

Semana de Matemática 2025

En honor a Niels
Henrik Abel

!Celebremos los 53
años de
la carrera de
Matemática en
Honduras!

Del 8 al 12
de
Septiembre



UNAH
UNIVERSIDAD NACIONAL
AUTÓNOMA DE HONDURAS



Semana de Matemática

Niels Henrik Abel

Facultad de Ciencias, UNAH 2025

Autoridades

Odir Fernández, Rector UNAH
Bryan Larios, Decano Facultad de Ciencias
Rámon Enamorado, Director Escuela de Matemática
Luis Zerón, Jefe Depto. Matemática Pura
José Ever Gonzales, Jefe Depto. Matemática Aplicada
Leandro Galo, Coordinador Maestría de Matemática
Henry Ocampo, Coordinador Carrera de Matemática

Comité Organizador

Carlos Dubon
Lidia Herrera
André Acuña
Darwin Hernandez
Bayron Escalante
Jerson Amaya
Kevin Pineda
Shirly Ordóñez
Luis Rodríguez

Editor General

Henry Ocampo

Editor Asociado

Roberto Duarte

SEMANA DE MATEMÁTICA: CELEBRANDO LOS 53 AÑOS DE LA CARRERA DE MATEMÁTICA EN HONDURAS

EDITOR GENERAL
Henry Ocampo

EDITOR ASOCIADO
Roberto Duarte

Semana de Matemática Niels Henrik Abel. Celebrando los 53 años de la Carrera de Matemática en Honduras.

UNAH, 2025

CONTENIDO

I. ACTIVIDADES	2
Cronograma	3
Enlaces	3
II. CONFERENCIAS	8
1. <i>Angel Rivera</i> : De la malla a la red neuronal: Resolviendo la ecuación del calor en 2D con Diferencias Finitas y el Método Deep Galerkin	9
2. <i>Aubin Arroyo</i> : Museo Virtual de Matemáticas	10
3. <i>César Romero</i> : Acción geométrica del semi-grupo de Lax-Oleinik y su efecto de regularización	11
4. <i>Cristian Cruz</i> : Modelos de predicción en series de tiempo	12
5. <i>Lendy Banegas, Fredy Vides</i> : Metamodelos Estocásticos de Control Prescriptivo y Estrategias de Paso Estable para Procesos Cognitivos y de Decisión	13
6. <i>Jean Bernard Hayet</i> : La IA al servicio de la seguridad vial: Predicción de trayectorias en entornos urbanos	14
7. <i>José Ever Gonzales</i> : La eficacia de los algoritmos genéticos para la optimización inteligente de hiperparámetros en algoritmos de Machine Learning	15
8. <i>Jose Perea</i> : Análisis Topológico de Series de Tiempo	16
9. <i>Leandro Galo</i> : El Muro de la Imposibilidad: Abel y la Búsqueda de la Fórmula Perdida	17
10. <i>Marvin Villafranca, Cristian Cruz</i> : Modelo VAR Integrado con Volatilidad Estocástica Multivariada y Errores de Cola Pesada	18

11. <i>Pedro Molina</i> : Modelos de espacio de estados con filtración de partículas aplicado a un modelo macroeconómico DSGE	19
12. <i>Roberto Duarte</i> : Clustering Robusto	20
13. <i>Sergio Gómez, Ansgar Ungel, Ilaria Perugia</i> : Método Local Discontinuous Galerkin que preserva la estructura para sistemas no lineales de difusión cruzada	21
III. CURSOS	22
14. <i>Henry Ocampo</i> : Machine Learning en Python	23
15. <i>Leonel Obando</i> : Análisis Topológico de Datos	24
IV. POSTERS	25
V. Autores	34
Autores	35

ACTIVIDADES

Cronograma

Figure 1: Calendario de actividades Semana de Matemática 2025 - Niels Henrik Abel

HORA	LUNES 8-sep	MARTES 9-sep	MIÉRCOLES 10-sep	JUEVES 11-sep	VIERNES 12-sep
08:00 - 09:00	Curso #1	Curso #1	Curso #1	Curso #1	*Senderismo
09:30 - 10:30	Inauguración	Conferencia #4	Conferencia #8	Conferencia #12	*Torneos
11:00 - 12:00	Conferencia #1	Conferencia #5	Conferencia #9	Conferencia #13	
12:00 - 13:00	Refrigerio	Refrigerio	Refrigerio	Refrigerio	Almuerzo
13:00 - 14:00	Curso #2	Curso #2	Curso #2	Curso #2	**Clausura
14:30 - 15:30	Conferencia #2	Conferencia #6	Conferencia #10	*Posters	
16:00 - 17:00	Conferencia #3	Conferencia #7	Conferencia #11		

Cursos:

Conferencias nacionales:

Conferencias internacionales:

Refrigerios o almuerzos:

*El horario de las actividades puede variar.

**El evento inicia al finalizar los torneos.

Presentación de Posters

Día: jueves 11 de septiembre.
Hora: 02:30 p.m. - 04:30 p.m.
Lugar: Sala Salvador Llopis, edificio F1, UNAH CU.

Clausura

Día: viernes 12 de septiembre.
Hora: 01:30 p.m. - 03:00 p.m.
Lugar: Aula 1, edificio F1, UNAH CU.

Enlaces

Todas las actividades serán transmitidas en vivo a través de la página oficial de la Semana de la Carrera de Matemática en *Facebook*: <https://www.facebook.com/SemanaCarreradeMatematicaUNAH>.

Inauguración

Día: lunes 8 de septiembre.

Hora: 09:30 a.m. - 10:30 a.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/87254740495?pwd=4q155WaAab3dPL7d8bFFBL966st1FQ.1>.

Conferencia #1

Metamodelos Estocásticos de Control Prescriptivo y Estrategias de Paso Estable para Procesos Cognitivos y de Decisión - **Lendy Banegas, Fredy Vides**.

Día: lunes 8 de septiembre.

Hora: 10:30 a.m. - 11:30 a.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/88642051055?pwd=UE4dcQXh2Us26PNDqCss41FGWuPUN1.1>.

Conferencia #2

Museo Virtual de Matemáticas - **Aubin Arroyo**.

Día: lunes 8 de septiembre.

Hora: 02:30 p.m. - 03:30 p.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/83235377031?pwd=ebbThMdRHk8EjBTabaJTqMoBSVisoq.1>.

Conferencia #3

Modelo VAR Integrado con Volatilidad Estocástica Multivariada y Errores de Cola Pesada - **Marvin Villafranca, Cristian Cruz**.

Día: lunes 8 de septiembre.

Hora: 04:00 p.m. - 05:00 p.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/86880470853?pwd=WxJcXniRHdeapZKrMjbXiZ0BTE8c7.1>.

Conferencia #4

Acción geométrica del semi-grupo de Lax-Oleinik y su efecto de regularización - **César Romero**.

Día: martes 9 de septiembre.

Hora: 09:30 a.m. - 10:30 a.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/85948358672?pwd=hBimfmFaHS9mbqZ1SD7RWoTJfXHS9v.1>.

Conferencia #5

La eficacia de los algoritmos genéticos para la optimización inteligente de hiperparámetros en algoritmos de Machine Learning - **José Ever Gonzales**.

Día: martes 9 de septiembre.

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

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/89288329041?pwd=sib3pVdTOYqd0xm9nT2hS6gsWpqXL9.1>.

Conferencia #6

De la malla a la red neuronal: Resolviendo la ecuación del calor en 2D con Diferencias Finitas y el Método Deep Galerkin - **Angel Rivera**.

Día: martes 9 de septiembre.

Hora: 02:30 p.m. - 03:30 p.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/88102895051?pwd=1jZDDiyLyLL3CH4ZsfeTMiMVKDD7uz.1>.

Conferencia #7

La IA al servicio de la seguridad vial: Predicción de trayectorias en entornos urbanos - **Jean Bernard Hayet**.

Día: martes 9 de septiembre.

Hora: 04:00 p.m. - 05:00 p.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/88689433696?pwd=Uc5nJc4jBSrfP0kCic70Irlg6uxkMa.1>.

Conferencia #8

Método Local Discontinuous Galerkin que preserva la estructura para sistemas no lineales de difusión cruzada - **Sergio Gómez**.

Día: miércoles 10 de septiembre.

Hora: 09:30 a.m. - 10:30 a.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/85865270814?pwd=VzwVwZcuf67ST02K10Hb8GaVu871Om.1>.

Conferencia #9

Análisis Topológico de Series de Tiempo - **José Perea.**

Día: miércoles 10 de septiembre.

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

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/82955448026?pwd=bLBh2R1kaiz7qzX5N5AlFo03d6eNGh.1>.

Conferencia #10

El Muro de la Imposibilidad: Abel y la Búsqueda de la Fórmula Perdida -

Leandro Galo.

Día: miércoles 10 de septiembre.

Hora: 02:30 p.m. - 03:30 p.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/82051616267?pwd=Ew1VnUNNXEiUbVrgAeaOeeHbbhxotv.1>.

Conferencia #11

Modelos de predicción en series de tiempo - **Cristian Cruz.**

Día: miércoles 10 de septiembre.

Hora: 04:00 p.m. - 05:00 p.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/81052365288?pwd=PaGGmqcmSCihT2m0O6RbdLxYm83dKb.1>.

Conferencia #12

Modelos de espacio de estados con filtración de partículas aplicado a un modelo macroeconómico DSGE - **Pedro Molina.**

Día: jueves 11 de septiembre.

Hora: 09:30 a.m. - 10:30 a.m.

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/82924842076?pwd=1Y7hYwJApM7L8iiLzS7uQufcweUM8R.1>.

Conferencia #13

Clustering Robusto - **Roberto Duarte.**

Día: jueves 11 de septiembre.

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

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/81052279718?pwd=nQzDrHtheTcUo5DY510TCIvhaVrTUL.1>.

Curso #1

Machine Learning en Python - **Henry Ocampo**.

Días: lunes 8 al jueves 11 de septiembre.

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

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/85299947965?pwd=9nFiAWV3SlqTuRGcxJrMr81kqUNQ8.1>.

Curso #2

Análisis Topológico de Datos - **Leonel Obando**.

Días: lunes 8 al jueves 11 de septiembre.

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

Lugar: Sala de Proyecciones del CRA, UNAH CU.

<https://us06web.zoom.us/j/87156730597?pwd=euK6zHSAgYfGsXYWjgxWmpo33JFBPo.1>.

CONFERENCIAS

De la malla a la red neuronal: Resolviendo la ecuación del calor en 2D con Diferencias Finitas y el Método Deep Galerkin

Angel Rivera

En este trabajo se presentará un análisis comparativo entre dos enfoques para la resolución numérica de la ecuación del calor bidimensional en un dominio cuadrado unitario, con condiciones de frontera de tipo Dirichlet y una condición inicial definida. El primer enfoque corresponde al método clásico de *Diferencias Finitas Explícito* (FTCS), mientras que el segundo emplea el método moderno *Deep Galerkin Method* (DGM), basado en redes neuronales profundas. Se abordará la formulación matemática de ambos métodos, su implementación computacional y se evaluará el desempeño mediante métricas de precisión y tiempos de ejecución. El experimento consistirá en resolver el mismo problema con ambas técnicas, implementando el método de Diferencias Finitas Explícito para aproximar la solución y desarrollando la formulación del Deep Galerkin Method para el mismo caso, definiendo su arquitectura de red y función de pérdida. Finalmente, se realizará una comparación cuantitativa entre ambas aproximaciones en términos de error numérico y tiempo de ejecución, discutiendo sus ventajas y limitaciones en el contexto de la resolución de la ecuación del calor.

