



I CONGRESO DE INTELIGENCIA ARTIFICIAL

ESCUELA DE MATEMÁTICA
FACULTAD DE CIENCIAS
— UNAH —

PROGRAMA Y LIBRO DE RESÚMENES

13- 17 de Julio 2026
Ciudad Universitaria, Tegucigalpa MDC, Honduras

Escuela de Matemática y Ciencias de la Computación

Facultad de Ciencias

Maestría en Matemática, UNAH 2026

Autoridades

Odir Fernández, Rector UNAH
Bryan Larios, Decano Facultad de Ciencias
Rámon Enamorado, Director Escuela de Matemática
Luis Zerón, Jefe Depto. Matemática Pura
Angel Rivera, Jefe Depto. Matemática Aplicada
Leandro Galo, Coordinador Maestría de Matemática
Roberto Duarte, Coordinador Investigación y Vinculación
Henry Ocampo, Coordinador Carrera de Matemática

Comité Organizador

Juan Carlos Leonardo
Ramón Enamorado
Leandro Galo
Roberto Duarte
Henry Ocampo
Rosibel Pacheco
José Ever Gonzalez
Iván Henriquez
Darwin Quiroz
Oswaldo Cubas
Darwin Gutierrez
Allison Chavez
Carlos Manuel Veroy
Mauricio Alvarenga

Editor General

Henry Ocampo

Editor Asociado

Roberto Duarte

ESCUELA DE MATEMÁTICA Y CIENCIAS DE LA
COMPUTACIÓN: CONGRESO DE INTELIGENCIA
ARTIFICIAL Y CIENCIA DE DATOS

EDITOR GENERAL
Henry Ocampo

EDITOR ASOCIADO
Roberto Duarte

Escuela de Matemática y Ciencias de la Computación Facultad de Ciencias.
Congreso de Inteligencia Artificial y Ciencia de Datos.

UNAH, 2026

CONTENIDO

I. ACTIVIDADES 2

Cronograma 3

Enlaces 3

II. CONFERENCIAS 7

1. *Jean Bernard H.* : Saber que no sabes: Lidar con la incertidumbre en los sistemas de aprendizaje profundo 8
2. *Allan Córdova, Oscar Madrid* : Regresión Distribucional Multivariante: Comparación entre Distributional Random Forests (DRF) y Redes Neuronales 9
3. *Gabriel Chicas* : Avances recientes en investigación matemática con IA 10
4. *Erlin Vásquez, Oscar Madrid* : Estimación de series temporales multivariadas constante por segmentos en los cuantiles 11
5. *Ruth Moreno, María Mendoza, Henry Ocampo, Iván Henríquez* : Estimación de la velocidad y densidad vehicular mediante técnicas de visión computacional y aprendizaje profundo 13
6. *Oscar Madrid* : Detección retrospectiva de puntos de cambio en redes dinámicas 14
7. *Carlos Madrid, Oscar Madrid, Yik Lun Key, Zhi Zhang, Yanzhen Chen* : Construcción de intervalos de confianza y estimación de varianza condicional con redes ReLU densas 15
8. *Adrián Pastor López* : La Ciencia Detrás de ChatGPT: Del Aprendizaje Estadístico a los Grandes Modelos de Lenguaje 16

III. CURSOS **17**

9. *Adrián Pastor López Monroy* : Introducción al Procesamiento de Lenguaje Natural **18**

10. *Jean Bernard Hayet* : Una introducción a los modelos generativos profundos **20**

11. *Gabriel Alexander Chicas* : Diseño e implementación de flujos de trabajo agénticos **22**

IV. Autores **24**

Autores **25**

ACTIVIDADES

Cronograma

Figure 1: Calendario de actividades

HORA	LUNES 13-jul	MARTES 14-jul	MIÉRCOLES 15-jul	JUEVES 16-jul	VIERNES 17-jul
08:00 - 09:30	INAUGURACIÓN	Curso #1: Introducción al Procesamiento de Lenguaje Natural Adrian Pastor López			
9:30-10:00	Receso				
10:00 - 11:00	Curso #1: Introducción al Procesamiento de Lenguaje Natural Adrian Pastor López	Conferencia #2 : Regresión Distribucional Multivariante: Comparación entre Distribucional Random Forests (DRF) y Redes Neuronales Allan Mauricio Cordova	Conferencia #4: Estimación de series temporales multivariadas constante por segmentos en los cuantiles Erlin Osmar Vásquez	Conferencia #7 (virtual): Construcción de intervalos de confianza y estimación de varianza condicional con redes ReLU densas Carlos Misael Madrid	
11:00 - 12:00	Conferencia #1: Saber que no sabes: Lidiar con la incertidumbre en los sistemas de aprendizaje profundo Jean Bernard Hayet	Conferencia #3: Avances recientes en investigación matemática con IA GabrieleAlexander Chicas	Conferencia #5: Estimación de la velocidad y densidad vehicular mediante técnicas de visión computacional y aprendizaje profundo Ruth Eunice Moreno	Conferencia #8: La Ciencia Detrás de ChatGPT: Del Aprendizaje Estadístico a los Grandes Modelos de Lenguaje Adrian Pastor López	
12:00 - 13:00					
13:00 - 14:30	Curso #2: Una introducción a los modelos generativos profundos Jean Bernard Hayet				
14:30 - 15:00	Receso				
15:00 - 16:30	Curso #3: Diseño e implementación de flujos de trabajo ágenticos GabrielAlexander Chicas			Clausura	
17:00 - 18:00			Conferencia #6 (virtual): Detección retrospectiva de puntos de cambio en redes dinámicas Oscar Hernán Madrid		
Conferencias: Sala Salvador Llopis, segundo piso, edificio F1					Conferencias virtuales:
Cursos: Centro de Computo EMCC, segundo piso, edificio F1					Conferencias presenciales:
					Cursos:

