




Formato para registro de Unidades de aprendizaje 2021

INSTRUCTIVO para el correcto llenado del formato SIP-30

- El formato SIP-30 es un formato digital el cual puede ser completado con un procesador de texto y guardarse como archivo PDF para su envío.
- Adicionalmente será necesario anexar la solicitud firmada por el director de la Unidad Académica respectiva y el acuerdo de Colegio donde se avaló su registro; tenga listos los archivos al momento de ingresar su solicitud en el formulario en línea.
- El enlace de atención única para esta y otras gestiones es: <https://forms.office.com/r/c8DLS6VBv1> (copie y pegue en un navegador web si el enlace no funciona)
- Tome en cuenta los criterios establecidos en el Reglamento de Estudios de Posgrado ([REP 2017](#)) para el llenado de este formato, a continuación se presentan algunas definiciones útiles:
 - *Número de semanas por semestre del programa*: Es el número de semanas lectivas efectivas al semestre, indicadas en el acuerdo de creación del programa académico o en alguna actualización posterior del programa. En caso de haber tenido una actualización en este sentido, la misma deberá haber sido presentada y avalada en reunión del Colegio de Profesores de la Unidad Académica, además de haber sido aprobada por la SIP. El rango de semanas lectivas al semestre es mínimo 15 y máximo 18.
 - *Tipo de horas*: Las unidades de aprendizaje, en cuanto a las horas asignadas, están clasificadas como: Teóricas, Prácticas y Teórico-prácticas. Estas denominaciones son excluyentes, es decir, las unidades de aprendizaje solo pueden ser de un solo tipo, no pueden tener horas combinadas.
 - *Número de horas – semana*: Es el número de horas asignadas para ser impartida la Unidad de Aprendizaje a la semana.
 - *Total de horas al semestre*: Es el número de horas totales a impartir de la Unidad de Aprendizaje al semestre. Se calcula multiplicando Número de semanas por número de horas-semana.
 - *Créditos* (Reglamento de Estudios de Posgrado 2017): FÓRMULA DE CÁLCULO: $16 \text{ hrs.} = 1 \text{ crédito}$ (horas totales / 16), no deben asignarse fracciones, los créditos deben redondearse a número entero.
- Para el registro de unidades de aprendizaje de modalidad no escolarizada o mixta incluya adicionalmente los campos marcados con el color azul
- En todos los campos existen comentarios en forma de  globo que sirven de ayuda para el requisitado correspondiente, en caso de duda solicite apoyo del asesor didáctico de la UTEyCV de su Unidad Académica.



Formato para registro de Unidades de aprendizaje 2021

I.- Datos de identificación de la unidad de aprendizaje

Unidad académica:	Centro de Investigación en Computación										
Programa académico:	Maestría en Ciencias de la Computación										
	<input type="checkbox"/>	Doctorado				<input type="checkbox"/>	Orientación profesional				
	<input checked="" type="checkbox"/>	Maestría				<input checked="" type="checkbox"/>	Orientado a la investigación				
	<input type="checkbox"/>	Especialidad				<input type="checkbox"/>	Con la industria				
	<input type="checkbox"/>					<input type="checkbox"/>	Especialidad médica				
Sesión de colegio donde se propuso:	15/10/2021				Fecha de propuesta:	04/10/2021					
Nombre de unidad de aprendizaje:	Aprendizaje automático por medio de grafos										
Clave de la unidad de aprendizaje:					Créditos:	5		<i>REP 2017</i>			
Semanas del semestre	18		Horas a la semana:		4		Horas totales:		72		
Tipo de unidad de aprendizaje:	Obligatoria:		Optativa:		<input checked="" type="checkbox"/>		Observaciones:				
Semestre:											
Teórica (%):	100		Práctica (%):				Teórico-prácticas (%):				
Área del conocimiento:	Ingeniería y Ciencias Fisicomatemáticas		<input checked="" type="checkbox"/>		Ciencias Sociales y Administrativas		Ciencias Médico Biológicas		Interdisciplinario		
Modalidad no escolarizada:	No escolarizada				Nombre de la Plataforma:						
Horas establecidas en el programa de estudios:	Mixta		Presencial (%):				En plataforma (%):				
	Presenciales (si procede) (horas x semana)						En plataforma (horas x semana):				