Palabras claves: Ecuación del calor, diferencias finitas, deep galerkin method, redes neuronales, modelación numérica.

Referencias

- [1] LeVeque, R. J. (2007). *Finite Difference Methods for Ordinary and Partial Differential Equations: Steady-State and Time-Dependent Problems*. SIAM.
- [2] Sirignano, J., & Spiliopoulos, K. (2018). DGM: A deep learning algorithm for solving partial differential equations. *Journal of Computational Physics*, 375, 1339–1364. <https://doi.org/10.1016/j.jcp.2018.08.029>
- [3] Strikwerda, J. C. (2004). *Finite Difference Schemes and Partial Differential Equations*. SIAM.
- [4] Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686–707.

Museo Virtual de Matemáticas

Aubin Arroyo

En esta presentación realizaremos un recorrido por el Museo Virtual de Matemáticas, un espacio interactivo diseñado para acercar esta disciplina a todo tipo de público. Mostraremos el funcionamiento de la plataforma y exploraremos algunas de las aplicaciones disponibles, que permiten experimentar con conceptos matemáticos de manera visual, dinámica y lúdica. La charla persigue dos objetivos principales: en primer lugar, motivar a los asistentes a visitar el museo, explorarlo y disfrutar de sus recursos; y en segundo lugar, invitarles a compartir la experiencia matemática con familiares y amigos a través de las herramientas que la plataforma ofrece. El propósito del museo es despertar la curiosidad y el interés por las matemáticas de forma creativa, accesible y significativa, contribuyendo a que más personas se acerquen a esta disciplina mediante experiencias interactivas.

Palabras claves: Divulgación, Matemáticas, Museo Virtual.

Acción geométrica del semi-grupo de Lax-Oleinik y su efecto de regularización

César Romero

En el contexto de un Hamiltoniano de Tonelli, Arnaud (2011) describió un elegante mecanismo geométrico que explica una propiedad de regularización del semi-grupo de Lax-Oleinik para un tiempo suficientemente pequeño, previamente introducida por Bernard (2007).

En la primera parte de esta charla, nuestro objetivo es explicar, de manera informal, las ideas principales de este resultado mediante un ejemplo. Posteriormente, analizaremos cómo se puede obtener un enunciado similar para un tiempo arbitrariamente largo, restringiendo la propiedad de regularización a una versión local. Este trabajo está en curso y hace parte de mi proyecto de investigación de doctorado.

Palabras claves: Ecuación de Hamilton-Jacobi, Semi-grupo de Lax-Oleinik, Pseudografos, Regularidad.

Referencias

- [1] Arnaud, M.-C. (2011). Pseudographs and the Lax–Oleinik semi-group: a geometric and dynamical interpretation. *Nonlinearity*, 24(1): 71–78. <https://doi.org/10.1088/0951-7715/24/1/003>
- [2] Bernard, P. (2007). Existence of $C^{1,1}$ critical sub-solutions of the Hamilton–Jacobi equation on compact manifolds. *Ann. Sci. Ec. Norm. Super.* (4), 40(3): 445–452. <https://hal.science/hal-00014965v2/file/lip-dec4.pdf>
- [3] Bernard, P. (2012). The Lax–Oleinik semi-group: a hamiltonian point of view. *Proc. R. Soc. Edinb. Sect. A*. 142(6): 1131–1177. <https://doi.org/10.1017/S0308210511000059>

Modelos de predicción en series de tiempo

Cristian Cruz

En este trabajo se da una introducción a una variedad de modelos de predicción en series de tiempo, estos modelos incluyen los tradicionales como ser el de caminata aleatoria, ARIMA, VAR, GARCH, modelos en espacio de estado y de volatilidad estocástica. También se presentan algunos modelos de aprendizaje automático como ser el Ridge, Lasso, Elastic Net, Random Forest y la Regresión Cuantílica. Se realiza una aplicación y se comparan las predicciones entre los modelos.

Palabras claves: Predicción, series de tiempo, métodos clásicos, aprendizaje automático.

Referencias

- [1] Bishop, C. (2006). Pattern Recognition and Machine Learning. *Springer*.
- [2] Box, G., Jenkins, G., and Reinsel, G. (2008). Time Series Analysis. *Wiley Series in Probability and Statistics*.
- [3] Koenker, R. and Bassett, G. (1978). Regression quantiles. *Econometrica*, 46(1):33–50.
- [4] Lutkepohl, H. (2005). New Introduction to Multiple Time Series Analysis. *Heidelberg: Springer Berlin*.
- [5] Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society, Serie B (Methodological)*, 58(1):267–288.
- [6] West, M. and Harrison, J. (1997). Bayesian Forecasting and dynamics models. *Springer*.

Metamodelos Estocásticos de Control Prescriptivo y Estrategias de Paso Estable para Procesos Cognitivos y de Decisión

Lendy Banegas, Fredy Vides

Este trabajo presenta un marco de cómputo de reservorios estructurados para modelar, predecir y prescribir intervenciones en sistemas adaptativos complejos, con énfasis en estabilidad e interpretabilidad. Los Computadores de Reservorio Estructurados Estocásticamente (SSRCs) incorporan restricciones inducidas por grafos en la conectividad del reservorio, embeddings estructurados para capturar interdependencias latentes y transformaciones de preservación de estabilidad llamadas pasos estables para mitigar desviaciones críticas en las trayectorias del sistema. La metodología integra modelado de señales latentes, manejo de entradas exógenas y dinámica probabilística, lo que permite simular procesos afectados por choques y efectos de memoria prolongada. Un esquema de aprendizaje adaptativo posibilita la actualización en línea de las matrices de acoplamiento conforme se dispone de nuevos datos, facilitando la adaptación en tiempo real. Más allá de la precisión predictiva, el marco enfatiza el control prescriptivo, habilitando el análisis de escenarios y el soporte a la toma de decisiones en ámbitos como los sistemas socioeconómicos y el monitoreo de procesos industriales. Estudios de simulación con datos sintéticos y relevantes por dominio muestran que los SSRCs logran un desempeño robusto bajo incertidumbre, preservando la interpretabilidad estructural.

Palabras claves: Identificación de sistemas, cómputo de reservorios, aprendizaje automático, procesos estocásticos, optimización y control.

Referencias

- [1] Yan, M., Huang, C., Bienstman, P., Tino, P., Lin, W., and Sun, J. (2024). Emerging opportunities and challenges for the future of reservoir computing. *Nature Communications*, 15(1): 2056. <https://doi.org/10.1038/s41467-024-45187-1>
- [2] Ehlers, P. J., Nurdin, H. I., and Soh, D. (2025). Stochastic reservoir computers. *Nature Communications*, 16(1): 3070. <https://doi.org/10.1038/s41467-025-58349-6>
- [3] Banegas, L., and Vides, F. (2025). Stochastically structured reservoir computers for financial and economic system identification. *arXiv preprint arXiv:2507.17115*. <https://arxiv.org/abs/2507.17115>
- [4] Vides, F., Nogueira, I. B. R., Lopez Gutierrez, G., Banegas, L., and Flores, E. (2025). Identifying systems with symmetries using equivariant autoregressive reservoir computers. *arXiv preprint arXiv:2311.09511*. <https://arxiv.org/abs/2311.09511>

La IA al servicio de la seguridad vial: Predicción de trayectorias en entornos urbanos

Jean Bernard Hayet

En esta plática, les introduciré el problema de predicción de trayectorias de peatones, que consiste en inferir qué movimiento va a realizar un peatón en los próximos segundos, a partir de observaciones de lo que hizo hasta ahora. Es un problema que toma particular relevancia por los avances realizados en coches autónomos, ya que poder tener tales predicciones permite a un sistema autónomo anticipar posibles riesgos de colisión. Les mostraré como se ha propuesto resolver este problema con técnicas de aprendizaje profundo, en particular los modelos generativos profundos, que permiten lidiar con la naturaleza multi-modal de las distribuciones predictivas en este contexto. Platicaremos de algunos trabajos de investigación recientes así como de perspectivas a corto y mediano plazo.

Palabras claves: Modelos predictivos, seguridad vial, coches autónomos, aprendizaje automático, aprendizaje profundo, análisis de datos.

Referencias

- [1] A. Gupta, J. Johnson, L. Fei-Fei, S. Savarese and A. Alahi, Social GAN: Socially Acceptable Trajectories with Generative Adversarial Networks, in Proc. of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City, UT, USA, 2018, pp. 2255-2264, doi: 10.1109/CVPR.2018.00240.
- [2] P. Xu, J.B. Hayet and I. Karamouzas, SocialVAE: Human Trajectory Prediction using Timewise Latents, in Proc. of European Conference on Computer Vision, pp. 511-528, 2022, Springer, doi: 10.1007/978-3-031-19772-7-30

La eficacia de los algoritmos genéticos para la optimización inteligente de hiperparámetros en algoritmos de Machine Learning

José Ever Gonzales

La optimización de hiperparámetros (HPO) es un desafío fundamental en el Machine Learning (ML), dado que una configuración adecuada de estos influye drásticamente en el rendimiento y la eficiencia de los modelos. Este proceso, a menudo tedioso y basado en la intuición o la "fuerza bruta" como la búsqueda en cuadrícula (grid search), y métodos más avanzados como la optimización bayesiana, puede ser ineficiente o quedar atrapado en óptimos locales, especialmente en espacios de búsqueda complejos donde la información de gradiente no está disponible.

Los algoritmos genéticos (AGs), inspirados en los principios de la evolución biológica, se presentan como una potente y robusta alternativa para la HPO. Como algoritmos de búsqueda de propósito general, los AGs son capaces de navegar eficazmente espacios de soluciones no lineales, no suaves y de alta dimensionalidad, superando las limitaciones de los métodos tradicionales al evitar óptimos locales. Su naturaleza iterativa y probabilística los hace relativamente insensibles al ruido y su paralelismo implícito les permite explorar múltiples soluciones simultáneamente.

Esta presentación explorará cómo la naturaleza adaptativa de los AGs, combinada con su capacidad para operar sin depender de gradientes, los posiciona como una herramienta clave en la optimización de hiperparámetros de ML.

Palabras claves: Algoritmos genéticos, Optimización de hiperparámetros, Machine Learning, computación evolutiva.

Referencias

- [1] Assunção, F., Lourenço, N., Machado, P., & Ribeiro, B. (2019). DENSER: deep evolutionary network structured representation. *Genet. Program. Evol. Mach.*, 20(1), 5–35. <https://doi.org/10.1007/s10710-018-9339-y>
- [2] Baeck, T., Hoffmeister, F., & Schwefel, H. (1991). A survey of evolution strategies. In *Proceedings of the Fourth International Conference on Genetic Algorithms* (pp. 2–9). Morgan Kaufmann.
- [3] Bergstra, J., Bardenet, R., Bengio, Y., & Kégl, B. (2011). Algorithms for Hyper-Parameter Optimization. In *Proceedings of NIPS-11*.
- [4] Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley.

Análisis Topológico de Series de Tiempo

Jose Perea

Las series de tiempo son ubicuas en aplicaciones científicas y tareas de aprendizaje automático, tales como la clasificación, cuantificación de recurrencia, imputación de datos y detección de anomalías. En esta charla, describiré cómo se pueden aprovechar herramientas de la topología algebraica, el análisis y los sistemas dinámicos para abordar algunas de estas preguntas, y en particular, su relevancia en aplicaciones de aprendizaje automático.

Palabras claves: Análisis topológico de datos, series de tiempo, homología persistente.