Inauguración

Día: lunes 13 de julio.
Hora: 08:00 a.m. - 09:30 p.m.
Lugar: Sala de Proyecciones CRA, UNAH CU.

Clausura

Día: jueves 16 de julio.
Hora: 03:00 p.m. - 04:30 p.m.
Lugar: Sala Salvador Llopis, edificio F1, UNAH CU.

Enlaces

Conferencia #1

Saber que no sabes: Lidar con la incertidumbre en los sistemas de aprendizaje profundo - **Jean Bernard Hayet**.

Día: lunes 13 de julio.

Hora: 11:00 a.m. - 12:00 p.m.

Lugar: Sala Salvador Llopis, edificio F1, UNAH CU.

<https://us02web.zoom.us/j/81322865149?pwd=bGPprUH7yVTgwdUQs00AWdSAgiPAqc.1>

ID de reunión: 813 2286 5149

Código de acceso: 252538

Conferencia #2

Regresión Distribucional Multivariante: Comparación entre Distributional Random Forests (DRF) y Redes Neuronales - **Allan Mauricio Córdova**.

Día: martes 14 de julio.

Hora: 10:00 a.m. - 11:00 a.m.

Lugar: Sala Salvador Llopis, edificio F1, UNAH CU.

<https://us02web.zoom.us/j/85126891563?pwd=F5W1Zz4RNaQxbrpamALUsv9fjhbtah.1>

ID de reunión: 851 2689 1563

Código de acceso: 218108

Conferencia #3

Avances recientes en investigación matemática con IA - **Gabriel Alexander Chicas**.

Día: martes 14 de julio.

Hora: 11:00 a.m. - 12:00 p.m.

Lugar: Sala Salvador Llopis, edificio F1, UNAH CU.

<https://us02web.zoom.us/j/88300721496?pwd=amL9ewyPBipWFzVxDLIZxBMSgmyaOr.1>

ID de reunión: 883 0072 1496

Código de acceso: 824019

Conferencia #4

Estimación de series temporales multivariadas constante por segmentos en los cuantiles - **Carlos Misael Madrid**.

Día: miércoles 15 de julio.

Hora: 10:00 a.m. - 11:00 a.m.

Lugar: Sala Salvador Llopis, edificio F1, UNAH CU.

<https://us02web.zoom.us/j/82267491854?pwd=PMSjGIfSUAogmedPUgxGkpEzwWshZg.1>

ID de reunión: 822 674 91854

Código de acceso: 123456

ID de reunión: 822 6749 1854

Código de acceso: 798566

Conferencia #5

Estimación de la velocidad y densidad vehicular mediante técnicas de visión computacional y aprendizaje profundo - **Ruth Eunice Moreno**.

Día: miércoles 15 de julio.

Hora: 11:00 a.m. - 12:00 p.m.

Lugar: Sala Salvador Llopis, edificio F1, UNAH CU.

<https://us02web.zoom.us/j/85872974741?pwd=xuelGBR5QwkGMEU2p7pFaAKbOiIDF4.1>

ID de reunión: 858 7297 4741

Código de acceso: 332799

Conferencia #6

Detección retrospectiva de puntos de cambio en redes dinámicas - **Oscar Hernán Madrid**.

Día: miércoles 15 de julio.

Hora: 05:00 p.m. - 06:00 p.m.

Lugar: Sala Salvador Llopis, edificio F1, UNAH CU.

<https://us02web.zoom.us/j/84708237908?pwd=r97bb3kC0pdWKl019gRhm66yBf9ioI.1>

ID de reunión: 847 0823 7908

Código de acceso: 911258

Conferencia #7

Construcción de intervalos de confianza y estimación de varianza condicional con redes ReLU densas - **Carlos Misael Madrid**.

Día: jueves 16 de julio.

Hora: 10:00 a.m. - 11:00 a.m.