Formato para registro de Unidades de aprendizaje 2021

I. Aprendizajes que el estudiante deberá demostrar al finalizar

Conocimientos	Habilidades y destrezas	Actitudes y valores
<ul style="list-style-type: none">• Sabrá transformar una colección de objetos (un «dataset») en un grafo, con atributos en los nodos y en las aristas del grafo.• Sabrá hacer minería de datos sobre un conjunto de datos que contiene relaciones entre los objetos, usando la teoría de grafos• Aplicará las técnicas de la Ciencia de Datos, el aprendizaje mecánico y la Inteligencia Artificial, a bases de datos enriquecidas con las relaciones entre los objetos.• Encontrará conjuntos de objetos frecuentes, objetos análogos, reglas de asociación, tendencias, desviaciones y anomalías, en un conjunto de objetos que pueden contener relaciones ente ellos.• Hará predicciones sobre nuevos objetos, nuevos atributos, nuevas relaciones y nuevos datasets, dados los objetos existentes	<ul style="list-style-type: none">• Podrá generar nuevas relaciones entre objetos existentes.• Dado un objeto con atributos desconocidos o incompletos, podrá predecir valores probables para atributos faltantes, usando la similitud de ese objeto con otros ligados a él.• Podrá predecir nuevas relaciones entre dos objetos, dada la existencia de tales relaciones entre objetos actuales similares.• Podrá usar redes neuronales para predecir las propiedades y relaciones sobre un nuevo dataset, al llevar a cabo aprendizaje mecánico sobre datasets similares	<ul style="list-style-type: none">• Observación crítica de los objetos que se consideran, sus atributos y las relaciones con otros objetos cercanos.• Obtendrá mayor poder de abstracción.• Interacción con personas expertas en los objetos bajo estudio y sus cualidades, que dominan áreas que los datasets cubren

Resolución que aborda la propuesta con su enfoque disciplinar

El curso extiende las capacidades del Aprendizaje Mecánico “convencional”, que considera a los objetos bajo estudio como elementos aislados que no se relacionan entre sí. El curso modela estas relaciones como aristas de un grafo, para poder aplicar la teoría de grafos, además de las redes neuronales y otras herramientas del aprendizaje mecánico, al conjunto de objetos considerando las relaciones y afinidades entre tales objetos. Con esto se obtiene un mayor poderío para generalizar, aprender y predecir. El curso es especialmente útil para informáticos que tienen que hacer predicciones, extrapolaciones y extensiones al conocimiento operativo actual. Es decir, informáticos ligados a las áreas de Planeación, Gerencia media y superior, y en general para la toma de decisiones tácticas y estratégicas



Formato para registro de Unidades de aprendizaje 2021

II. Proximidad formativa

Áreas multi, inter y transdisciplinarias

Líneas de Generación y Aplicación de Conocimiento

Sectores sociales

<ul style="list-style-type: none">• Computación.• Representación de la información.• Matemáticas discretas.• Álgebra lineal.• Teoría de grafos	<ul style="list-style-type: none">• Ciencia y tecnología de la información	<ul style="list-style-type: none">• Los conocimientos, habilidades y destrezas adquiridos en el curso serán de gran ayuda a los tomadores de decisiones a nivel medio y superior. Inteligencia de negocios, gerentes, supervisores, políticos y gobernantes.
--	--	--

Estrategia de asociación:

El tomador de decisiones facilitará al estudiante una gran cantidad de datos, así como el problema o cuestión a resolver. El estudiante aplicará las técnicas aprendidas en este curso para hallar soluciones y mostrarlas de manera que el tomador de decisiones pueda entenderlas fácilmente. Mientras obtiene la solución al problema, el estudiante abordará al tomador de decisiones exponiéndole dudas sobre ciertos atributos de los objetos, o de las aristas, buscando taxonomías entre esos atributos. Al indagar la correlación entre atributos de los objetos o de las aristas, el estudiante propondrá al tomador de decisiones la simplificación de ciertos atributos (generalización, abstracción, eliminación, selección de un subconjunto de atributos, formación de nuevos atributos que engloban atributos actuales...), para concentrar la información en pocos atributos relevantes.



Formato para registro de Unidades de aprendizaje 2021

III Metodología de enseñanza – aprendizaje

Descripción

Evidencias como proceso de aprendizaje	Evidencias integradoras (resultados que contribuyen al curriculum)	Ponderación