El Muro de la Imposibilidad: Abel y la Búsqueda de la Fórmula Perdida

Leandro Galo

Durante siglos, los matemáticos más brillantes persiguieron un sueño: encontrar una fórmula general para resolver ecuaciones de quinto grado, tal como existía para los grados inferiores. Pero en 1824, un joven genio noruego, Niels Henrik Abel, demostró lo imposible: ese sueño era inalcanzable. Esta charla explorará la revolucionaria idea de Abel —que a veces probar la imposibilidad es más poderoso que encontrar una solución— y cómo su teorema no cerró una puerta, sino que abrió las compuertas al álgebra moderna, la teoría de grupos y nuevas formas de pensar las matemáticas. A través de esta plática se abordarán los siguientes puntos:

- El desafío histórico de las ecuaciones polinómicas.
- La vida trágica y brillante de Niels Henrik Abel.
- El Teorema de Abel-Ruffini: por qué no puede existir una "fórmula para la quintática".
- El legado de la imposibilidad: rigor, simetría y nuevos caminos para la matemática.

Palabras claves: Ecuaciones polinómicas, resolución por radicales, imposibilidad en matemática, Teorema de Abel-Ruffini, simetría, álgebra abstracta.

Referencias

- [1] Abel, N. H. (1824). Mémoire sur les équations algébriques, où on démontre l'impossibilité de la résolution de l'équation générale du cinquième degré. *Journal für die reine und angewandte Mathematik (Crelle's Journal)*, 1, 65–84.
- [2] Derbyshire, J. (2006). *Unknown Quantity: A Real and Imaginary History of Algebra*. Joseph Henry Press.
- [3] Hellman, H. (2006). *Great Feuds in Mathematics: Ten of the Liveliest Disputes Ever*. John Wiley & Sons.
- [4] Artin, E. (1998). *Galois Theory*. Dover Publications.
- [5] Pesic, P. (2003). *Abel's Proof: An Essay on the Sources and Meaning of Mathematical Unsolvability*. The MIT Press.

Modelo VAR Integrado con Volatilidad Estocástica Multivariada y Errores de Cola Pesada

Marvin Villafranca, Cristian Cruz

Los modelos autorregresivos vectoriales (VAR) son usados para capturar las relaciones dinámicas de series de tiempo multivariadas. Por otro lado, los modelos de volatilidad estocástica multivariada (MSV) permiten modelar la varianza cuando cambia en el tiempo. La distribución t de Student es usada para modelar valores en las series de tiempo que a menudo son de magnitud extrema. Por lo anterior, en este trabajo se propone la integración de un modelo VAR, un modelo MSV y una distribución t de Student (VAR-MSV- t). La elección del orden VAR-MSV- t más adecuado se lleva a cabo por medio del Criterio de Información de Desviación (DIC). Se presentan fórmulas para estimar la asimetría de Mardia y la curtosis de Koziol del modelo. Se hizo una aplicación a tres variables macroeconómicas clave para los Estados Unidos. Agregamos el índice del mercado de valores SP500 y se interpretaron los resultados. Para estimar los parámetros se usan métodos de Monte Carlo vía Cadenas de Markov (MCMC). Los resultados indican que el modelo captura las relaciones dinámicas, así como la varianza cambiando en el tiempo y los valores de magnitud extrema de manera eficaz.

Palabras claves: volatilidad estocástica multivariada, error de colas pesadas, asimetría multivariada, curtosis multivariada.

Referencias

- [1] Ishihara, T., and Omori, Y. (2012). Efficient Bayesian estimation of a multivariate stochastic volatility model with cross leverage and heavy-tailed errors. *Computational Statistics and Data Analysis*, 11: 3674–9473. <https://doi.org/10.1016/j.csda.2010.07.015>
- [2] Cruz Torres, C. A., and Villafranca Rivera, M. L. (2024). Modelos autorregresivos vectoriales integrados con volatilidad estocástica multivariada aplicado a la economía de Estados Unidos en el periodo de 1948–2019. *Aglala*, 15(2): 116–142. <https://revistas.uninunez.edu.co/index.php/aglala/article/view/2523>
- [3] Jammalamadaka, S. R., Taufer, E., and Terdik, G. H. (2021). On multivariate skewness and kurtosis. *Sankhya A: The Indian Journal of Statistics*, 2: 607–644. <https://doi.org/10.1007/s13171-020-00211-6>
- [4] Kollo, T. (2008). Multivariate skewness and kurtosis measures with an application in ICA. *Journal of Multivariate Analysis*, 10: 2328–2338. <https://doi.org/10.1016/j.jmva.2008.02.033>

Modelos de espacio de estados con filtración de partículas aplicado a un modelo macroeconómico DSGE

Pedro Molina

En esta investigación se desarrolla un modelo Dinámico Estocástico de Equilibrio General (DSGE, por sus siglas en inglés) de la cual surgen como una evolución natural de los modelos de crecimiento neoclásico. Estos modelos combinan el rigor macroeconómico con estructuras dinámicas y estocásticas, permitiendo evaluar cuantitativamente las políticas económicas. El modelo propuesto por ocho ecuaciones de equilibrio, se representó en su forma de espacio de estados multivariado, lo que facilita la aplicación de técnicas secuenciales de Monte Carlo (SMC), en particular el filtro de partículas dentro de un marco Bayesiano, con la idea de evitar linealizar el modelo lo cual permite preservar la naturaleza completa para la estimación del modelo. Durante el proceso de filtrado, se emplearon técnicas numéricas como la cuadratura de Gauss-Hermite y la interpolación mediante elementos finitos para aproximar esperanzas racionales que no tienen solución analítica. Asimismo, se incorporaron técnicas de estimación robusta. La base de datos proviene del sistema FRED (Federal Reserve Broad, EE. UU), enfocándose en la estimación y la predicción de tres variables macroeconómicas fundamentales: g_t (PIB), π_t (Inflación) y r_t (Tasa de interés) de manera trimestral, realizando estimaciones de los años 2000 – 2023 y predicciones para el año 2024. Los resultados obtenidos demostraron que utilizar técnicas Secuenciales de Monte Carlo y estimación robusta en modelos DSGE, se tiene estimaciones y predicciones eficientes.

Palabras claves: Modelos DSGE, modelos de espacio de estados, filtros de partículas, Gauss-Hermite, elemento finito, PIB, inflación, Tasa de interés.

Referencias

- [1] J. Bernardo and A. Smith. Bayesian Theory. John Wiley & Sons, 1994
- [2] R. L. Burden and J. D. Faires. Numerical Analysis. Brooks/Cole Cengage Learning, 9th edition, 2011.
- [3] J. Fernández-Villaverde and J. F. Rubio-Ramírez. Estimating macroeconomic models: A likelihood approach. *Review of Economic Studies*, 74(4):1059–1087, 2007
- [4] C. A. C. Torres. Modelos Dinámicos Estocásticos de Equilíbrio Geral com Choques Heterocedásticos. Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, Brasil, 2015
- [5] P. J. Huber and E. M. Ronchetti. Robust Statistics. Wiley Series in Probability and Statistics. Wiley, 2nd edition, 2009. ISBN 978-0-470-12990-6

Clustering Robusto

Roberto Duarte

El clustering es una técnica de aprendizaje no supervisado cuyo objetivo es organizar un conjunto de datos en grupos de tal manera que estos sean los más similares dentro de ellos y los mas diferentes entre ellos. El método más popular debido a su simplicidad es el K-medias, sin embargo su dependencia de promedios lo hace sensible a valores atípicos. Una solución es proponer una versión robusta que minimiza una escala τ de las distancias. Simulaciones por el método de Monte Carlo muestran la reducción de la influencia de los valores atípicos y mostrando además que los centros de los grupos están bien definidos y son fuertemente consistentes.

Palabras claves: Robustez, M-estimador, Clustering

Referencias

- [1] González, Juan Domingo. (2019). Métodos de clustering robustos. (Tesis Doctoral. Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales.)
- [2] Maronna, R. A., Martin, R. D., Yohai, V. J., & Salibián-Barrera, M. (2019). Robust statistics: theory and methods (with R). John Wiley & Sons.

Método Local Discontinuous Galerkin que preserva la estructura para sistemas no lineales de difusión cruzada

Sergio Gómez, Ansgar Unga, Ilaria Perugia

La principal dificultad en el diseño de métodos para la aproximación numérica de sistemas de difusión cruzada es que la matriz de difusión puede ser no simétrica y no ser semidefinida positiva. En esta charla, presentamos un método Local Discontinuous Galerkin de alto orden para la discretización de sistemas no lineales de difusión cruzada (2). Basándonos en el marco *boundedness-by-entropy* introducido en (3), reformulamos el problema original en términos de una variable de entropía.

El método está diseñado para que:

- i) preserve naturalmente la positividad y acotación de la solución exacta, incluso si no se dispone de un principio del máximo;
- ii) las no linealidades no aparezcan dentro de los operadores diferenciales, reduciendo así el costo computacional del método;
- iii) se imponga débilmente una regla de la cadena que involucra las variables auxiliares, lo que nos permite demostrar una versión discreta de estabilidad de la entropía.

Presentamos varios experimentos numéricos que validan nuestros resultados teóricos. Además, mostramos algunos resultados obtenidos para modelos de proteínas relacionadas con enfermedades neurodegenerativas (1).

Palabras claves: sistemas de difusión cruzada; método Local Discontinuous Galerkin; preservación de estructura; variable de entropía.

Referencias

- [1] P.-F. Antonietti, M. Corti, S. Gómez, and I. Perugia. A structure-preserving LDG discretization of the Fisher-Kolmogorov equation for modeling neurodegenerative diseases. arXiv:2504.05784, 2025.
- [2] S. Gómez, A. Jüngel, and I. Perugia. Structure-preserving Local Discontinuous Galerkin method for nonlinear cross-diffusion systems. arXiv:2406.17900, 2024.
- [3] A. Jüngel. The boundedness-by-entropy method for cross-diffusion systems. *Nonlinearity*, 28:1963–2001, 2015.

CURSOS

Machine Learning en Python

Henry Ocampo

Descripción

El curso de Machine Learning en Python está diseñado para proporcionar una introducción a los fundamentos y a las técnicas más utilizadas en este campo, con un enfoque especial en el aprendizaje supervisado. A lo largo del curso, los estudiantes aprenderán a procesar y visualizar datos, así como a implementar algoritmos de machine learning utilizando la librería `scikit-learn` y otras herramientas del ecosistema Python. Estos conocimientos se aplicarán en proyectos prácticos que permitirán consolidar las habilidades adquiridas.

Contenido

No.	Tema	Descripción
1	Introducción al aprendizaje supervisado	Conceptos básicos y aplicaciones
2	Preprocesamiento de datos	Limpieza, normalización y transformación de datos
3	Visualización de datos	reducción de dimensión, PCA
4	Modelos supervisados	árboles de decisión, K-Vecinos más cercanos
5	Evaluación de modelos	Métricas de evaluación y validación

Referencias bibliográficas

- [1] James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). An Introduction to Statistical Learning: with Applications in Python. Springer Nature.

Recursos electrónicos

- *Kaggle dataset* <https://www.kaggle.com/datasets>.

Análisis Topológico de Datos

Leonel Obando

Descripción

El presente curso ofrece una introducción a los fundamentos del Análisis Topológico de Datos (TDA), un área emergente que combina matemáticas puras, topología y aplicaciones computacionales para estudiar la “forma” de conjuntos de datos. A lo largo de cuatro sesiones, los estudiantes aprenderán a construir modelos topológicos a partir de datos discretos, entenderán cómo la homología captura información de conectividad y agujeros en distintas dimensiones, y descubrirán cómo la homología persistente permite distinguir patrones significativos del ruido. El curso tiene un enfoque conceptual y visual, empleando ejemplos gráficos y aplicaciones prácticas. No se requiere conocimiento previo de álgebra homológica, pero sí familiaridad con conceptos básicos de topología.