Lugar: Sala Salvador Llopis, edificio F1, UNAH CU.

<https://us02web.zoom.us/j/81374094087?pwd=52ICDSYOaRuiHi8SWroObfwWxCqhUo.1>

ID de reunión: 813 7409 4087

Código de acceso: 180319

Conferencia #8

La Ciencia Detrás de ChatGPT: Del Aprendizaje Estadístico a los Grandes Modelos de Lenguaje - **Adrián Pastor López**.

Día: jueves 16 de julio.

Hora: 11:00 a.m. - 12:00 p.m.

Lugar: Sala Salvador Llopis, edificio F1, UNAH CU.

<https://us02web.zoom.us/j/88007912921?pwd=1Jc3x0RaJMbubwpDlJlkoXJViwfVCb.1>

ID de reunión: 880 0791 2921

Código de acceso: 886989

Curso #1

Introducción al Procesamiento de Lenguaje Natural - **Adrián Pastor López.**

Días: lunes 13 de julio al jueves 16 de julio.

Hora: 08:00 a.m. - 09:30 a.m.

Lugar: Laboratorio de computación EMCC, edificio F1, UNAH CU.

Curso #2

Una introducción a los modelos generativos profundos - **Jean Bernard Hayet.**

Días: lunes 13 de julio al jueves 16 de julio.

Hora: 01:00 p.m. - 02:30 p.m.

Lugar: Laboratorio de computación EMCC, edificio F1, UNAH CU.

Curso #3

Diseño e implementación de flujos de trabajo ágenticos - **Gabriel Alexander Chicas.**

Días: lunes 13 de julio al jueves 15 de julio.

Hora: 01:00 p.m. - 02:30 p.m.

Lugar: Laboratorio de computación EMCC, edificio F1, UNAH CU.

CONFERENCIAS

Saber que no sabes: Lidiar con la incertidumbre en los sistemas de aprendizaje profundo

Jean Bernard H.

En esta charla, intentaré motivar lo crucial que es para los desarrolladores de sistemas de inteligencia artificial moderna, basada en un uso masivo de datos, de proveer incertidumbres fiables sobre los *outputs* de sus sistemas; daré un panorama sobre la cuestión de la representación, de la cuantificación y de la evaluación de las incertidumbres producidas por sistemas de inteligencia artificial, lo que nos llevará a discutir sobre el modelo de Aprendizaje Profundo Bayesiano.

Palabras claves: Aprendizaje profundo, Incertidumbre, Modelos profundos Bayesianos.

Referencias

- [1] A. Kendall and Y. Gal. What uncertainties do we need in bayesian deep learning for computer vision? In Advances in neural information processing systems, pages 5574-5584, 2017.
- [2] Practical Uncertainty Estimation and Out-of-Distribution Robustness in Deep Learning. Tutorial NeurIPS, 2020.
- [3] Bayesian Deep Learning. Video tutorial.

Regresión Distribucional Multivariante: Comparación entre Distributional Random Forests (DRF) y Redes Neuronales

Allan Córdova, Oscar Madrid

La regresión distribucional multivariante ha emergido como una herramienta fundamental para el análisis de fenómenos complejos en los que el interés no se limita a la estimación de valores promedio, sino que requiere una caracterización completa de la incertidumbre asociada a las variables de respuesta. A diferencia de los métodos tradicionales de regresión, que se enfocan en estimar la media condicional, la regresión distribucional modela la distribución condicional completa de un vector de respuestas dado un conjunto de covariables. Esto permite estudiar aspectos relevantes como la variabilidad, la asimetría, el comportamiento en las colas de la distribución y la estructura de dependencia entre las variables de interés, además de facilitar el cálculo de probabilidades condicionales y otros funcionales distribucionales.

En este contexto, se estudian y comparan dos metodologías modernas de aprendizaje automático para la estimación de distribuciones condicionales multivariadas: los Bosques Aleatorios Distribucionales (Distributional Random Forests, DRF) y las Redes Neuronales Densas con activación ReLU (NN-ReLU). Ambos enfoques se caracterizan por su capacidad para capturar relaciones no lineales y estructuras complejas sin requerir supuestos paramétricos restrictivos.

La conferencia tiene como objetivo presentar los fundamentos de estos métodos y comparar su desempeño en la estimación de distribuciones condicionales multivariadas mediante escenarios simulados no lineales y heterocedásticos, así como a través de una aplicación a datos meteorológicos reales.

Palabras claves: aprendizaje automático, regresión distribucional multivariante, Distributional Random Forest, Redes neuronales ReLU, distribución condicional multivariada.