IV. Descripción de la participación esperada en el estudiante

Receptiva	Resolutiva	Autónoma	Estratégica



Formato para registro de Unidades de aprendizaje 2021

Contenido temático

1. INTRODUCCIÓN. Conversión de bases de datos relacionales en grafos. Definición del Software que será usado.	2 Horas.
1.1 Aplicaciones. Grafos: nueva frontera del aprendizaje automático. Aprendizaje profundo con grafos	
2 MÉTODOS TRADICIONALES PARA EL APRENDIZAJE CON GRAFOS	2 Horas
2.1 Dado un grafo $G = (V, E)$, ¿Cómo predecir $f: V \rightarrow R^n$? ¿Cómo aprender f ?	
2.2 Encontrar representaciones útiles. Coeficiente de agrupamiento; Graphlets. Predicción de enlaces	
2.3 Potencias de la matriz de adyacencia. Funciones y núcleos de grafos: núcleo Weisfeiler-Lehman; refinamiento del color	
3 INMERSIONES DE NODOS	4 Horas
3.1 Codificadores, decodificadores, superficial y profundo. Aprendizaje de nodos inmersos. Enfoque de trayectorias aleatorias	
3.2 Aprendizaje de funciones como optimización. Muestreo negativo. Inmersiones de grafos	
3.3 Node2vec: Trayectorias con sesgo. Inmersión de grafos. Aprendiendo inmersiones de trayectorias	
4 GRAFOS COMO MATRIZ: PAGERANK, TRAYECTORIAS ALEATORIAS	6 Horas
4.1 Integraciones, distribución estacionaria, formulación de vector propio	
4.2 Métodos de iteración de potencia. Factorización de matrices y nodos inmersos	
5 PASO DE MENSAJES Y CLASIFICACIÓN DE NODOS	2 Horas
5.1 Clasificación relacional y clasificación iterativa. Propagación de la creencia. Algoritmo Loopy BP	
6 REDES NEURONALES DE GRAFOS (GNNs)	10 Horas
6.1 Introducción. Codificadores profundos de grafos.	
6.2 Principios de aprendizaje profundo	
6.2.1 Aprendizaje mecánico como optimización. Función objetiva. Función de pérdida	
6.2.2 Vector gradiente. Descenso de gradiente. Tasa de aprendizaje. Descenso de gradiente estocástico	
6.2.3 Función de red neuronal. Back propagation. Perceptrón multicapa.	
6.3 Aprendizaje profundo para grafos	
6.3.1 Vecindad de la red local. Apilamiento de múltiples capas. Redes convolucionales	
6.3.2 Redes convolucionales de grafos. Agregación de vecinos. Codificador profundo	
6.3.3 Formulación matricial. Cómo entrenar redes neuronales para grafos. Capacidad inductiva	
7 PERSPECTIVA GENERAL DE LAS REDES NEURONALES DE GRAFOS	5 Horas
7.1 Entorno general de los GNNs	
7.2 GNN de una sola capa	
7.2.1 Proceso de dos pasos: (1) mensaje; (2) agregación. GNN de una sola capa	
7.2.2 Redes convolucionales de grafos (GCN). Redes de atención de grafos (GAT). Mecanismo de atención	
7.2.3 Normalización por lotes. Caída. Activación. No linealidad. ReLU. Sigmoide. ReLU paramétrico	
7.3 Apilando capas de GNNs	
7.3.1 Construcción de una red neuronal de grafos. Suavizamiento excesivo. Campo receptivo. Salto de conexiones	
8 PREDICCIONES CON GNNs	8 Horas