Contenido

No.	Tema	Descripción
1	Topología y datos	Motivación, ejemplos iniciales, complejos simpliciales (Vietoris–Rips)
2	Homología simplicial	Intuición de H_0 , H_1 , H_2 , ciclos y bordes, ejemplos simples
3	Homología persistente	Filtraciones, evolución topológica, códigos de barras y diagramas de persistencia
4	Aplicaciones y herramientas	Biología, neurociencia, materiales, imagenología; software (GUDHI)

Referencias bibliográficas

[1] Carlsson, G. (2009). Topology and data. *Bulletin of the American Mathematical Society*, 46(2), 255–308.

[2] Ghrist, R. (2008). Barcodes: The persistent topology of data. *Bulletin of the American Mathematical Society*, 45(1), 61–75

Recursos electrónicos

- GUDHI Library (Python/C++): <http://gudhi.gforge.inria.fr/>.

POSTERS



SISTEMA DE APOYO AL DIAGNOSTICO DE CANCER DE MAMA CON CLASIFICACION MULTICLASE MEDIANTE REDES NEURONALES CONVOLUCIONALES

ANYELO JASSIEL BACA BARAHONA

UNIVERSIDAD NACIONAL AUTONOMA DE HONDURAS.



UNAH

INTRODUCCIÓN

El cáncer de mama es una de las neoplasias más frecuentes y principal causa de Muerte por cáncer en la población femenina. El diagnóstico mediante biopsias constituye la mejor confirmación definitiva de la enfermedad. Sin embargo la interpretación de las imágenes de biopsias presenta desafíos significativos que incluye la complejidad de los patrones tisulares, la variabilidad inter observador entre patólogo y el análisis exhaustivo requerido para cada caso.

Este estudio se propone desarrollar y Validar un modelo de CNN para el análisis automatizado de imágenes de biopsias de mama, implementando un Sistema de clasificación multiclase que distinga entre 8 categorías las cuales corresponde a 4 tejidos benigno (adenosis, tubular adenoma, phyllodes tumor, fibroadenoma) y 4 tejidos maligno (ductal carcinoma, lobular carcinoma papillary carcinoma, mucinous carcinoma). Este enfoque tiene como objetivo incrementar la precisión diagnóstica y como herramienta de apoyo para los patólogos.

METODOLOGÍA

Este estudio implementó la arquitectura YOLOv11m para la detección y clasificación de cáncer de mama en imágenes histopatológicas del dataset BreakHis, utilizando 1859 imágenes anotadas manualmente con LabelStudio en formato YOLO para las 8 categorías histopatológicas (4 benignas y 4 malignas). El preprocesamiento incluyó redimensionamiento a 640x640 píxeles, normalización, aumento de datos con Mosaic16 y RandomAffine, y balanceo de clases. El entrenamiento, con una duración total de 3 horas, 45 minutos y 16 segundos, constó de 300 épocas con un learning rate de 0.001 y validación cruzada 5-fold. Los resultados demostraron un excelente rendimiento del modelo, alcanzando un **mAP@0.5 del 96%** y un **mAP@0.5:0.95 del 88%**. Adicionalmente, se desarrolló una interfaz gráfica (GUI) como herramienta de uso práctico que permite cargar los pesos del modelo entrenado, seleccionar áreas de interés en las imágenes histopatológicas y realizar predicciones en tiempo real sobre dichas áreas. Esta herramienta facilita la implementación clínica del modelo, ofreciendo una detección precisa y clasificación confiable que supera los desafíos de variabilidad morfológica en las muestras histopatológicas.

RESULTADOS




FIG. 1. Curvas de pérdida y precisión.




FIG. 2. Ejemplo de Mosaic16 de entrenamiento.

Confusion Matrix

	adenosis	ductal_carcinoma	lobular_carcinoma	phyllodes_tumor	tubular_adenoma	background
adenosis	15	0	0	0	0	0
ductal_carcinoma	0	15	0	0	0	0
lobular_carcinoma	0	0	15	0	0	0
phyllodes_tumor	0	0	0	15	0	0
tubular_adenoma	0	0	0	0	15	0
background	0	0	0	0	0	15

FIG. 3. Matriz de confusión.




FIG. 4. GUI del sistema en biopsia WSIs.




FIG. 5. GUI del sistema en área específica de biopsia.

CONCLUSIÓN

El modelo basado en YOLOv11m demuestra tener una precisión considerable en la detección y clasificación de las 8 categorías de tejido mamarios. La implementación de una GUI intuitiva permite a los patólogos seleccionar áreas de interés específicas para su análisis permitiendo su aplicación clínica como una herramienta de apoyo.

Como recomendación se sugiere actualizaciones continuas del modelo incorporando nuevas variantes para mejorar la calidad del data set.

REFERENCIAS

- Bukun. (2020). *BreakHis dataset* [Dataset].
Kaggle. <https://www.kaggle.com/datasets/ambarish/breakhis>
- Elkenawy, El-Sayed, M., Ewees, A. A., Al-qaness, M. A. A., & Kim, S. (2024). Greylag goose optimization and multilayer perceptron for enhancing lung cancer classification. *Scientific Reports*, 14(1), 23784. <https://doi.org/10.1038/s41598-024-72013-x>
- Hirra, I., Ahmad, M., Hussain, A., Ashraf, M. U., Saeed, I. A., Qadri, S. F., Alghamdi, N. S., & Alfakheh, A. S. (2021). Breast cancer classification from histopathological images using patch-based deep learning modeling. *IEEE Access*, 9, 24273-24287. <https://doi.org/10.1109/ACCESS.2021.3056516>
- Rahman, H., Terence, S., Robinson, N., & Nallathambi, G. (2023). Efficient breast cancer diagnosis from complex mammographic images using deep convolutional neural network. *Computational Intelligence and Neuroscience*, 2023, 1-11. <https://doi.org/10.1155/2023/7717712>

DETECCIÓN DE CÁNCER MEDIANTE ANÁLISIS DE IMÁGENES CON REDES NEURONALES CONVOLUCIONALES



AXEL XAVIER SIERRA HERNÁNDEZ

UNAH- axl.sierra2002@gmail.com

INTRODUCCIÓN

El cáncer colorrectal representa una de las principales causas de mortalidad por cáncer a nivel mundial, y su detección temprana es fundamental para mejorar el pronóstico de los pacientes. Sin embargo, el diagnóstico convencional, requiere tiempo, experiencia especializada y puede estar sujeto a variaciones entre observadores.

Este estudio propone un modelo de clasificación binaria para la detección de cáncer colorrectal, utilizando imágenes histopatológicas. Este proyecto busca aportar una herramienta que complemente el trabajo de los patólogos, reduciendo tiempos de diagnóstico y aumentando la precisión clínica.

METODOLOGÍA

Se implementó un modelo basado en la arquitectura ResNet50, una red neuronal convolucional profunda. El entrenamiento se realizó en dos fases: primero, con las capas convolucionales congeladas; y luego, mediante ajuste fino (fine-tuning), permitiendo una actualización parcial de las capas profundas.

Se utilizaron dos bases de datos públicas:

- 1. **NCT-CRC-HE-100K:** Utilizado para el entrenamiento y validación interna. Contiene 100,000 imágenes.
- 2. **CRC-VAL-HE-7K:** Utilizado exclusivamente para la validación externa. Contiene 7,180 imágenes provenientes de pacientes distintos a los del conjunto de entrenamiento.

Durante el entrenamiento se emplearon técnicas de aumento de datos. El desempeño final se evaluó mediante métricas como precisión, F1-score y AUC.

RESULTADOS

Se evaluó el rendimiento del modelo sobre el conjunto de prueba.




Figura 1 . Comparación de Matrices de Confusión por Umbral





Figura 3 . Comparación de Métricas de Rendimiento por Umbral




Figura 4 . Análisis Grad-CAM: Detección de Cáncer en Imágenes Histopatológicas de Predicción Benigna




Figura 5 . Análisis Grad-CAM: Detección de Cáncer en Imágenes Histopatológicas de Predicción Maligna

CONCLUSIÓN Y DISCUSIÓN

Este proyecto aporta un modelo de clasificación binaria para la detección de cáncer colorrectal a partir de imágenes histopatológicas. El principal aporte radica en la implementación de una arquitectura robusta combinada con transferencia de aprendizaje.

Desde el punto de vista práctico, esta herramienta puede integrarse para apoyar a los patólogos en la revisión de biopsias, reduciendo tiempos de análisis, minimizando errores diagnósticos y contribuyendo a la detección temprana del cáncer colorrectal.

REFERENCIAS BIBLIOGRÁFICAS

1. TensorFlow. (n.d.). TensorFlow Documentation. TensorFlow. https://www.tensorflow.org/api_docs
2. James, G., Witten, D., Hastie, T., Tibshirani, R., & Bryan, J. (2023). An Introduction to Statistical Learning: with Applications in Python (1st ed.). Springer. <https://www.statlearning.com/>
3. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. Medical Image Analysis, 42, 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
4. Kather, J. N., Halama, N., & Marx, A. (2019). NCT-CRC-HE-100K: A large-scale histopathology image dataset for colorectal cancer. Zenodo. <https://doi.org/10.5281/zenodo.1214456>
5. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 770–778). <https://doi.org/10.1109/CVPR.2016.90>

Resumen

Este trabajo estudia aproximaciones para la función factorial en valores pequeños y grandes, extendida a los reales mediante la función Gamma. Se analizan métodos clásicos: como la aproximación de Stirling, eje central en esta investigación y refinamientos modernos: Stirling+1 y Ramanujan, evaluando su precisiones para distintos rangos numéricos. El objetivo principal es comparar su eficacia teórica y aplicada mediante análisis numéricos.

Aproximaciones Clásicas y Modernas

La función Gamma $\Gamma(n+1)$ es la herramienta teórica exacta por excelencia, ya que generaliza el factorial a números complejos y no enteros, esta función no es una aproximación sino una definición exacta del factorial, para cálculos exactos o generalizaciones. La formula integral es:

$$\Gamma(n+1) = \int_0^{\infty} t^n e^{-t} dt \quad n \geq 0, n \in \mathbb{N}$$

La fórmula de Stirling, es un método de aproximación clásica para estimar factoriales y valores de la función Gamma $\Gamma(n+1)$. La fórmula completa es la siguiente:

$$n! \approx \sqrt{2\pi n} \left(\frac{n}{e}\right)^n, \text{ error} \sim \frac{1}{12n}.$$

Su versión más básica es rápida, pero poco precisa con números pequeños, aunque mejora significativamente al aumentar el valor de n .

La fórmula de Stirling+1, surgió como una extensión con un término correctivo y viene dada por:

$$n! \approx \sqrt{2\pi n} \left(\frac{n}{e}\right)^n \left(1 + \frac{1}{12n}\right), \text{ error} \sim \frac{1}{288n^2}$$

esta versión mejora la aproximación básica, como también mejora significativamente la precisión para n pequeños o moderados.

La fórmula de aproximación de Ramanujan es una alternativa más precisa a la fórmula de Stirling, especialmente útil para valores de n pequeños o moderados.

Su formula es:

$$n! \approx \sqrt{2\pi n} \left(\frac{n}{e}\right)^n \left(1 + \frac{1}{2n} + \frac{1}{8n^2} + \frac{1}{240n^3}\right)^{\frac{1}{4}}, \text{ error} \sim \frac{-1}{1440n^4}$$

Aunque Stirling es práctica para estimaciones rápidas, la aproximación de Ramanujan, basada en una profunda intuición matemática, es la opción preferida cuando se busca la máxima exactitud.

