnología y/o innovaciones en procesos, servicios o productos que contribuyan a la solución de problemas, mejoren la convivencia, generen oportunidades para el desarrollo sustentable y propicien una mejor calidad de vida.		
DISEÑO Y GESTIÓN DE INFRAESTRUCTURAS SOSTENIBLES PARA EL DESARROLLO		
Diseña y gestiona infraestructuras seguras, eficientes y sostenibles que promueven el desarrollo socioeconómico y ambiental, integrando conocimientos de áreas como infraestructura para el transporte, estructura y materiales, computación e hidrología. Este diseño y gestión considera la sostenibilidad en todos sus aspectos y se rige por altos estándares éticos y profesionales.		

DOMINIOS	OBJETOS DE ESTUDIO	RESULTADOS DE APRENDIZAJE	METODOLOGÍA	EVIDENCIAS
<p>Analiza y recupera información pertinente mediante diversas estrategias de búsqueda de datos científicos</p> <p>Gestiona, almacena, organiza y categoriza la información de manera que se traduzca en conocimiento</p> <p>Desarrolla el pensamiento científico y humanista con base en los fundamentos epistemológicos de la investigación</p> <p>Asume una actitud ética al procesar la información derivada de los resultados de investigación</p> <p>Análisis Integral de Requerimientos de Infraestructura</p> <p>Aplicación de Criterios y Reglamentos de Diseño Sostenible</p> <p>Uso Eficiente de Tecnologías y Herramientas Especializadas</p>	<p>1. Redes Neuronales</p> <p>1.1 Manejo de diferentes tipos de datos</p> <p>1.1.1 Pre-procesamiento de datos</p> <p>1.1.2 Manejo de datos faltantes</p> <p>1.1.3 Partición de datos</p> <p>1.2 Aprendizaje Supervisado y No Supervisado</p> <p>1.3 Algoritmos de Optimización</p> <p>1.3.1 Mini-batch GD</p> <p>1.3.2 GD con momentum</p> <p>1.3.3 RMSprop</p> <p>1.3.4 Adam</p> <p>1.4 Evaluación del modelo</p> <p>1.4.1 Validación cruzada</p> <p>1.4.2 Ajuste de hiperparámetros. Fine-Tune</p> <p>1.4.3 Métricas de desempeño</p> <p>1.4.4 Underfitting / overfitting</p> <p>1.5 Técnicas de Regularización</p> <p>1.5.1 Dropout</p>	<p>Los estudiantes serán capaces de comprender y aplicar técnicas de pre-procesamiento de datos para diferentes tipos de conjuntos de datos, incluyendo el manejo de datos faltantes y la partición de datos.</p> <p>Los estudiantes serán capaces de implementar modelos de aprendizaje supervisado y no supervisado utilizando diferentes algoritmos de optimización, como mini-batch GD, GD con momentum, RMSprop y Adam.</p> <p>Los estudiantes serán capaces de evaluar el desempeño de los modelos de redes neuronales utilizando técnicas como validación cruzada, ajuste de hiperparámetros y métricas de desempeño.</p> <p>Los estudiantes serán capaces de aplicar técnicas de regularización, como dropout, weight decay y early stopping, para evitar el sobreajuste de los modelos.</p> <p>Los estudiantes serán capaces de construir y entrenar modelos de aprendizaje profundo para problemas de</p>	<p>Estrategias:</p> <p>Clases magistrales para introducir los conceptos fundamentales de pre-procesamiento de datos, algoritmos de optimización y evaluación de modelos.</p> <p>Sesiones prácticas donde los estudiantes implementarán los diferentes algoritmos y técnicas utilizando bibliotecas de aprendizaje profundo como TensorFlow o PyTorch.</p> <p>Discusiones grupales para analizar casos de estudio y aplicaciones de los modelos de redes neuronales en problemas del mundo real.</p> <p>Secuencias:</p> <p>Introducción teórica a los conceptos de pre-procesamiento de datos y algoritmos de optimización.</p> <p>Prácticas guiadas para el manejo de datos y la implementación de modelos de aprendizaje supervisado y no supervisado.</p> <p>Sesiones de laboratorio para la evaluación del desempeño de los modelos y la aplicación de técnicas de regularización.</p>	<p>Implementación de pre-procesamiento de datos:</p> <p>Informes detallados que describen el proceso de limpieza y transformación de datos, junto con el código utilizado para realizar estas tareas.</p> <p>Conjuntos de datos pre-procesados y listos para su uso en modelos de redes neuronales.</p> <p>Modelos de aprendizaje supervisado y no supervisado:</p> <p>Resultados de entrenamiento y evaluación de modelos de aprendizaje supervisado (clasificación o regresión) y no supervisado (clustering).</p> <p>Análisis de desempeño de los modelos, incluyendo métricas de precisión, sensibilidad, especificidad, entre otras.</p> <p>Evaluación de técnicas de optimización y regularización:</p> <p>Comparación de diferentes algoritmos de optimización (Mini-</p>