Referencias

- [1] Čevič, D., Michel, L., Näf, J., Bühlmann, P., and Meinshausen, N. (2022). Distributional Random Forests: Heterogeneity Adjustment and Multivariate Distributional Regression. *Journal of Machine Learning Research*, 23(333): 1–79. <https://www.jmlr.org/papers/v23/21-0585.html>
- [2] Madrid Padilla, C. M., Madrid Padilla, O. H., and Chatterjee, S. (2025). *Risk Bounds For Distributional Regression*. Advances in Neural Information Processing Systems (NeurIPS 2025). <https://arxiv.org/abs/2505.09075>

Avances recientes en investigación matemática con IA

Gabriel Chicas

Los modelos grandes de lenguaje (LLM) han mostrado una creciente capacidad para el razonamiento matemático. Hace apenas un par de años (2024), el estándar de rendimiento en matemáticas para los LLM eran problemas de olimpiadas de matemática como la AIME (American Invitational Mathematics Examination). En 2025, diversos modelos ya alcanzaban resultados impresionantes abordando problemas de la Olimpiada Internacional de Matemática (IMO), la competencia más difícil y prestigiosa a nivel escolar. A lo largo de 2025 y del presente año, la capacidad de algunos modelos de frontera ha llegado a abarcar matemáticas universitarias e investigación. En esta conferencia, haré un recorrido de estos avances y plantearé algunas ideas psicoanalíticas sobre la relación entre los LLM y la experiencia inconsciente del matemático.

Palabras claves: modelos grandes de lenguaje (LLM), razonamiento matemático, inteligencia artificial, olimpiadas de matemáticas, investigación matemática, cognición matemática.

Referencias

- [1] David Bessis, *The AI Revolution in Mathematics Has Arrived*. Quanta Magazine. Disponible en: <https://davidbessis.substack.com/p/the-fall-of-the-theorem-economy>
- [2] Chris Hayduk, *The Unreasonable Effectiveness of LLMs in Mathematics*. Disponible en: <https://www.chrishayduk.com/p/the-unreasonable-effectiveness-of>

Estimación de series temporales multivariadas constante por segmentos en los cuantiles

Erlin Vásquez, Oscar Madrid

El análisis de series temporales ha estado tradicionalmente orientado al estudio de características globales como la media, la varianza o la distribución completa de los datos. Sin embargo, estos enfoques pueden resultar insuficientes cuando las observaciones presentan asimetrías pronunciadas, colas pesadas o comportamientos extremos que afectan de manera significativa la dinámica del proceso. En este contexto, el presente trabajo propone una metodología de segmentación en cuantiles específicos a lo largo de un conjunto de series temporales que presentan puntos de cambio compartidos. Este enfoque es particularmente relevante en aplicaciones donde los eventos extremos tienden a manifestarse de forma simultánea o altamente correlacionada entre distintas series.

La propuesta metodológica se fundamenta en dos componentes principales. En primer lugar, se emplea la regresión cuantílica como herramienta de estimación, la cual permite modelar distintos puntos de la distribución condicional y ofrece una mayor robustez frente a valores atípicos y distribuciones con colas pesadas. En segundo lugar, se incorpora una penalización basada en la variación total (TV), cuyo objetivo es promover soluciones segmentadas y facilitar la identificación precisa de puntos de cambio asociados a modificaciones en el mecanismo generador de los datos.

Para la resolución del problema de optimización se desarrolla un algoritmo basado en el Método de Multiplicadores de Dirección Alternante (ADMM), mientras que la selección del modelo se lleva a cabo mediante ideas del Criterio de Información Bayesiano (BIC). El desempeño del método propuesto se evalúa mediante estudios de simulación y se compara con el enfoque *Group Fused Lasso* (GFL) bajo escenarios con errores normales y distribuciones *t*-Student con tres grados de libertad. Los resultados obtenidos evidencian la robustez, precisión y competitividad de la metodología propuesta en la segmentación de series estacionarias por segmentos que presentan puntos de cambio compartidos.

Palabras claves: Segmentación, Método de Multiplicadores de Dirección Alternante, cuantiles, puntos de cambio, variación total.

Referencias

- [1] Bleakley, K., & Vert, J. P. (2011). The group fused lasso for multiple change-point detection. *Technical Report HAL-00602121, Bioinformatics Center (CBIO)*. <https://inria.hal.science/hal-00602121>
- [2] Boyd, S., Parikh, N., Chu, E., Peleato, B., and Eckstein, J. (2011). Distributed optimization and statistical learning via the alternating direction method of multipliers. *Foundations and Trends in Machine Learning*,

3(1):1–122. https://web.stanford.edu/~boyd/papers/pdf/admm_distr_stats.pdf

- [3] Koenker, R. and Bassett Jr, G. (1978). Regression quantiles. *Econometrica: journal of the Econometric Society*, pages 33–50. <http://www.econ.uiuc.edu/~roger/NAKE/rqs78.pdf>
- [4] Madrid Padilla, O. H. and Chatterjee, S. (2022). Risk bounds for quantile trend filtering. *Biometrika*, 109(3):751–768. <https://doi.org/10.1093/biomet/asab045>