Resultados

Método	Precisión $n = 1$	Precisión $n = 10$	Complejidad
Stirling básica	$\sim 8\%$ error	$\sim 0,8\%$ error	Muy simple
Stirling+1 término	$\sim 0,7\%$ error	$\sim 0,008\%$ error	Simple
Ramanujan	$\sim 0,01\%$ error	$\sim 10^{-7}\%$ error	Menos simple
Función Gamma	Exacta	Exacta	Evaluación numérica requerida

Tabla 1. Comparación de métodos de aproximación factorial




Figura 1. Comparación de aproximación para 1!.




Figura 2. Comparación de aproximación para 10!.

Conclusiones

- La fórmula de Stirling es ideal para análisis teóricos y comportamiento asintótico, gracias a su simplicidad y elegancia matemática, aunque pierde precisión para valores pequeños de n .
- Las aproximaciones de Stirling+1 y Ramanujan son superiores en aplicaciones numéricas que exigen alta precisión, ya que sus términos de corrección adicionales minimizan errores, incluso con n pequeño, siendo cruciales en simulaciones o algoritmos sensibles a decimales.

Referencias

- Conrad, Keith, *Stirling's Formula*, University of Connecticut, 2008. Disponible en: <https://kconrad.math.uconn.edu/blurbs/analysis/stirling.pdf>.
- Bender, Carl M. and Orszag, Steven A., *Advanced Mathematical Methods for Scientists and Engineers*, McGraw-Hill, New York, 1978.



Predicción de Series Temporales de Precipitaciones Pluviales mediante Redes Neuronales

Jorge Alberto Mendez Lopez
UNAH - jamendezl@unah.hn

Escuela de Matemática y Ciencias de la Computación



Introducción

El análisis de series temporales es una herramienta fundamental para la comprensión de fenómenos naturales, especialmente aquellos asociados con la variabilidad climática y los eventos meteorológicos. En este contexto, la predicción de la precipitación pluvial se vuelve una tarea clave, especialmente en países como Honduras, donde los eventos climáticos extremos, como lluvias intensas, inundaciones o sequías, tienen un impacto significativo en la economía, la seguridad alimentaria y el bienestar de la población. En este trabajo se desarrolla un modelo predictivo de precipitación pluvial mediante el uso de redes neuronales aplicado a series temporales, utilizando datos históricos proporcionados por el Instituto Hondureño de Ciencias de la Tierra (IHCIT) de la Universidad Nacional Autónoma de Honduras (UNAH).

Datos y Preprocesamiento


Se utilizaron datos diarios de precipitación registrados por la estación meteorológica del IHCIT-UNAH entre 1979 y 2023. Los datos fueron normalizados utilizando el Escalado Min-Max.

$$z'_t = \frac{z_t - \min(Z)}{\max(Z) - \min(Z)}$$

Pasamos los datos a una forma matricial. Llamando un número entero k la longitud de la ventana (numero de columnas) donde $K = N - L + 1$, $1 < L < N$, N es el número total de observaciones. Mapeamos la serie temporal original en una secuencia de vectores rezagados de tamaño L formando K vectores rezagados

$$H_i = (z_i, \dots, z_{i+L-1})^T \quad (1 \leq i \leq K)$$

Arquitectura del Modelo



Resultados




Figura 1. Estimación y predicción del modelo.




Figura 2. Error en datos de entrenamiento.




Figura 3. Distribución de errores en datos de entrenamiento.




Figura 4. Distribución de errores en datos de prueba.




Figura 5. Error en datos de prueba.




Figura 6. Predicción del modelo (último año).

Conclusiones y Discusión

El modelo fue capaz de capturar de manera efectiva las tendencias generales y patrones recurrentes en las series temporales de precipitación pluvial y mostró una capacidad predictiva prometedora. Se recomienda la integración de variables meteorológicas adicionales, como la temperatura y la humedad relativa, con el fin de mejorar la precisión de las predicciones y analizar el impacto de dichas variables, especialmente en la detección de eventos extremos.

Referencias

- [1] B. Cai, S. Yang, L. Gao, and Y. Xiang, "Hybrid variational autoencoder for time series forecasting," *Knowledge-Based Systems*, vol. 281, p. 111079, 2023.
- [2] N. Golyandina and A. Zhigljavsky, *Singular Spectrum Analysis for Time Series*, 2nd ed., Springer, 2013.
- [3] H. Xu, Z. Guo, Y. Cao, X. Cheng, Q. Zhang, and D. Chen, "Research on short-term precipitation forecasting method based on CEEMDAN-GRU algorithm," *Scientific Reports*, vol. 14, no. 1, p. 31885, 2024.



Matroides orientados - Aplicación para resolver el poker

Leonel Josué Maradiaga Ordóñez - lmaradiago@unah.hn
Leonel Alejandro Obando Reyes - leonelobando@unah.edu.hn

Escuela de Matemáticas y Ciencias de la Computación, Universidad Nacional Autónoma de Honduras



Resumen

En este trabajo se explora el uso de matroides orientados como herramienta matemática para el análisis estratégico en juegos secuenciales, particularmente en el póker. Estos objetos combinan elementos de álgebra lineal y teoría de grafos. El objetivo es vincular estas estructuras con el algoritmo de minimización de remordimiento contrafactual (CFR), una técnica ampliamente utilizada para encontrar equilibrios de Nash en juegos de información imperfecta. El algoritmo aprende estrategias óptimas desde cero, incluyendo comportamientos complejos como bluffing y slowplay. Nuestra propuesta utiliza matroides orientados para representar el espacio de decisiones y estrategias en el CFR, lo que permite desarrollar modelos más balanceados y difíciles de explotar. Este enfoque establece una conexión novedosa entre la teoría de matroides y la teoría de juegos, con potencial aplicación en optimización.

Matroides

Un **matroide** generaliza la noción de independencia lineal en espacios vectoriales. Formalmente, un matroide es un par ordenado $(E, \mathcal{I})$, donde E es finito (conjunto suelo o "ground set") y $\mathcal{I}$ es una colección de subconjuntos de E (colección de subconjuntos independientes) que cumple las siguientes propiedades:

- (1) **No vacío:** $\emptyset \in \mathcal{I}$.
- (2) **Propiedad hereditaria:** Si $I_1 \in \mathcal{I}$ y $I_2 \subseteq I_1$, entonces $I_2 \in \mathcal{I}$.
- (3) **Propiedad de intercambio:** Si $I_1, I_2 \in \mathcal{I}$ y $|I_1| < |I_2|$, entonces existe un elemento $x \in I_2 \setminus I_1$ tal que $I_1 \cup \{x\} \in \mathcal{I}$.

Circuitos

Los circuitos C son los conjuntos independientes mínimos, es decir, son subconjuntos de E que satisfacen $C \notin \mathcal{I}$ y $\{C \setminus \{z\}\} \in \mathcal{I}$ para cualquier $z \in C$. Sea C un conjunto de conjuntos de un conjunto E . Entonces E es la colección de circuitos de un matroide en E si y solo si C tiene las siguientes propiedades:

- (C1) $\emptyset \notin C$.
- (C2) Si C_1, C_2 son miembros de C y $C_1 \subseteq C_2$, entonces $C_1 = C_2$.
- (C3) Si C_1, C_2 son miembros distintos de C y $e \in C_1 \cap C_2$, entonces existe un miembro C_3 de C tal que $C_3 \subseteq (C_1 \cup C_2) \setminus \{e\}$.

$$\begin{matrix} & 1 & 2 & 3 & 4 & 5 & 6 & 7 \\ a & 1 & 0 & 0 & 1 & 0 & 0 & 0 \\ b & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ c & 0 & 1 & 0 & 1 & 1 & 1 & 0 \\ d & 0 & 0 & 1 & 0 & 1 & 1 & 0 \end{matrix}$$




Figura 1. Grafo de la matriz

Matroides orientados

Una colección C de subconjuntos orientados de un conjunto E es el conjunto de **circuitos orientados** de una **matroide orientado** sobre E si y solo si satisface los siguientes axiomas:

1. $\emptyset \notin C$.
2. $C = -C$. (Simetría)
3. $\forall X, Y \in C$, si $X \subseteq Y$, entonces $X = Y$ o $X = -Y$. (Incomparabilidad)
4. $\forall X, Y \in C$, $X \neq -Y$, $y \in X^+ \cap Y^-$ hay un $Z \in C$ tal que:
 - $Z^+ \subseteq (X^+ \cup Y^+) \setminus \{y\}$
 - $Z^- \subseteq (X^- \cup Y^-) \setminus \{y\}$ (Axioma de Eliminación Débil)

Algoritmo CFR

$$R_t^T(I, a) = \frac{1}{T} \sum_{t=1}^T \pi_{-t}^a(I) (u_t(\sigma_{t-1}^a(I)) - u_t(\sigma_t^a(I)))$$

Definimos $R_t^{T+1}(I, a) = \max(R_t^T(I, a), 0)$, y la estrategia para el tiempo $T + 1$ es:

$$\sigma_t^{T+1}(I)(a) = \begin{cases} \frac{R_t^{T+1}(I, a)}{\sum_{a \in A(I)} R_t^{T+1}(I, a)} & \text{si } \sum_{a \in A(I)} R_t^{T+1}(I, a) > 0 \\ \text{en otro caso} \end{cases}$$

Algorithm 1: Algoritmo de cálculo de ganancias en tiempo T

Input: Inicializamos **ganancias** en tiempo 0 para cada acción en cada infoSet

Output: **Ganancias** en tiempo T

1. $\vec{p}^0 \leftarrow$ Normalizamos las ganancias;
2. **for** $t = 1, \dots, T$ **do**
3. Calculamos **utilidades** para $\vec{p}^{t-1}$ en cada acción del infoSet;
4. Actualizamos **ganancias** cargadas (weighted) por la probabilidad de alcance;
5. $\vec{p}^t \leftarrow$ Normalizamos las **ganancias**;
6. **end**
7. **return** $\vec{p}^T$;

Experimentos




Figura 2. Opciones posibles para el juego




Figura 3. Mil iteraciones, convergencia al equilibrio de Nash

InfoSet	Strat:Bet	Strat:Pass	Belief:H	Belief:L	TotGain:Bet	TotGain:Pass
K	0.80	0.20	0.50	0.50	4.31	1.06
Q	0.12	0.88	0.50	0.50	1.03	7.22
J	0.24	0.76	0.50	0.50	2.47	7.74
Kb	0.95	0.05	0.54	0.46	8.75	0.50
Qb	0.11	0.89	0.21	0.79	0.60	4.96
Jb	0.32	0.68	0.18	0.82	1.95	4.21
Kb	0.97	0.03	0.34	0.66	15.28	0.50
Qb	0.41	0.59	0.77	0.23	4.24	6.00
Jb	0.04	0.96	0.87	0.13	0.50	12.54
Kpb	0.97	0.03	0.26	0.74	15.83	0.50
Qpb	0.63	0.37	0.75	0.25	4.91	2.89
Jpb	0.04	0.96	0.90	0.10	0.50	13.15

Cuadro 1. Resultados del modelo para distintas estrategias, creencias y utilidades con mil iteraciones.

