

<p style="text-align: center;">UNIVERSIDAD AUTÓNOMA DE CHIHUAHUA</p>  <p style="text-align: center;">FACULTAD DE INGENIERÍA</p> <p>PROGRAMA ANALÍTICO DE LA UNIDAD DE APRENDIZAJE:</p> <p style="text-align: center;">VISIÓN POR COMPUTADORA</p>	DES:	Ingeniería
	Programa académico	Doctorado en Ingeniería
	Tipo de materia (Obli/Opta):	Optativa
	Clave de la materia:	DI24OP19
	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>	Redes Neuronales Artificiales	
DESCRIPCIÓN DEL CURSO		
<p>La visión por computadora se destaca como un área de investigación altamente dinámica, impulsada por los notables avances en diversas aplicaciones, como sistemas de seguridad, navegación automática, diagnóstico en imágenes médicas, entre otras áreas relevantes. En este curso, nos enfocaremos en el estudio e implementación de diversos modelos computacionales, centrándonos en aplicaciones de clasificación, segmentación y detección de imágenes mediante el empleo de modelos de aprendizaje profundo.</p> <p>Exploraremos diversas arquitecturas de redes neuronales con el objetivo de comprender a fondo las operaciones llevadas a cabo por el modelo computacional. A través de este análisis, buscaremos identificar oportunidades de mejora, enfocadas en la optimización de la carga computacional y la obtención de resultados más precisos y eficientes.</p> <p>El enfoque de este curso busca acoger la diversidad de perspectivas y experiencias, fomentando un ambiente de aprendizaje en donde el estudiante pueda desarrollar sus fortalezas cognitivas para aplicar lo estudiado en problemas computacionales para diferentes contextos de aplicación.</p>		
COMPETENCIAS A DESARROLLAR		
DISEÑO Y GESTIÓN DE INFRAESTRUCTURAS SOSTENIBLES PARA EL DESARROLLO		
<p>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.</p>		

DOMINIOS	OBJETOS DE ESTUDIO	RESULTADOS DE APRENDIZAJE	METODOLOGÍA	EVIDENCIAS
<p>Análisis Integral de Requerimientos de Infraestructura, Aplicación de Criterios y Reglamentos de Diseño Sostenible, Uso Eficiente de Tecnologías y Herramientas Especializadas</p>	<p>1. Procesamiento de imágenes</p> <p>1.1 Arquitectura de la corteza visual</p> <p>1.2 Modelos de color</p> <p>1.3 Pre-procesamiento de Imágenes</p> <p>1.3.1 Normalización y Estandarización</p> <p>1.3.2 Aumento de datos</p> <p>1.4 Extracción de características</p> <p>1.4.1 Local Binary Patterns</p> <p>1.4.2 Detector de puntos de interés. Harris</p> <p>1.4.3 SIFT: Scale-invariant feature transform</p>	<p>Los estudiantes serán capaces de identificar y explicar la arquitectura de la corteza visual en el procesamiento de imágenes.</p> <p>Los estudiantes podrán aplicar modelos de color en el análisis y procesamiento de imágenes.</p> <p>Los estudiantes demostrarán habilidades en el pre-procesamiento de imágenes, incluyendo la normalización, estandarización y aumento de datos.</p> <p>Los estudiantes serán capaces de realizar la extracción de características utilizando técnicas como Local Binary Patterns, Detector de puntos de interés (Harris) y SIFT.</p>	<p>Clases teóricas: Exposición de conceptos fundamentales del procesamiento de imágenes mediante presentaciones interactivas.</p> <p>Prácticas guiadas: Ejercicios prácticos en laboratorio para aplicar los conceptos aprendidos utilizando herramientas de procesamiento de imágenes.</p> <p>Estudio de casos: Análisis de casos reales de aplicación del procesamiento de imágenes en diversas áreas como medicina, seguridad, entretenimiento, etc.</p> <p>Secuencia: Introducción al procesamiento de imágenes. Arquitectura de la corteza visual y modelos de color. Pre-procesamiento de imágenes: normalización, estandarización y aumento de datos. Extracción de características: Local Binary Patterns, Detector de puntos de interés (Harris), SIFT.</p> <p>Recursos didácticos: Presentaciones multimedia. Herramientas de procesamiento de imágenes (por ejemplo, OpenCV).</p> <p>Material de lectura complementaria (libros, artículos)</p>	<p>Informe de laboratorio: Los estudiantes deberán presentar un informe detallado de las prácticas realizadas en laboratorio, describiendo los pasos seguidos, los resultados obtenidos y las conclusiones alcanzadas.</p> <p>Implementación de algoritmos: Los estudiantes deberán desarrollar y presentar la implementación de al menos un algoritmo de pre-procesamiento de imágenes y otro de extracción de características, demostrando su comprensión y habilidades en la aplicación práctica de los conceptos aprendidos.</p>

