




## 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

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



## 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"><li>• Sabrá transformar una colección de objetos (un «dataset») en un grafo, con atributos en los nodos y en las aristas del grafo.</li><li>• Sabrá hacer minería de datos sobre un conjunto de datos que contiene relaciones entre los objetos, usando la teoría de grafos</li><li>• 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.</li><li>• 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.</li><li>• Hará predicciones sobre nuevos objetos, nuevos atributos, nuevas relaciones y nuevos datasets, dados los objetos existen</li></ul>	<ul style="list-style-type: none"><li>• Podrá generar nuevas relaciones entre objetos existentes.</li><li>• 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.</li><li>• Podrá predecir nuevas relaciones entre dos objetos, dada la existencia de tales relaciones entre objetos actuales similares.</li><li>• Podrá usar redes neuronales para predecir las propiedades y relaciones sobre un nuevo dataset, al llevar a cabo aprendizaje mecánico sobre datasets similares</li></ul>	<ul style="list-style-type: none"><li>• Observación crítica de los objetos que se consideran, sus atributos y las relaciones con otros objetos cercanos.</li><li>• Obtendrá mayor poder de abstracción.</li><li>• Interacción con personas expertas en los objetos bajo estudio y sus cualidades, que dominan áreas</li></ul>

### 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"><li>• Computación.</li><li>• Representación de la información.</li><li>• Matemáticas discretas.</li><li>• Álgebra lineal.</li><li>• Teoría de grafos</li></ul>	<ul style="list-style-type: none"><li>• Ciencia y tecnología de la información</li></ul>	<ul style="list-style-type: none"><li>• 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.</li></ul>
--	--	--

##### 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. INTRODUCTION. Converting relational data bases to graphs. Software that we will use.	2 Hours.
1.1. Applications. Graphs are the new frontier of machine learning. Deep learning with graphs	
2. TRADITIONAL METHODS FOR MACHINE LEARNING IN GRAPHS	2 Hours
2.1. Given graph $G = (V, E)$ , how to predict $f$ in $f : V \rightarrow \mathbb{R}^n$ ? How to learn $f$ ?	
2.2. Finding useful representations. Clustering coefficient; graphlets. Link prediction	
2.3. Powers of the adjacency matrix. Graph-level features and kernels: Weisfeiler-Lehman kernel; color refinement	
3. NODE EMBEDDINGS	4 Hours
3.1. Encoder, decoders; shallow and deep. Learning node embeddings. Random walk approaches	
3.2. Feature learning as optimization. Negative sampling. Embedding entire graphs	
3.3. Node2vec: biased walks. Embedding entire graphs. Learning walk embeddings	
4. GRAPH AS MATRIX: PAGERANK, RANDOM WALKS	6 Hours
4.1. Embeddings. Stationary distribution. Eigenvector formulation	
4.2. Power iteration methods. Matrix factorization and node embeddings	
5. MESSAGE PASSING AND NODE CLASSIFICATION	2 Hours
5.1. Relational classification and iterative classification. Belief propagation. Loopy BP algorithm	
6. GRAPH NEURAL NETWORKS (GNNs)	10 Hours
6.1. Introduction. Deep graph encoders	
6.2. Basics of Deep learning	
6.2.1. Machine learning as optimization. Objective function. Loss function	
6.2.2. Gradient vector. Gradient descent. Learning rate. Stochastic gradient descent	
6.2.3. Neural network function. Back propagation. Multi-layer perceptron (MLP)	
6.3. Deep learning for graphs	
6.3.1. Local network neighborhood. Stacking multiple layers. Convolutional networks	
6.3.2. Graph convolutional networks. Neighborhood aggregation. Deep encoder.	
6.3.3. Matrix formulation. How to train a GNN. Inductive capability	
7. A GENERAL PERSPECTIVE OF GNNs	5 Hours
7.1. A general framework for GNNs	
7.2. A single layer of a GNN	
7.2.1. Two step process: (1) message; (2) aggregation. A single GNN layer	
7.2.2. Graph convolutional networks (GCN). Graph attention networks (GAT). Attention mechanism	
7.2.3. Batch normalization. Dropout. Activation. Non linearity. ReLU. Sigmoid. Parametric ReLU	
7.3. Stacking layers of GNN	
7.3.1. How to construct a Graph Neural Network. Over-smoothing. Receptive field. Skip connections	
8. PREDICTION WITH GNNs	8 Hours
8.1. GNN augmentation and training	
8.2. Prediction with GNNs	