Resultados

Player One Check-Raise All-in Range												
A	K	Q	J	T	9	8	7	6	5	4	3	2
A	AK	AQ	AJ	AT	A9	A8	A7	A6	A5	A4	A3	A2
K	KQ	KJ	KT	K9	K8	K7	K6	K5	K4	K3	K2	
Q	AQ	KQ	QJ	Q9	Q8	Q7	Q6	Q5	Q4	Q3	Q2	
J	AJ	KJ	QJ	J9	J8	J7	J6	J5	J4	J3	J2	
T	AT	KT	QT	JT	T9	T8	T7	T6	T5	T4	T3	T2
9	A9	K9	Q9	J9	T9	98	97	96	95	94	93	92
8	A8	K8	Q8	J8	T8	98	87	86	85	84	83	82
7	A7	K7	Q7	J7	T7	97	87	76	75	74	73	72
6	A6	K6	Q6	J6	T6	96	86	76	65	64	63	62
5	A5	K5	Q5	J5	T5	95	85	75	65	54	53	52
4	A4	K4	Q4	J4	T4	94	84	74	64	54	43	42
3	A3	K3	Q3	J3	T3	93	83	73	63	53	43	32
2	A2	K2	Q2	J2	T2	92	82	72	62	52	42	32

Player One Call All-in Range												
A	K	Q	J	T	9	8	7	6	5	4	3	2
A	AK	AQ	AJ	AT	A9	A8	A7	A6	A5	A4	A3	A2
K	KQ	KJ	KT	K9	K8	K7	K6	K5	K4	K3	K2	
Q	AQ	KQ	QJ	Q9	Q8	Q7	Q6	Q5	Q4	Q3	Q2	
J	AJ	KJ	QJ	J9	J8	J7	J6	J5	J4	J3	J2	
T	AT	KT	QT	JT	T9	T8	T7	T6	T5	T4	T3	T2
9	A9	K9	Q9	J9	T9	98	97	96	95	94	93	92
8	A8	K8	Q8	J8	T8	98	87	86	85	84	83	82
7	A7	K7	Q7	J7	T7	97	87	76	75	74	73	72
6	A6	K6	Q6	J6	T6	96	86	76	65	64	63	62
5	A5	K5	Q5	J5	T5	95	85	75	65	54	53	52
4	A4	K4	Q4	J4	T4	94	84	74	64	54	43	42
3	A3	K3	Q3	J3	T3	93	83	73	63	53	43	32
2	A2	K2	Q2	J2	T2	92	82	72	62	52	42	32

Conclusiones

La teoría de matroides orientados y circuitos orientados, se adapta naturalmente a la teoría de grafos y permite optimizar los algoritmos encargados de recorrer los árboles al limitar las decisiones posibles a conjuntos independientes en cada juego, reduciendo el espacio de búsqueda y acelerando la convergencia del modelo.

Referencias

- [1] James Oxley, *Matroid Theory*, 2nd ed., Department of Mathematics, Louisiana State University, Oxford University Press, 2011.
- [2] A. Björner, M. Las Vergnas, B. Sturmfels, N. White and G. Ziegler, *Oriented Matroids*, 2nd ed., Cambridge University Press, 1999.
- [3] Prathamesh Sonawane and Arav Chheda, *A survey on Game Theory Optimal Poker*, arXiv:2401.06168v1, University of Illinois Urbana Champaign, USA, Jan 2024.
- [4] Z. Martin, J. Michael, B. Michael, P. Carmelo, *Regret minimization in games with incomplete information*, Computing Science Department, University of Alberta, Canada.



Clasificación Binaria Aplicada a Predicción de Aprobación de Préstamos Bancarios

Luis Fernando Rodríguez Díaz - UNAH - lfrdriguezdz@unah.hn

Escuela de Matemáticas y Ciencias de la Computación, UNAH



Introducción

La clasificación binaria es esencial en aprendizaje automático, con aplicaciones críticas en finanzas como la evaluación de riesgo crediticio. En este trabajo, implementamos regresión logística regularizada para predecir la aprobación de préstamos, formulando la estimación de parámetros como un problema de optimización no lineal resuelto mediante descenso de gradiente. Desarrollamos una implementación completa en Python que incluye:

- Preprocesamiento de los datos
- Estrategias adaptativas de tamaño de paso
- Múltiples criterios de parada configurables
- Regularización L_2 para evitar sobreajuste

Datos y Preprocesamiento

Se emplearon datos sintéticos del *Loan Approval dataset* de Kaggle, con dos variantes de 6 423 muestras cada una (versión limpia y versión con ruido), distribuidas en 3 468 aprobaciones y 2 955 rechazos.

Cada registro incluye datos temporales, características demográficas, variables financieras, detalles del préstamo y otros indicadores.

El preprocesamiento aplicado al *DataFrame* antes del entrenamiento consistió en derivar variables clave, balanceo las clases para obtener una proporción de 54 % aprobados / 46 % rechazados, inyección de ruido ligero a algunas variables, codificación *one-hot* de variables categóricas y finalmente escalamiento y ajuste de la media (media 0, desviación 1) a las variables numéricas resultantes.

Al finalizar, se obtuvieron conjuntos de 6 243 entradas con 53 características listas para la estimación de parámetros mediante descenso de gradiente.

Modelo Teórico

Para clasificar los préstamos encontramos los coeficientes β que minimicen la función de pérdida logística regularizada

$$\frac{1}{m} \sum_{i=1}^m \left[(1 - y_i) \beta^T X_i + \ln(1 + e^{-\beta^T X_i}) \right] + \lambda \sum_{j=1}^n \beta_j^2$$

Donde:

- $\beta = (\beta_0, \beta_1, \dots, \beta_n) \in \mathbb{R}^{n+1}$ es el vector de coeficientes óptimos a estimar.
- $X_i = (1, X_{i,1}, X_{i,2}, \dots, X_{i,n}) \in \mathbb{R}^{n+1}$ es el vector de n características de la observación i .
- $y_i \in \{0, 1\}$ es la clase real de la observación i .
- $m \in \mathbb{N}$ es el número total de observaciones.
- $\lambda > 0$ es el hiperparámetro de regularización.

Descenso del Gradiente - Concepto e Implementación

El descenso del gradiente es un algoritmo iterativo que minimiza la función de costo moviendo los parámetros en la dirección opuesta al gradiente. En cada iteración, los coeficientes β se actualizan como:

$$\beta^{(k+1)} = \beta^{(k)} - \alpha_k \nabla J(\beta^{(k)})$$

donde α_k es el tamaño de paso. Se implementaron tres métodos para determinar α_k :

- Paso fijo:** Simple pero requiere ajuste manual.
- Backtracking:** Ajusta α_k dinámicamente para garantizar una disminución suficiente del costo.
- Regla gradiente-Hessiano:** Utiliza el Hessiano para un paso óptimo, ideal para el caso cuadrático

Como todo método iterativo, requiere de un criterio de parada. En esta implementación se incluyeron:

- Número máximo de iteraciones:** Limita el tiempo de ejecución.
- Tolerancia en el gradiente:** Detiene el algoritmo cuando $\|\nabla J(\beta)\|$ es menor que una tolerancia definida.
- Tolerancia en la función objetivo:** Detiene el algoritmo cuando el cambio en $J(\beta)$ es insignificante.
- Tolerancia en los parámetros:** Detiene el algoritmo cuando la diferencia entre el parámetro a evaluar actual y el anterior es insignificante.

Algorithm 1 Descenso del Gradiente

Require: Datos X , etiquetas y , λ , α_0 , $k_{\max}$

Ensure: Coeficientes óptimos β^*

```
1: Inicializar  $\beta \leftarrow 0$ 
2: for  $k = 1$  to  $k_{\max}$  do
3:   Calcular  $\nabla J(\beta)$ 
4:   if Criterio de parada satisfecho then
5:     break
6:   end if
7:   Actualizar  $\alpha_k$  según criterio de paso
8:   Actualizar  $\beta \leftarrow \beta - \alpha_k \nabla J(\beta)$ 
9: end for
```

Donde $\nabla J(\beta) = \lambda \beta + \sum_{i=1}^m (\sigma(\beta^T X_i) - y_i) X_i$

Parámetros y configuración usada en la optimización

- Regularización:** L_2 con $\lambda = 5 \times 10^{-4}$.
- Inicialización:** $\beta^{(0)} \sim \mathcal{N}(0, 0.01)$.
- Límite de iteraciones:** $k_{\max} = 15,000$.
- Criterio de parada preferente:** $\|\nabla J(\beta)\| < 10^{-5}$.
- Regla de paso por defecto:** Búsqueda en línea (backtracking) con $\alpha_0 = 1$, $\rho = 0.8$, $c = 0.1$.
- Partición datos:** 80 % entrenamiento / 20 % prueba (5460 / 963).

Resultados de la optimización

	Sin ruido	Con ruido
Iteraciones	15,000	15,000
Tiempo total (HH:MM:SS)	00:54:00	00:49:34
Valor final $f(\beta)$	9.2065×10^{-2}	9.6323×10^{-2}
$\ \nabla J(\beta)\ $ final	7.3865×10^{-5}	2.1701×10^{-4}
Exactitud (entrenamiento)	96.5 %	96.63 %
Exactitud (prueba)	96.16 %	96.47 %
Umbral óptimo τ_{opt}	0.6364	0.6263

Comportamiento del Algoritmo




Figura 1. Evolución de la norma del gradiente $\|\nabla J(\beta)\|$ vs. iteraciones.




Figura 2. Matriz de confusión para datos de prueba con ruido

Conclusiones y Discusión

El modelo de regresión logística con optimización por descenso de gradiente demostró alta efectividad (exactitud >96 %) en la predicción de aprobación de préstamos en ambos casos. Como trabajo futuro, se propone explorar métodos de segundo orden y validación con datos reales.

Referencias

- Luenberger, D. G. & Ye, Y. (2021). *Linear and Nonlinear Programming* (4th ed.). Springer.
- Larsen, R. J. & Marx, M. L. (2018). *An Introduction to Mathematical Statistics and Its Applications* (5th ed.). Pearson.
- Nocedal, J. & Wright, S. J. (2006). *Numerical Optimization* (2nd ed.). Springer.
- Beck, A. (2014). *Introduction to Nonlinear Optimization: Theory, Algorithms, and Applications with MATLAB*. SIAM.
- Zoppelletto, L. (2023). Financial risk for loan approval [Kaggle dataset]. Recuperado de <https://www.kaggle.com/datasets/lorenzozoppelletto/financial-risk-for-loan-approval>



UNAH
UNIVERSIDAD NACIONAL
AUTÓNOMA DE HONDURAS

Análisis espacial de precios de Airbnb en NYC con Geoestadística y Econometría

Oscar Andree Cortés Hernández

ocortese@unah.hn

Universidad Nacional Autónoma de Honduras



Introducción


El análisis estadístico de datos espaciales ha crecido por la masiva disponibilidad de información georreferenciada y mejores herramientas computacionales [2, 3]. Este trabajo combina: Exploración espacial (mapas, Moran, LISA) [1], geoestadística (variograma, kriging) [3, 5] y econometría espacial (SAR/SEM/SARAR) [2], aplicadas a precios de Airbnb en NYC (2019) [4].

Datos y preparación

Variable objetivo: $\log(\text{price})$; covariables: `room_type`, `minimum_nights`, `availability_365`, `number_of_reviews`, `reviews_per_month`, `neighbourhood_group`, `lon/lat`.
Pesos espaciales k -NN ($k = 8$) estandarizados por filas para Moran/LISA [1].
Filtrado de outliers y transformación logarítmica [2].
Reproyección a UTM 18N (m) para variograma/kriging [3].


Exploración espacial de precios

Patrón general: precios más altos en Manhattan y corredores selectos de Brooklyn; menor nivel hacia Queens y Staten Island.



Mapa de cuantiles de $\log(\text{price})$.