			científicos).	
Análisis Integral de Requerimientos de Infraestructura, Aplicación de Criterios y Reglamentos de Diseño Sostenible, Uso Eficiente de Tecnologías y Herramientas Especializadas	<p>2. Detección de objetos en imágenes</p> <p>2.1 Annotations, bounding box, información del ground truth</p> <p>2.2 Métricas</p> <p>2.3 Funciones de loss</p> <p>2.4 Bases de datos</p> <p>2.5 Detectores de dos etapas</p> <p>2.5.1 R-CNN</p> <p>2.5.2 Fast R-CNN</p> <p>2.5.3 Faster R-CNN</p> <p>2.5.4 Mask R-CNN</p> <p>2.6 Detectores de una etapa</p> <p>2.6.1 Efficient-Det</p> <p>2.7 Análisis de parámetros en las arquitecturas</p> <p>2.7.1 Reducción de parámetros</p>	<p>Los estudiantes serán capaces de comprender y aplicar conceptos relacionados con la detección de objetos en imágenes, incluyendo annotations, bounding box, y ground truth.</p> <p>Los estudiantes podrán utilizar diversas métricas y funciones de loss para evaluar algoritmos de detección de objetos.</p> <p>Los estudiantes serán capaces de describir y comparar distintas arquitecturas de detección de objetos, incluyendo detectores de dos etapas (R-CNN, Fast R-CNN, Faster R-CNN, Mask R-CNN) y detectores de una etapa (Efficient-Det).</p> <p>Los estudiantes podrán analizar parámetros en las arquitecturas de detección de objetos para optimizar el rendimiento del modelo.</p>	<p>Estrategias:</p> <p>Clases teóricas: Explicación de conceptos fundamentales de detección de objetos y revisión de arquitecturas de modelos.</p> <p>Prácticas guiadas: Implementación de algoritmos de detección de objetos utilizando bibliotecas de aprendizaje profundo.</p> <p>Estudio de casos: Análisis de aplicaciones prácticas de detección de objetos en diferentes campos.</p> <p>Secuencia: Fundamentos de detección de objetos. Anotaciones, bounding box y ground truth. Métricas y funciones de loss. Arquitecturas de detección de objetos.</p> <p>Recursos didácticos: Material de lectura recomendado. Ejemplos de código.</p> <p>Bases de datos de imágenes etiquetadas.</p>	<p>Evaluación de modelos: Los estudiantes deberán entrenar varios modelos de detección de objetos utilizando conjuntos de datos específicos y evaluar su desempeño utilizando métricas relevantes como precisión, recall y F1-score.</p> <p>Informe de aplicación: Los estudiantes deberán seleccionar un caso de aplicación de detección de objetos en el mundo real y elaborar un informe detallado que describa el problema, la metodología utilizada, los resultados obtenidos y las posibles mejoras.</p>
Análisis Integral de Requerimientos de Infraestructura, Aplicación de Criterios y Reglamentos de Diseño Sostenible, Uso Eficiente de Tecnologías y	<p>3. Segmentación de objetos en imágenes</p> <p>3.1 Segmentación semántica</p> <p>3.2 Annotations, información del ground truth</p> <p>3.3 Métricas</p>	<p>Los estudiantes serán capaces de entender y aplicar técnicas de segmentación semántica en el procesamiento de imágenes.</p> <p>Los estudiantes podrán trabajar con</p>	<p>Estrategias:</p> <p>Clases teóricas: Presentación de técnicas y algoritmos de segmentación de objetos.</p> <p>Prácticas guiadas: Implementación de modelos de segmentación</p>	<p>Implementación de modelos: Los estudiantes deberán implementar al menos un modelo de segmentación de objetos utilizando alguna de las arquitecturas estudiadas en clase</p>