Estimación de la velocidad y densidad vehicular mediante técnicas de visión computacional y aprendizaje profundo

Ruth Moreno, María Mendoza, Henry Ocampo, Iván Henríquez

En este trabajo se plantea un estudio orientado a la estimación de velocidad vehicular mediante técnicas de visión por computadora y aprendizaje automático. Los videos capturados en carreteras serán procesados mediante un modelo de Redes Neuronales Convolucionales (CNN) entrenado con una base de datos elaborada por los propios autores, a partir de imágenes y secuencias de video etiquetadas manualmente. Este modelo permitirá la detección de vehículos, sobre la cual se desarrollarán algoritmos de seguimiento y estimación de velocidad. Con los datos obtenidos se calculará la densidad vehicular en intervalos de tiempo definidos, aplicando métodos de muestreo que garanticen la representatividad de la información. Finalmente, se implementará una regresión lineal entre velocidad y densidad, cuyos coeficientes servirán como parámetros de entrada en un modelo de congestión vehicular formulado mediante ecuaciones diferenciales parciales. El objetivo de la investigación es generar información precisa y validada que contribuya al desarrollo de modelos avanzados para el análisis y predicción del tráfico vehicular.

Palabras claves: Aprendizaje automático, Redes neuronales convolucionales, algoritmos de seguimiento, detección de objetos.

Referencias

- [1] Grents, A., Varkentin, V., and Goryaev, N. (2020). Determining vehicle speed based on video using convolutional neural network. *Proceedings of the XIV International Conference "Organization and Safety of Traffic in Large Cities"*. South Ural State University, Chelyabinsk, Russia.
- [2] Aggarwal, C. C. (2018). *Neural Networks and Deep Learning: A Textbook*. Springer. International Business Machines (IBM) T. J. Watson Research Center, Yorktown Heights, NY, USA.
- [3] Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. University of Washington, Allen Institute for AI, Facebook AI Research. <http://pjreddie.com/yolo/>
- [4] Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press.
- [5] Villamarin, D. (2015). Estado del Arte, Herramientas y Aplicaciones para Transformaciones Geométricas 3D. *Conference Paper*. Universidad de las Fuerzas Armadas-ESPE. Disponible en: <https://www.researchgate.net/publication/290964976>

Detección retrospectiva de puntos de cambio en redes dinámicas

Oscar Madrid

Esta charla presenta métodos estadísticos para detectar cambios estructurales abruptos en redes observadas a lo largo del tiempo. La primera parte estudia la fisión de la comunidad de chimpancés de Ngogo y cómo el análisis de redes identifica una transición clave antes del conflicto letal. La segunda parte introduce un marco para redes dinámicas multicapa, con metodología, teoría de localización e inferencia para puntos de cambio.

Construcción de intervalos de confianza y estimación de varianza condicional con redes ReLU densas

Carlos Madrid, Oscar Madrid, Yik Lun Key, Zhi Zhang, Yanzhen Chen

En esta charla se estudian dos problemas centrales en la cuantificación de incertidumbre para modelos de aprendizaje profundo: la estimación de la varianza condicional y la construcción de intervalos de confianza en regresión no paramétrica. Se considera un modelo con ruido heterocedástico, en el que tanto la media condicional como la varianza condicional pueden depender de las covariables. El objetivo es estimar la función de varianza condicional y construir intervalos de confianza para la media verdadera con una cobertura previamente especificada.

El enfoque propuesto utiliza redes neuronales densas con activación ReLU. Primero se estima la media condicional mediante una red ReLU y luego, a partir de los residuos, se ajusta una segunda red ReLU para estimar la varianza condicional. Se presentan cotas no asintóticas para la estimación de la media y de la varianza bajo distribuciones de error generales, incluyendo errores subexponenciales. Además, se introduce un procedimiento bootstrap robusto, basado en las estimaciones de media y varianza, para construir intervalos de confianza con garantías teóricas de cobertura. Los resultados se complementan con simulaciones y experimentos con datos reales, donde el método propuesto alcanza niveles de cobertura cercanos al nominal y produce intervalos de longitud razonable.

Palabras claves: intervalos de confianza, varianza condicional, redes neuronales ReLU, bootstrap, regresión no paramétrica, cuantificación de incertidumbre.

Referencias

- [1] Madrid Padilla, C. M., Madrid Padilla, O. H., Kei, Y. L., Zhang, Z., and Chen, Y. (2025). *Confidence Interval Construction and Conditional Variance Estimation with Dense ReLU Networks*. arXiv:2412.20355v2. <https://arxiv.org/abs/2412.20355>
- [2] Efron, B., and Tibshirani, R. J. (1994). *An Introduction to the Bootstrap*. Chapman and Hall/CRC.
- [3] Fan, J., and Yao, Q. (1998). Efficient estimation of conditional variance functions in stochastic regression. *Biometrika*, 85(3): 645–660.
- [4] Kohler, M., and Langer, S. (2019). On the rate of convergence of fully connected very deep neural network regression estimates. arXiv:1908.11133.