Autocorrelación: I de Moran global significativo ($p < 0.001$) [2], evidencia de patrones no aleatorios.



LISA: clústeres locales de $\log(\text{price})$ (HH en Manhattan/Brooklyn; LL en Staten Island/Queens) [1].


Geoestadística: variograma y kriging

Variograma: mejor modelo esférico (nugget 0.006, sill parcial 0.122, rango ≈ 15.97 km) [3].



Variograma empírico y ajuste esférico (SSE mínimo).

Kriging ordinario: rejilla de 600 m. Validación LOOCV (escala log): RMSE = 0.367, MAE = 0.250, $R^2 = 0.339$ [3].



Superficie continua del precio estimado (USD).

Resultados econométricos

Base OLS: $R^2_0 \approx 0.502$. Efectos (respecto a *entre home/apt*): Private room ≈ -0.77 , Shared room ≈ -1.16 . Localización: Manhattan $\approx +0.559$, Brooklyn $\approx +0.249$. Residuales con autocorrelación (Moran $p < 0.001$) [2].

SARAR (GMM) preferido: $\lambda \approx 0.454$; residuales sin autocorrelación (Moran $I \approx -0.0047$, $p \approx 0.985$) [2]. Incluye efectos de vecindario (spillovers) y corrige dependencia en errores, mejorando la inferencia y la robustez predictiva.

Resumen

El estudio integra ESE, geoestadística y econometría espacial para analizar precios de Airbnb en NYC (2019). Se detecta autocorrelación espacial significativa [2], con clústeres bien definidos de altos y bajos precios [1]. El variograma esférico modela adecuadamente la estructura espacial [3]; el kriging produce superficies continuas interpretables con precisión moderada. El modelo SARAR corrige la dependencia espacial en residuales, fortaleciendo la calidad de la inferencia y la utilidad para decisiones [2].

Resultados

Componente	Resultado
Moran global	$p < 0.001$ (autocorrelación positiva)
LISA	HH: Manhattan/Brooklyn; LL: Staten Island/Queens
Variograma	Esférico: nugget 0.006; sill 0.122; rango 15.97 km
Kriging (CV)	RMSE 0.367; MAE 0.250; $R^2 \approx 0.339$
OLS (log-price)	$R^2_0 \approx 0.502$
SARAR (GMM)	$\lambda \approx 0.454$; Moran resid. n.s.

Conclusiones

- Estructura espacial clara:** clústeres High-High en Manhattan/Brooklyn y Low-Low en Staten Island/Queens; la localización es determinante [1].
- Modelo de continuidad:** el variograma esférico captura la dependencia intraurbana, base para kriging estable [3].
- Predicción y mapas:** el kriging ofrece una superficie de precios útil para exploración de mercado [3].
- Econometría espacial:** SARAR reduce la autocorrelación residual y mejora la consistencia de estimaciones [2].
- Determinantes del precio:** efectos fuertes de `room_type` y `neighbourhood_group`; prima por Manhattan y penalización por habitaciones privadas/compartidas.
- Limitación:** heterogeneidad micro-espacial no capturada completamente; podría ampliarse con covariables finas (amenidades, accesibilidad).

Referencias

- L. Anselin, Local indicators of spatial association—LISA, *Geographical Analysis* **27** (1995), no. 2, 93–115.
- R. Bivand, E. Pebesma, and V. Gómez-Rubio, *Applied Spatial Data Analysis with R*, Second edition, Springer, New York, 2013.
- N. A. C. Cressie, *Statistics for Spatial Data*, Wiley-Interscience, New York, 1993.
- Inside Airbnb, New York City Airbnb Open Data, Inside Airbnb, 2019. <http://insideairbnb.com/get-the-data.html>.
- G. Matheron, Principles of geostatistics, *Economic Geology* **58** (1963), no. 8, 1246–1266.

Datos: Airbnb NYC 2019





Técnicas de Regularización para el Diagnóstico de TDAH

Thelma Lorena Fonseca
Universidad Nacional Autónoma de Honduras



Resumen

El Trastorno por Déficit de Atención e Hiperactividad (TDAH) es una condición neuropsiquiátrica común que presenta desafíos diagnósticos debido a la complejidad de sus síntomas. Este estudio aplica técnicas de regresión penalizada, específicamente Lasso, junto con el algoritmo de k-vecinos más cercanos (KNN), para analizar un conjunto de datos clínicos tabulares relacionados con el TDAH. El objetivo es mejorar la identificación de variables clave asociadas al trastorno y construir modelos predictivos robustos que ayuden en el diagnóstico.

Fundamentos: Lasso y KNN

Lasso: Regresión penalizada que incorpora una penalización ℓ_1 para realizar selección automática de variables [3]. El modelo minimiza:

$$\min_{\beta_0, \beta} \left\{ \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\}$$


Esto fuerza a algunos coeficientes β_j a ser exactamente cero, permitiendo una interpretación más clara del modelo.

KNN: Algoritmo no paramétrico que clasifica una nueva observación x_0 según la mayoría de clase de sus k vecinos más cercanos [2].


$$\hat{y}(x_0) = \arg \max_{c \in C} \sum_{i \in N_k(x_0)} \mathbb{I}(y_i = c)$$

donde C es el conjunto de clases posibles y $\mathbb{I}(\cdot)$ es la función indicadora.

Comparación Geométrica de Modelos



Lasso: Penalización ℓ_1 fuerza coeficientes a cero [3].



KNN: Fronteras de decisión basadas en vecinos [2].

Metodología y Datos

Se utilizó el conjunto **HYPERAKTIV** con 85 observaciones y 759 variables [7]. Se integraron datos clínicos, fisiológicos y psicométricos. El dataset fue dividido en 80% entrenamiento y 20% prueba. Se usó validación cruzada *k-fold* para ajustar el parámetro λ en Lasso. El modelo KNN fue probado con $k = 8$.

Se emplearon variables predictoras relacionadas con la sintomatología de TDAH, y la variable respuesta (y) es binaria, donde:

- $y = 1$: participante con diagnóstico de TDAH.
- $y = 0$: participante sin diagnóstico de TDAH.

Variables Seleccionadas y Validación de Lasso


La selección de variables mediante Lasso permitió identificar predictores clínicos y fisiológicos relevantes para el diagnóstico del TDAH, mientras que el modelo KNN ofreció una referencia comparativa basada en proximidad sin supuestos paramétricos.

Fold	$\lambda = 0.01$	$\lambda = 0.05205$	$\lambda = 0.1$
1	0.0420	0.0375	0.0802
2	0.0604	0.0543	0.0901
3	0.0503	0.0477	0.0823
4	0.0601	0.0609	0.0896
5	0.0778	0.0614	0.0737
Promedio	0.0597	0.05236	0.0832

- El menor ECM promedio corresponde a $\lambda = 0.05205$, que es el valor óptimo obtenido por validación cruzada automática.
- Este λ fue utilizado para entrenar el modelo final de Lasso.

Variables Relevantes y Validación Cruzada

Variable	Descripción	Signo
WURS	Escala retrospectiva TDAH en infancia	+
ASRS	Escala de TDAH en adultos	+
HADS_D	Subescala de depresión (HADS)	-
ACC_ft_real_21	Parte real del coef. 21 de la FFT	+
ACC_ft_angle_30	Fase del coef. 30 de la FFT	-



Comparación de modelos: Lasso vs KNN

Predicción	Referencia	Total
0	0	1
1	2	7
Total	10	10

Lasso

Predicción	Referencia	Total
0	4	2
1	6	8
Total	10	10

KNN (k = 8)

Métricas de evaluación:

Métrica	Lasso	KNN
Accuracy	0.75	0.60
Kappa	0.50	-
Sensibilidad (Recall)	0.70	0.90
Especificidad	0.80	0.60
Valor predictivo positivo (PPV)	0.7778	0.6923
Valor predictivo negativo (NPV)	0.7273	0.8571
Balanced Accuracy	0.75	0.75
Prueba de McNemar	1.00000	0.37109




Figura. Curvas ROC para Lasso y KNN.

Conclusiones

- Lasso seleccionó eficazmente las variables más relevantes del conjunto de datos.
- ASRS, WURS y variables fisiológicas mostraron fuerte asociación con el diagnóstico de TDAH.
- Lasso obtuvo mejor desempeño ($AUC \approx 0.80$) que KNN ($k = 8$), con mayor especificidad.
- La validación cruzada optimizó λ en Lasso y evitó el sobreajuste.

References

- [1] Arashnic. Adhd diagnosis data. <https://www.kaggle.com/datasets/arashnic/adhd-diagnosis-data>, 2024.
- [2] T. M. Cover and P. E. Hart. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1):21–27, 1967.
- [3] Gareth James, Daniela Witten, Trevor Hastie, and Robert Tibshirani. *An Introduction to Statistical Learning: with Applications in R*. Springer, New York, 2013.

Autores

Autores



Lic. Angel Rivera Cursé la Licenciatura en Matemática con Orientación en Ingeniería Matemática en la Universidad Nacional Autónoma de Honduras (UNAH) y actualmente estoy finalizando mis estudios de posgrado en la misma orientación. Me desempeño como docente en el Departamento de Matemática Aplicada de UNAH-CU. Mi especialización se centra en el estudio y aplicación de ecuaciones diferenciales, así como en el desarrollo de soluciones mediante programación, integrando herramientas computacionales para el análisis y modelado de problemas matemáticos.

Ph.D. Aubin Arroyo (1974, Ciudad de México) es matemático y artista visual. Investigador en el Instituto de Matemáticas, Unidad Cuernavaca, de la UNAM, donde se especializa en Sistemas Dinámicos, Geometría Tropical y Teoría de Números. Además, ha destacado por su enfoque innovador en la visualización de conceptos matemáticos, fusionando ciencia y arte. Sus obras han sido exhibidas internacionalmente y ha curado exposiciones como "Imaginario Matemático" en Universum. Coordina el Museo Virtual de Matemáticas y forma parte de la Comisión de Divulgación y Popularización de la Matemática de la Unión Matemática de América Latina y el Caribe.



M.Sc. César Romero Actualmente soy estudiante de doctorado en la Universidad Paris Dauphine - PSL, con un proyecto de tesis en Dinámica Hamiltoniana. Más específicamente, estudio la regularidad de conjuntos invariantes bajo un tipo particular de sistemas, conocidos como Hamiltonianos de Tonelli. También realicé estudios de maestría en la Universidad Sorbonne Paris Nord y en el Centro de Investigación en Matemáticas (CIMAT), en Guanajuato, México. En las dos instituciones inicié mi

recorrido académico en el área de sistemas dinámicos. Asimismo, cursé la carrera de Matemáticas en la Universidad Nacional de Colombia, sede Bogotá.

Ph.D. Cristian Cruz Realicé mis estudios de doctorado en la Universidad Federal de Rio de Janeiro (UFRJ) en Brasil, donde obtuve el título de Doctorado en Ciencias Estadísticas. Estudié mi Maestría en Matemática con orientación en Economía Matemática en el Instituto de Matemática Pura y Aplicada (IMPA) también en Brasil. Cursé la Licenciatura en Matemática con Orientación en Ingeniería Matemática y la Licenciatura en Ingeniería Eléctrica Industrial en la Universidad Nacional Autónoma de Honduras (UNAH). Actualmente soy docente en la UNAH en el Departamento de Estadística Matemática. Fui Coordinador General de la Maestría en Matemática con orientación en Ingeniería Matemática y Estadística Matemática en el periodo 2018-2022. Mi experiencia laboral también incluye como docente en otras instituciones educativas privadas y como consultor externo para instituciones nacionales e internacionales. Laboro en el Banco Central de Honduras en el Departamento de Investigación Económica. En el ámbito académico, he supervisado estudiantes en tesis de licenciatura y de maestría en el área Estadística y Econometría. He publicado en revistas nacionales e internacionales de manera individual y con colaboraciones en el área de Matemática, Estadística y Econometría. Además, he presentado y participado en congresos académicos nacionales e internacionales.