**Formato para registro de Unidades de aprendizaje 2021**

8.2.1.GNN training pipeline. GNN Prediction heads (node level, edge level, graph level)	
8.2.2.Hierarchical pooling. Training GNNs. Supervised vs unsupervised. Supervised labels on graphs	
8.2.3.Unsupervised signals. Classification or regression. Regression loss. Evaluation metrics	
8.3. Setting-up GNN prediction tasks	
8.3.1.Examples	
9. THEORY. SETTING-UP GNN PREDICTION TASKS	6 Hours
9.1. GCN, GraphSAGE, design space. Designing a maximally expressive GNN. Computational graph	
9.2. Designing the most powerful GNN. Universal approximation theorem. Graph isomorphism network (GIN)	
9.3. Relation to WL Graph kernel. The complete GIN model. The power of pooling	
10. HETEROGENEOUS GRAPHS	6 Hours
10.1. Heterogeneous graphs and Relational GCNs (RGCN)	
10.2. Scalability of RGCNs. Block diagonal matrices. Applications of Knowledge graphs (KG)	
10.3. Bilinear modeling. Composition relations. KG embeddings in practice. Traversing KG for conjunctive queries	
11. REASONING IN KNOWLEDGE GRAPHS	6 Hours
11.1. Answering multiple-hop queries. Path queries. Conjunctive queries. Query2box	
11.2. Traversing KG in vector space. Embedding AND-OR query. Box embedding	
11.3. Projection, intersection operators. Query generation from templates. Visualization. Embedding space	
12. IDENTIFYING AND COUNTING MOTIFS IN NETWORKS	4 Hours
12.1. Network motifs. Motif significance and profile. ER random graphs. Neural subgraph matching	
12.2. Neural architecture for subgraphs. Order embedding. Training neural subgraph matching. Find frequent subgraphs	
13. COMMUNITY DETECTION IN NETWORKS	4 Hours
13.1. Triadic closure. Edge overlap vs strength. Network communities. Null model. Modularity	
13.2. Louvain algorithm. Detecting overlapping communities. Protein-protein interactions	
13.3. Community affiliation graph model (AGM). Graph fitting. Relaxing AGM	
14. GENERATIVE MODELS FOR GRAPHS	2 Hours
14.1. Properties of real-world graphs. The small-world model. Kronecker graph model	
14.2. Recursive graph generation. Stochastic Kronecker graphs	
15. DEEP GENERATIVE MODELS FOR GRAPHS	1 Hour
16. ADVANCED TOPICS IN GRAPH NEURAL NETWORKS	1 Hour
17. SCALING UP GNNs TO LARGE GRAPHS	1 Hour
18. MARINKA ZITNIK. GNNs IN COMPUTATIONAL BIOLOGY	1 Hour
19. GNNs IN SCIENCE	1 Hour
Total number of hours	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...	





### Formato para registro de Unidades de aprendizaje 2021

Conferencias magistrales

No se contemplan en este curso

Notas complementarias


VII. Referencias

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 responsabilidades

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

#### VERIFICACIÓN GENERAL DE LA PLANEACIÓN DIDÁCTICA

Por la División de Operación y Promoción al Posgrado de la SIP

Nombre \_\_\_\_\_

FIRMA \_\_\_\_\_

#### REVISIÓN DE LA PLANEACIÓN DIDÁCTICA (VIABILIDAD)

Por la Subdirección de Diseño y Desarrollo de la DEV

Nombre \_\_\_\_\_

FIRMA \_\_\_\_\_

#### VERIFICACIÓN PARA SU PUESTA EN OPERACIÓN

Por la Dirección de Posgrado

Nombre \_\_\_\_\_

FIRMA \_\_\_\_\_

SELLO DE VALIDACIÓN

#### REVISIÓN TÉCNICO-PEDAGÓGICA PARA LA MODALIDAD

Por la Dirección para la Educación Virtual

Nombre \_\_\_\_\_

FIRMA \_\_\_\_\_