La Ciencia Detrás de ChatGPT: Del Aprendizaje Estadístico a los Grandes Modelos de Lenguaje

Adrián Pastor López

En esta plática se abordará el impacto transformador y los principios fundamentales de los Large Language Models (LLMs), modelos capaces de resolver problemas cada vez más complejos, responder preguntas, traducir textos, generar contenido creativo y analizar grandes volúmenes de información. Se presentará un breve recorrido por la evolución de los modelos de lenguaje, desde los primeros enfoques estadísticos para la predicción de palabras hasta el desarrollo de arquitecturas modernas basadas en redes neuronales. Asimismo, se discutirá cómo la rápida evolución de estos modelos transformó la percepción inicial de que eran simples curiosidades tecnológicas, convirtiéndolos en una de las innovaciones más disruptivas de la Inteligencia Artificial. Finalmente, se revisarán de manera general algunos conceptos clave relacionados con la generación automática de texto, el entrenamiento de estos modelos, así como sus principales limitaciones y desafíos, incluyendo las alucinaciones, los sesgos y otros retos asociados a su uso responsable.

Palabras claves: Inteligencia Artificial (IA), Large Language Models (LLMs), ChatGPT, Procesamiento del Lenguaje Natural.

Referencias

- [1] Jurafsky, D., and Martin, J. H. (2025). *Speech and Language Processing* (3rd ed., draft). <https://web.stanford.edu/~jurafsky/slp3/>
- [2] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I. (2017). *Attention Is All You Need*. In *Advances in Neural Information Processing Systems (NeurIPS 30)*. <https://arxiv.org/abs/1706.03762>
- [3] Wei, J., Wang, X., Schuurmans, D., Bosma, M., Ichter, B., Xia, F., Chi, E., Le, Q. V., and Zhou, D. (2022). *Chain-of-Thought Prompting Elicits Reasoning in Large Language Models*. In *Advances in Neural Information Processing Systems (NeurIPS 35)*. <https://arxiv.org/abs/2201.11903>
- [4] Brown, T. B., Mann, B., Ryder, N., et al. (2020). *Language Models are Few-Shot Learners*. In *Advances in Neural Information Processing Systems (NeurIPS 33)*. <https://arxiv.org/abs/2005.14165>

CURSOS

Introducción al Procesamiento de Lenguaje Natural

Adrián Pastor López Monroy

Descripción

Este curso ofrece una introducción práctica al Procesamiento de Lenguaje Natural (PLN) utilizando Python. A través de ejemplos y ejercicios, los participantes aprenderán los conceptos fundamentales para representar y analizar texto, desde el preprocesamiento básico hasta la construcción de representaciones vectoriales de palabras y la aplicación de modelos sencillos para clasificación de texto. El curso utilizará herramientas ampliamente empleadas en PLN, como `NLTK` y `scikit-learn`, trabajando con conjuntos de datos reales.

Contenido

No.	Tema	Descripción
1	Procesamiento básico de texto	Introducción al PLN, pre-procesamiento de texto, representaciones vectoriales (Bag of Words) y clasificación de texto.
2	Embeddings	Introducción a representaciones distribucionales mediante co-ocurrencias (TCOR) y redes neuronales (Word2Vec).
3	Modelado estadístico del lenguaje	Introducción al modelado del lenguaje mediante enfoques estadísticos y probabilísticos.
4	Modelado neuronal del lenguaje	Introducción al modelado del lenguaje mediante enfoques basados en redes neuronales.

Capacidades previas

- Conocimientos básicos de programación en Python.

- Manejo elemental de estructuras de datos (listas, diccionarios y funciones).
- Interés por la Inteligencia Artificial y el Procesamiento de Lenguaje Natural.

Referencias bibliográficas

- [1] Jurafsky, D., & Martin, J. H. (2025). *Speech and Language Processing* (3rd ed., draft). <https://web.stanford.edu/~jurafsky/slp3/>
- [2] Bird, S., Klein, E., & Loper, E. (2009). *Natural Language Processing with Python*. O'Reilly Media.

Recursos electrónicos

- *Anaconda*: <https://www.anaconda.com/download>
- *NLTK Documentation*: <https://www.nltk.org/>
- *Scikit-learn Documentation*: <https://scikit-learn.org/>
- *Google Colaboratory*: <https://colab.research.google.com/>

Una introducción a los modelos generativos profundos

Jean Bernard Hayet

Descripción

La IA generativa se ha vuelto omnipresente en nuestra vida diaria, con un uso constante y creciente de herramientas automatizadas para producir textos o imágenes. En este tutorial, describiremos los fundamentos matemáticos de los modelos generativos más recientes detrás de la IA generativa, específicamente los modelos de difusión (*denoising diffusion probabilistic models*) y el *flow matching*. En ambos casos, explicaremos los principios teóricos detrás de estos enfoques y realizaremos ejercicios prácticos en Google Colab para que los participantes se familiaricen con su implementación, en el contexto de la generación de imágenes.