Ph.D. Fredy Vides Obtuve el grado de Doctor en Matemática con distinción honorífica en la University of New Mexico (UNM), en Albuquerque, Estados Unidos, y soy Licenciado en Matemática con Orientación en Ingeniería Matemática por la Universidad Nacional Autónoma de Honduras (UNAH). Durante mi formación, desempeñé funciones como instructor y docente en el Departamento de Matemática Aplicada de la UNAH, donde actualmente ejerzo como Profesor Titular III. Mi trabajo académico y profesional se ha centrado en el análisis matricial, la

modelación y control de sistemas, la optimización y el cómputo científico de alto rendimiento, con énfasis en aplicaciones de análisis predictivo y prescriptivo en sistemas financieros, sociales y ciberfísicos. He liderado proyectos de investigación en aprendizaje automático, identificación estructurada de sistemas y gemelos digitales, así como colaboraciones con la Comisión Nacional de Bancos y Seguros (CNBS) orientadas a la simulación de escenarios y la estabilidad del sistema financiero. Soy autor y coautor de publicaciones en revistas indexadas de alcance internacional y he servido como miembro de

comités editoriales en revistas científicas dentro y fuera de Honduras. He realizado estancias científicas en centros y universidades de Dinamarca, Estados Unidos, Austria y Canadá, y soy miembro activo de la Federación Internacional de Control Automático (IFAC).

M.Sc. Henry Ocampo Realicé mis estudios de posgrado en el Centro de Investigación en Matemáticas (CIMAT), en la ciudad de Guanajuato, México, donde obtuve el grado de Maestro en Ciencias con Especialidad en Computación y Matemáticas Industriales. Cursé la Licenciatura en Matemática con Orientación en Informática en la Universidad Nacional Autónoma de Honduras (UNAH). Durante mi formación, me desempeñé como instructor de laboratorio en la Escuela de Matemática y, tras obtener el título, inicié labores como docente en el Departamento de Matemática Aplicada. Actualmente, soy Coordinador de la Carrera de Matemática UNAH-CU. Me especializo en las áreas de análisis de datos, optimización y aprendizaje automático (machine learning), con un enfoque particular en inteligencia artificial aplicada al análisis de imágenes médicas, redes neuronales y procesamiento de lenguaje natural.



Ph.D. Jean Bernard Hayet Estudié un grado de ingeniería en la Ecole Nationale Supérieure de Techniques Avancées (ENSTA) en París de 1996 a 1999. Obtuve mi grado de maestría en inteligencia artificial por la Universidad París VI y mi grado de doctorado por la Universidad de Toulouse en 2003, con una tesis en robótica autónoma. He trabajado como post-doc en la Universidad de Liejas (Bélgica) desde 2004 a 2007 en temas de visión artificial. Desde 2007, soy investigador del Departamento de Ciencias de la Computación en el Centro de Investigación en Matemáticas (CIMAT), en Guanajuato, México. Doy clases de programación, de visión artificial, entre otras, y realizo trabajos de investigación en el aplicar técnicas de aprendizaje automático en visión artificial y robótica autónoma.

M.Sc. José Ever Gonzales Realicé mis estudios de posgrado en la Universidad de Jaume I, Castellón, España, donde obtuve el grado de Maestro en Matemática Computacional con énfasis en criptografía. Cursé la Licenciatura en Matemática con Orientación en Informática en la Universidad Nacional

Autónoma de Honduras (UNAH).y tras obtener el título, inicié labores como docente en el Departamento de Matemática, años después pasé a ser parte del Departamento de Matemática Aplicada. Como parte del desarrollo del Doctorado en Matemática en la Universidad Politécnica de Valencia, he participado en el desarrollo de aplicaciones de Machine Learning en Astrofísica en el Instituto de Astrofísica de Canarias, además, he participado en el desarrollo de sistemas de mundos infinitos en videojuegos serios en el instituto de imágenes de la Universidad de Jaume I. Actualmente, soy docente y me especializo en las áreas de análisis de datos, aprendizaje automático con un enfoque particular en inteligencia artificial aplicada en espectroscopía en estrellas masivas, en el análisis de imágenes médicas, redes neuronales y desarrollo de videojuegos. .



Ph.D. José Perea Jose Perea es profesor asociado en el departamento de Matemáticas y en el Khoury College de ciencias de la computación en la universidad de Northeastern, Boston, USA. Antes de unirse a Northeastern, ocupó cargos como profesor asistente en los departamentos de CMSE y Matemáticas en Michigan State University (2015–2021), y como postdoctorante en el departamento de Matemáticas en la Universidad de Duke (2011–2015). Obtuvo un doctorado en Matemáticas de la Universidad de Stanford (2011) y una licenciatura en Matemáticas de la Universidad del Valle, Colombia (Valedictorian, Summa cum laude, 2006). Jose Perea es

uno de los conferencistas inaugurales 2022–2024 de la Asociación Matemática de América (Mathematical Association of America) y la Asociación Nacional de Matemáticas (National Association of Mathematics), recibió el premio NSF CAREER en 2020, fue reconocido en 2020 por Lathisms (Mes de la Herencia Hispana), y en 2018 por Mathematically Gifted and Black (Mes de la Historia Afroestadounidense).

Ph.D. Leandro Galo Soy Doctor en Matemáticas por el Instituto de Matemáticas de la Universidad Nacional Autónoma de México (UNAM). Obtuve también los grados de Maestría y Licenciatura en Matemática con orientación en Ingeniería Matemática en la Universidad Nacional Autónoma de Honduras (UNAH), donde actualmente me desempeño como Profesor Titular II. He sido coordinador de la carrera de Licenciatura en Matemática y actualmente coordino la Maestría en Matemática en la UNAH. Mi experiencia docente incluye la coordinación



de cátedras como Análisis Numérico y Ecuaciones Diferenciales. Mi trabajo de investigación se centra en la teoría de control de ecuaciones en derivadas parciales, especialmente en problemas de controlabilidad para ecuaciones parabólicas degeneradas con condiciones de frontera y potenciales singulares. Mis resultados han sido publicados en revistas científicas internacionales de prestigio. Además, soy miembro activo del Comité Hondureño de Olimpiadas de Matemáticas y de la Asociación Hondureña de Matemática (ASOMATH), destacándome por mi compromiso con la divulgación y el fortalecimiento de la matemática en la región.




M.Sc. Marvin Villafranca Realicé mis estudios de posgrado en la Universidad Nacional Autónoma de Honduras (UNAH), Ciudad Universitaria, donde obtuve el grado de Maestría en Matemática con Orientación en Estadística Matemática. Asimismo, cursé la Licenciatura en Matemática con Orientación en Estadística en la misma universidad. He participado como docente en la Maestría en Matemática con Orientación en Estadística Matemática de la UNAH-CU, impartiendo la asignatura Métodos Multivariantes. Mi especialidad es la investigación en modelos econométricos de series de

tiempo multivariadas aplicados a contextos macroeconómicos y financieros. Entre estos modelos se incluyen los Modelos Autorregresivos Vectoriales (VAR), los Modelos de Volatilidad Estocástica Multivariada (MSV) y sus diversas variantes. Actualmente realizo investigaciones orientadas al estudio de las propiedades de estos modelos, por ejemplo, la asimetría y la curtosis multivariada.

Lic. Leonel Obando Soy licenciado en matemática con orientación en Ingeniería Matemática por la Universidad Nacional Autónoma de Honduras (UNAH), institución en la que actualmente curso una Maestría en Matemática. Mi proyecto de tesis está orientado al estudio de Variedades Tóricas y su aplicación a familias de redes de reacciones químicas. Desde más de cinco años me desempeño como docente en la UNAH, impartiendo asignaturas como Topología, Álgebra Abstracta, Geometría Diferencial, Topología Algebraica, Ecuaciones Diferenciales Parciales, Sistemas Dinámicos, entre otras. También he acompañado a estudiantes de la licenciatura en Matemática en el desarrollo de trabajos de investigación. Mis principales áreas de interés son la Geometría Algebraica y la Teoría de Números. He participado impartiendo cursos y conferencias en actividades académicas de la Carrera de



Matemática, y actualmente formo parte del Comité Nacional de Olimpiadas Matemáticas de Honduras, desde donde impulso proyectos relacionados con olimpiadas a nivel universitario.



Lic. Pedro Molina Realicé mis estudios de posgrado en la Universidad Nacional Autónoma de Honduras (UNAH), en la ciudad del Distrito Central, Honduras, donde actualmente soy egresado, culminando el trabajo de investigación para la obtención del título del grado de Magister en Matemática con Orientación en Estadística Matemática. También cursé la Licenciatura en Matemática con Orientación en Ingeniería Matemática en la Universidad Nacional Autónoma de Honduras (UNAH) con honores de Magna Cum Laude. Durante mi proceso de formación,

me desempeñé como instructor de en la Escuela de Matemática y, tras obtener el título, inicié labores como coordinador académico en la Universidad de Defensa de Honduras. Actualmente, soy especialista regional en análisis en el departamento de cobranza de Grupo Financiero Ficohsa, donde mis funciones cubren las áreas de análisis de datos, análisis de riesgo, riesgo crediticio, entre otros.

M.Sc. Roberto Duarte Máster en Estadística Matemática y Especialista en Estadística por la Universidad de Buenos Aires, además de Máster y Licenciado en Matemática con orientación en Estadística Matemática por la Universidad Nacional Autónoma de Honduras (UNAH). Actualmente me desempeño como Profesor Titular II en el Departamento de Estadística Matemática de la UNAH, donde imparto cursos avanzados de estadística a nivel de licenciatura y maestría. He trabajado como analista de datos estadísticos en el Instituto Nacional de Estadística, experiencia que me permitió aplicar herramientas como R y SPSS, en el análisis de datos y el control de calidad. He participado en congresos internacionales como el Latin American Congress of Probability and Mathematical Statistics y el International Symposium of Mathematical Methods Applied to Sciences. Mis publicaciones abordan temas como el modelado de medios filtrantes con diagramas de Voronoi-Laguerre y la comparación de estimadores robustos en distribuciones Beta.





Ph.D. Sergio Gómez Obtuve el doctorado en Matemáticas Computacionales y Ciencias de la Decisión por la Università degli Studi di Pavia (Italia) y la Università della Svizzera italiana (Suiza) en 2023. Antes de ello, completé la Maestría en Matemática Aplicada en la Universidad de Puerto Rico en Mayagüez en 2018 y la Licenciatura en Matemáticas con Orientación en Ingeniería Matemática en la Universidad Nacional

Autónoma de Honduras (UNAH) en 2016. Entre octubre de 2023 y enero de 2025 trabajé como investigador posdoctoral en la Università degli Studi di Milano-Bicocca (UNIMIB), centrando mi labor en el desarrollo y análisis de métodos numéricos avanzados para ecuaciones diferenciales parciales (EDP). Mis líneas de investigación incluyen métodos de Galerkin discontinuos, métodos de elementos virtuales, métodos espacio-tiempo para ecuaciones de evolución, métodos numéricos con preservación de estructura para EDP no lineales y aproximación numérica de EDP fraccionarias. Actualmente, me desempeño como Assistant Professor of Numerical Analysis en plaza tenure-track en UNIMIB.