<p>Herramientas Especializadas</p>	<p>3.4 Funciones de loss</p> <p>3.5 Arquitecturas de redes enfocadas a segmentación</p> <p> 3.5.1 Redes FCN</p> <p> 3.5.2 Encoder-Decoder</p> <p>3.6 Análisis de parámetros en las arquitecturas</p> <p> 3.6.1 Reducción de parámetros</p>	<p>annotations y ground truth para la segmentación de objetos en imágenes.</p> <p>Los estudiantes demostrarán habilidades en la evaluación de modelos de segmentación utilizando métricas y funciones de loss.</p> <p>Los estudiantes serán capaces de describir y comparar diferentes arquitecturas de redes neuronales enfocadas a la segmentación, como las Redes FCN y Encoder-Decoder.</p> <p>Los estudiantes podrán analizar parámetros en las arquitecturas de segmentación para optimizar el rendimiento del modelo.</p>	<p>utilizando frameworks de aprendizaje profundo.</p> <p>Estudio de casos: Revisión de aplicaciones prácticas de segmentación en diversas áreas.</p> <p>Secuencia: Introducción a la segmentación de objetos. Segmentación semántica y otras técnicas. Evaluación de modelos: métricas y funciones de loss. Arquitecturas de redes neuronales para segmentación.</p> <p>Recursos didácticos: Material de lectura complementaria. Entornos de desarrollo para ejecución de código.</p> <p>Conjuntos de datos etiquetados para entrenamiento y evaluación de modelos.</p>	<p>y aplicarlo a un conjunto de datos de prueba.</p> <p>Presentación de resultados: Los estudiantes deberán preparar una presentación en la que muestren los resultados de la segmentación obtenidos, discutan su efectividad y propongan posibles mejoras o aplicaciones adicionales.</p>
------------------------------------	---	--	---	--

FUENTES DE INFORMACIÓN	EVALUACIÓN DE LOS APRENDIZAJES
<ul style="list-style-type: none"> Valliappa Lakshmanan, Martin Görner & Ryan Gillard (2021). Practical Machine Learning for Computer Vision End-to-End Machine Learning for Images. O'Reilly Richard Szeliski (2023). Computer Vision Algorithms and Applications. doi.org/10.1007/978-3-030-34372-9. ISSN 1868-0941. 2nd Edition. Springer Cham. Rafael C. Gonzales, Richard E. Woods. (2007) Digital Image Processing. 3rd Edition. ISBN 013168728X. Pearson 	<ul style="list-style-type: none"> - Tareas 30% - Examen 30% - Trabajo final integrador 40% <p>Propone una contribución a una arquitectura de red neuronal enfocada a problemas de segmentación y/o, detección y la evalúa contra modelos existentes considerando las diferentes métricas utilizadas en el estado del arte explicando las ventajas del modelo propuesto. Todo esto utilizando datos relacionados con su tema de investigación.</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. Procesamiento de Imágenes																
2. Detección de objetos en imágenes																
3. Segmentación de objetos en imágenes																