Contenido

No.	Tema	Descripción
1	Introducción	Conceptos básicos y aplicaciones de los modelos generativos.
2	Modelos de difusión (1)	Descripción de los principios generales y estudio de una implementación de DDPM.
3	Modelos de difusión (2)	Mejorías: el DDIM.
4	Flow Matching	Concepto de Flujo Normalizante; Flow Matching; Estudio de una implementación.
5	Conclusiones y discusión	

Capacidades previas

- Comprensión y aplicación de conceptos estadísticos básicos.
- Manejo de Python (deseado).

Referencias bibliográficas

1. Denoising Diffusion Probabilistic Models. Jonathan Ho, Ajay Jain and

- Pieter Abbeel. Advances in Neural Information Processing Systems, 6840–6851. 2020.
2. Denoising Difusion Implicit Models. Jiaming Song, Chenlin Meng, Stefano Ermon. International Conference on Learning Representations (ICLR). 2021.
 3. Flow Matching for Generative Modeling. Yaron Lipman, Ricky Chen, Heli Ben-Hamu, Maximilian Nickel, and Matt Le. arXiv preprint. 2022.

Recursos electrónicos

- Se compartirán URLs de notebooks de Google Colab.

Diseño e implementación de flujos de trabajo agénticos

Gabriel Alexander Chicas

Descripción

En mi experiencia profesional, los servicios basados en agentes de IA están en alta demanda actualmente. Mi intención en este taller es cubrir algunos ejemplos de flujos de trabajo que se encuentran en el desarrollo de dichos productos. El énfasis estará en *agentes*, es decir, servicios de IA que trabajan de forma autónoma. Veremos una descripción teórica junto a la implementación de ejemplos programando en Python.

Contenido

No.	Tema	Descripción
1	Estrategias generales	Ejemplos sencillos (chain prompting, routing).
2	RAG (Retrieved Augmented Generation)	Estrategia para mejorar la calidad y exactitud de las respuestas de un LLM.
3	Model Context Protocol (MCP)	Protocolo estandarizado para integrar el uso de un LLM con herramientas externas.
4	Implementación	Implementación de ejemplos concretos.

Capacidades previas

- Experiencia con Python y Jupyter Notebook.
- Familiaridad con el funcionamiento de modelos de lenguaje (LLM).

Recursos electrónicos

- Zeljko Avramovic, *Agentic Design Patterns*.
<https://zeljkoavramovic.github.io/agent-design-patterns/knowledge-retrieval-rag>
- Nemotron Personas El Salvador.
<https://huggingface.co/datasets/nvidia/Nemotron-Personas-El-Salvador>

Autores

Autores

Ph.D. Adrián Pastor López Monroy *pastor.lopez@cimat.mx*

El Dr. López Monroy obtuvo su Maestría y Doctorado en Ciencias de la Computación en el Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE, México) en 2012 y 2017, respectivamente. En 2017 fue distinguido con el premio a la mejor tesis de doctorado en Inteligencia Artificial por la Sociedad Mexicana de IA. Es miembro del Sistema Nacional de Investigadores e Investigadoras, sus trabajos cuentan con más de 2000 citas y un H-index de 22 según Google Scholar, su área de especialidad es el Procesamiento de Lenguaje Natural (PLN). Durante 2017 y 2018, se desempeñó en la Universidad de Houston, Texas, como Investigador Asociado de Tiempo Completo y Catedrático. Desde 2018 en México se desempeña como Profesor Investigador en el Departamento de Ciencias de la Computación del Centro de Investigación en Matemáticas (CIMAT).



Ph.D. Jean Bernard Hayet *jbhayet@cimat.mx*



Dr. Jean Bernard estudió su carrera de ingeniería en la École Nationale Supérieure de Techniques Avancées (ENSTA) en París, y obtuvo su maestría en inteligencia artificial en la Universidad París VI. En 2003, obtuvo su doctorado en la Universidad de Toulouse, en el LAAS-CNRS, en Toulouse. De 2004 a 2007, fue investigador posdoctoral en la Universidad de Lieja. Desde 2007, trabaja en el CIMAT en Guanajuato, México, donde actualmente es Investigador Titular B en el Departamento de Ciencias de la Computación. Imparte esencialmente

clases de programación, visión por computadora y aprendizaje máquina. Su investigación se concentra en la confluencia de visión por computadora y de robótica.