Formato para registro de Unidades de aprendizaje 2021

8.1 GNN Aumento y entrenamiento	
8.2 Predicción con GNNs	
8.2.1 Rutas de entrenamiento de GNN. Gerarquias de predicción (nivel nodo, nivel de borde, nivel de grafo)	
8.2.2 Agrupación jerárquica. Tipos de entrenamiento de GNN. Supervisado vs No supervisado, etiquetas de grafos	
8.2.3 Señales no supervisadas. Clasificación o regresión. Pérdidas de regresión. Métricas de evaluación	
8.3 Configuración de tareas de predicción con GNN	
8.3.1 Ejemplos	
9 TEORÍA. CONFIGURACIÓN DE TAREAS DE PREDICCIÓN CON GNNs	6 Horas
9.1 GCN, GraphSAGE, Espacio de diseño. Diseño de GNN de alta expresividad	
9.2 Diseño de GNN mas potentes. Teorema de aproximación universal. Red de grafos isomórficos (GIN)	
9.3 Relación con el kernel de grafos WL. Modelo GIN completo. El poder de la agrupación.	
10 GRAFOS HETEROGÉNEOS	6 Horas
10.1 Grafos heterogéneos y Relacionales GCNs (RGCN)	
10.2 Escalabilidad de RGCNs. Matrices de bloques. Aplicaciones de los gráficos del conocimiento	
10.3 Modelado bilineal. Relaciones de composición. KG embebidos.	
11 RAZONAMIENTO EN GRAFOS DE CONOCIMIENTO	6 Horas
11.1 Respuestas con consultas de varios saltos. Rutas de consultas. Consultas conjuntivas. Query2box	
11.2 Trazado KG en espacio vectorial. Consultas AND-OR Embebidas. cuadros embebidas	
11.3 Proyección, intersección de operadores. Generación de consultas a partir de plantillas. Visualización. Espacios embebidos	
12 IDENTIFICACIÓN Y CONTEO DE MOTIVOS EN REDES	4 Horas
12.1 Redes de motivos. Significado y perfiles de motivos. Gráficos aleatorios ER. Coincidencia de subgrafos neuronales	
12.2 Arquitectura de subgrafos neuronales. Orden de incrustación. Entrenamiento de coincidencia de subgrafos neuronales. Búsqueda de subgrafos frecuentes	
13 DETECCIÓN DE COMUNIDADES EN REDES	4 Horas
13.1 Cierre triádico. Superposición de bordes vs fuerza. Comunidades de redes. Modelo nulo. Modularidad	
13.2 Algoritmo de Louvain Detección de comunidades sobrepuestas. Interacciones proteína-proteína.	
13.3 Modelo gráfico de afiliación comunitaria (AGM). Ajuste gráfico. AGM Holgado	
14 MODELOS GENERATIVOS PARA GRAFOS	2 Horas
14.1 Propiedades de los grafos del mundo real. El modelo del mundo pequeño. Modelo de gráfico de Kronecker	
14.2 Generación de gráficos recursivos. Gráficos estocásticos de Kronecker	
15 MODELOS GENERADORES PROFUNDOS PARA GRAFOS	1 hora
16 TEMAS AVANZADOS EN GRAFOS DE REDES NEURALES	1 hora
17 ESCALA DE GNN A GRAFOS GRANDES	1 hora
18 MARINKA ZITNIK. GNNs EN BIOLOGÍA COMPUTACIONAL	1 hora
19 GNNs EN CIENCIA	1 hora
Total de horas	72



Formato para registro de Unidades de aprendizaje 2021

V. Secuencia programática

No.	Tema	Objetivo de aprendizaje / competencia específica	Tiempo/Horas/Semanas	
Actividad(es):	No. Nombre de la actividad: Descripción de la actividad:		Tipo de interacción(es):	
			Referencias (s):	
Evidencia(s):				

Tipo de interacción: ID–Instrucción directa, TC–Trabajo colaborativo, AC–Análisis en campo, RP–Reflexión personal, PE–Presentación expositiva

Indicar solo el número de las *Referencias* indizadas en la sección VII de este documento.

Nota: Replique esta sección las veces que sea necesario para cubrir toda la secuencia programática

VI. Habilitadores tecnológicos

Disposiciones	Especificaciones / descripción de efectos
Conectividad	
Habilidades digitales	
Interoperabilidad	
Datos abiertos	
<i>Big Data</i>	
<i>Machine Learning</i>	
Simulación	
Realidad aumentada	
Otro...	

VII. Referencias



Formato para registro de Unidades de aprendizaje 2021

Conferencias magistrales

No se contemplan en este curso

Notas complementarias

Documentales / electrónicas

1. Graph representation learning. William L. Hamilton. Morgan & Clauton Publishers. 2020
2. Deep learning. Ian Goodfellow, Yoshua Bengio, Aaron Courville. MIT Press. 2020. ISBN-13 978-0262035613
3. Networks, crowds and markets. David Easley and Jon Kleinberg. Cambridge University Press. 2010
4. Network Science. Albert-László Barabási. Cambridge University Press. 1st. edition 2016. ISBN-13: 978-1107076266

VIII. Créditos y responsabilas

Responsabilidad	Nombre completo	Clave de nombramiento /No. de empleado
Coordinador (Autor)	Adolfo Guzmán Arenas	9500093
Participante (Coautor)	Gilberto Lorenzo Martínez Luna	9601000
Asesor didáctico / Diseñador Instruccional		
Tecnólogo educativo / Comunicólogo		
Corrector de estilo		
Programador multimedia / Diseñador gráfico		
Otro...		



Formato para registro de Unidades de aprendizaje 2021

Por la División de Operación y Promoción al Posgrado de la SIP	Por la Subdirección de Diseño y Desarrollo de la DEV
Nombre _____	Nombre _____
FIRMA _____	FIRMA _____

VERIFICACIÓN PARA SU PUESTA EN OPERACIÓN

REVISIÓN TÉCNICO-PEDAGÓGICA PARA LA MODALIDAD

Por la Dirección de Posgrado	Por la Dirección para la Educación Virtual
Nombre _____	Nombre _____
FIRMA _____	FIRMA _____
SELLO DE VALIDACIÓN	