	<p>1.5.2 Weight decay</p> <p>1.5.3 Early Stopping</p>	<p>clasificación y regresión, incluyendo redes CNN, RNN y redes no supervisadas como autoencoders y redes GAN.</p>	<p>Recursos Didácticos:</p> <p>Presentaciones interactivas que resumen los conceptos clave de cada tema.</p> <p>Notebooks de Jupyter con ejemplos de código y ejercicios prácticos.</p> <p>Conjuntos de datos de ejemplo para realizar experimentos y prácticas.</p> <p>Material de lectura complementario, incluyendo artículos científicos y tutoriales en línea sobre redes neuronales y aprendizaje profundo.</p>	<p>batch GD, Adam, etc.) mediante gráficos de convergencia y análisis de tiempos de entrenamiento.</p> <p>Análisis del efecto de técnicas de regularización (dropout, weight decay, etc.) en la mitigación del sobreajuste.</p>
<p>Analiza y recupera información pertinente mediante diversas estrategias de búsqueda de datos científicos</p> <p>Gestiona, almacena, organiza y categoriza la información de manera que se traduzca en conocimiento</p> <p>Desarrolla el pensamiento científico y humanista con base en los fundamentos epistemológicos de la investigación</p> <p>Asume una actitud ética al procesar la información derivada de los resultados de investigación</p>	<p>2. Modelos de Aprendizaje Profundo para problemas de clasificación y regresión</p> <p>2.1 Redes CNN</p> <p>2.1.1 Tipos de convoluciones</p> <p>2.1.2 Batch Normalization</p> <p>2.1.3 Bloques Residuales</p> <p>2.1.4 Forward y Backpropagation en CNN</p> <p>2.1.5 Arquitecturas CNN</p> <p>2.1.6 Transferencia de aprendizaje. Ajuste fino.</p>	<p>Los estudiantes serán capaces de comprender los principios fundamentales de las redes neuronales convolucionales (CNN) y recurrentes (RNN) y aplicarlos en problemas de clasificación y regresión.</p> <p>Los estudiantes serán capaces de implementar diferentes arquitecturas de redes CNN y RNN, incluyendo el manejo de tipos de convoluciones, batch normalization, bloques residuales y transferencia de aprendizaje.</p> <p>Los estudiantes serán capaces de explicar</p>	<p>Estrategias:</p> <p>Conferencias introductorias para presentar los principios de las redes neuronales convolucionales (CNN) y recurrentes (RNN).</p> <p>Talleres prácticos donde los estudiantes implementarán diferentes arquitecturas de redes CNN y RNN utilizando frameworks como Keras.</p> <p>Sesiones de resolución de problemas para abordar desafíos específicos en la implementación y entrenamiento de</p>	<p>Implementación de redes neuronales convolucionales (CNN) y recurrentes (RNN):</p> <p>Desarrollo de modelos CNN para tareas de clasificación de imágenes, con reportes detallados sobre la arquitectura de la red, hiperparámetros utilizados y resultados obtenidos.</p> <p>Implementación de modelos RNN para problemas de procesamiento de secuencias, como el análisis de sentimientos o la</p>