Ph.D. Gabriel Alexander Chicas Reyes

gabriel.chicas@seguridad.sv Su formación en matemáticas puras viene de Japón, Europa y México. Es catedrático de matemáticas de la Universidad de El Salvador. Posteriormente ha pasado a dedicarse a la inteligencia artificial. Le gusta la interacción entre la matemática, la filosofía y el psicoanálisis. Para este congreso, planteará algunas de sus ideas psicoanalíticas aplicadas a la inteligencia artificial.



Ph.D. Carlos Misael Madrid Padilla

oscar@ufpa.br Es Profesor Asistente tenure-track en el Departamento de Estadística y Ciencia de Datos de Washington University in St. Louis. Obtuvo el grado de Ph.D. en Matemáticas en el Departamento de Matemáticas de la University of Notre Dame, bajo la supervisión del Dr. Daren Wang. Durante los primeros dos años de mis estudios doctorales, obtuvo también el grado de Maestría en Matemáticas, bajo la supervisión del Dr. Alex Himonas. Realizó sus estudios de licenciatura en Matemáticas en el Centro de Investigación en Matemáticas, en México,

donde obtuvo el grado de B.S. in Mathematics en mayo de 2019. Durante esta etapa, fue asesorado por el Dr. Víctor M. Pérez Abreu C. y el Dr. Mario Díaz.



Lic. Erlin Osmar Vásquez Carballo

evasquez@unah.edu.hn Cursó la Licenciatura en Matemática con Orientación en Ingeniería Matemática en la Universidad Nacional Autónoma de Honduras (UNAH). Durante su formación, se desempeñó como instructor de laboratorio en la Escuela de Matemática y, tras obtener el título, inició labores como docente en el Departamento de Estadística Matemática. Actualmente, se desempeña como docente en el Departamento de Estadística Matemática de la UNAH-CU. Sus intereses de investigación incluyen la optimización, el aprendizaje automático y la ciencia de datos, con especial énfasis en el análisis de series de tiempo.



**Lic. Allan Mauricio Córdova Martínez**

allan.cordova@unah.edu.hn Realizó sus estudios de Licenciatura en Matemática con Orientación en Ingeniería Matemática en la Universidad Nacional Autónoma de Honduras (UNAH). Tras obtener el título de licenciado, se incorporó como docente al Departamento de Estadística Matemática de la misma institución. Actualmente, es docente del Departamento de Estadística Matemática en la UNAH-Ciudad Universitaria y estudiante próximo a egresar de la Maestría en Matemática con Orientación en Estadística de la UNAH. Sus áreas de interés

incluyen la estadística, ciencia de datos, aprendizaje automático y la modelación matemática.

Lic. Ruth Eunice Moreno Melara

ruth.moreno@unah.hn Cursó la Licenciatura en Matemática con Orientación en Informática en la Universidad Nacional Autónoma de Honduras (UNAH). Actualmente curso la Maestría en Matemática con Orientación en Estadística Matemática en la misma institución. Participó en un programa de intercambio de investigación en la Università Campus Bio-Medico di Roma, Italia, desarrollando actividades de investigación en modelación matemática. Durante su formación se desempeñó como instructora de laboratorio en la



Escuela de Matemática y tras obtener el título trabajó como analista de Inteligencia de Negocios en la Administración Aduanera de Honduras, desarrollando soluciones de análisis de datos, inteligencia artificial, automatizaciones de procesos y apoyo en redacciones para pliegos de licitación para la contratación de soluciones basadas en machine learning y visión por computadora. Su trabajo académico y profesional se centra en aprendizaje automático, visión computacional, el análisis de datos, la estadística aplicada y la optimización matemática.



Ph.D. Oscar Hernán Madrid Padilla

oscar.madrid@stat.ucla.edu El Dr. Oscar Hernán Madrid Padilla es un matemático y estadístico hondureño, originario de Trinidad, Santa Bárbara. Desde muy joven destacó en las Olimpiadas Hondureñas de Matemáticas, obteniendo la medalla de oro nacional y representando a Honduras en la 49.^a Olimpiada Internacional de Matemáticas (IMO) en 2008, donde recibió una Mención Honorífica, siendo uno de los primeros hondureños en obtener este reconocimiento en esa competencia. Gracias

a su sobresaliente desempeño académico, obtuvo una beca para realizar la Licenciatura en Matemáticas en el Centro de Investigación en Matemáticas (CIMAT), en Guanajuato, México, institución donde inició su formación científica. Posteriormente obtuvo el doctorado en Estadística en la Universidad de Texas en Austin y desarrolló investigación en la Universidad de California, Berkeley. Actualmente es Profesor Asociado con permanencia (Associate Professor with tenure) en el Departamento de Estadística y Ciencia de Datos de la University of California, Los Angeles (UCLA). Su investigación se centra en estadística matemática, aprendizaje automático, ciencia de datos, optimización e inteligencia artificial, áreas en las que ha realizado importantes contribuciones y publicado en revistas científicas de alto impacto.