<p>Análisis Integral de Requerimientos de Infraestructura</p> <p>Aplicación de Criterios y Reglamentos de Diseño Sostenible</p> <p>Uso Eficiente de Tecnologías y Herramientas Especializadas</p>	<p>2.1.7 Visualización de mapas de activación</p> <p>2.2 Redes Recurrentes RNN</p> <p>2.2.1 Arquitecturas</p> <p>2.2.2 Forward y Backpropagation en RNN</p> <p>2.2.3 LSTz</p> <p>2.3 Redes No Supervisadas</p> <p>2.3.1 Autoencoders</p> <p>2.3.2 Redes GAN</p>	<p>los conceptos de forward y backpropagation en CNN y RNN, así como el funcionamiento de técnicas de regularización como LSTz.</p> <p>Los estudiantes serán capaces de utilizar modelos de aprendizaje profundo para realizar tareas de clasificación y regresión en conjuntos de datos del mundo real.</p> <p>Los estudiantes serán capaces de visualizar y analizar los mapas de activación generados por las capas ocultas de las redes CNN y RNN.</p>	<p>modelos de aprendizaje profundo.</p> <p>Secuencias:</p> <p>Introducción teórica a las redes CNN y RNN, incluyendo sus aplicaciones en problemas de clasificación y regresión.</p> <p>Prácticas guiadas para la implementación de arquitecturas de redes CNN y RNN utilizando conjuntos de datos reales.</p> <p>Sesiones de laboratorio para la visualización y análisis de los resultados obtenidos con los modelos entrenados.</p> <p>Recursos Didácticos:</p> <p>Presentaciones interactivas con ejemplos visuales de arquitecturas de redes CNN y RNN.</p> <p>Notebooks de Jupyter con código de implementación de modelos y ejercicios prácticos.</p> <p>Conjuntos de datos públicos y herramientas de visualización para facilitar la experimentación y el análisis de resultados.</p>	<p>predicción de series temporales.</p> <p>Transferencia de aprendizaje y ajuste fino:</p> <p>Evaluación del desempeño de modelos pre-entrenados mediante técnicas de transferencia de aprendizaje en nuevas tareas específicas.</p> <p>Informes que documentan el proceso de ajuste fino de modelos pre-entrenados en conjuntos de datos propios, junto con análisis comparativos de resultados.</p> <p>Visualización de resultados y análisis de errores:</p> <p>Representación visual de mapas de activación y características aprendidas por los modelos CNN.</p> <p>Identificación y análisis de errores cometidos por los modelos, con el fin de comprender sus limitaciones y proponer mejoras.</p>
---	---	--	--	--

FUENTES DE INFORMACIÓN	EVALUACIÓN DE LOS APRENDIZAJES
<ul style="list-style-type: none"> Goodfellow, I., Bengio, Y., & Courville, A. (2016). "Deep Learning." MIT Press. 	<p>Tareas 20%</p> <p>Reportes de investigación 20%</p>

<ul style="list-style-type: none"> • Zhang, Aston, Lipton, Zachary C., Li, Mu, & Smola, Alexander J. (2021). "Dive into Deep Learning." arXiv preprint arXiv:2106.11342. • Géron, A. (2019). "Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems" (2nd ed.). O'Reilly. • Müller, A. C., & Guido, S. (2016). "Introduction to Machine Learning with Python: A Guide for Beginners in Data Science" (1st ed.). O'Reilly. • Albon, Chris (2018). "Machine Learning with Python Cookbook: Practical Solutions from Preprocessing to Deep Learning" (1st ed.). O'Reilly.. 	<p>Ponencias 20%</p> <p>Trabajo final integrador 40%</p>
--	--

Cronograma del avance programático

Objetos de aprendizaje	Semanas															
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1. Representaciones textuales y espacios vectoriales.																
2. Modelos probabilísticos.																