El Landscape, el Swampland y las Metaheurísticas

Brandon Marquez-Salazar[1], Angel Diaz-Pacheco[1], Cesar Damian[1]
[1]División de Ingenierías Campus Irapuato-Salamanca, Universidad de Guanajuato, Salamanca, Guanajuato, México.
b.marquezsalazar@ugto.mx

Resumen

En la física de altas energías, la teoría de cuerdas enfrenta el problema del swampland, el cual se basa en la conjetura de que la mayoría de los universos que este marco teórico puede predecir no corresponden con los comportamientos observados, de modo que encontrar el modelo teórico que corresponda con un universo como el nuestro requiere de una búsqueda exhaustiva. En el ámbito computacional, esta búsqueda se puede abstraer como un problema de minimización. Los métodos numéricos tradicionales generalmente resultan insuficientes en este ámbito debido a la complejidad topológica que describe el hiperespacio de las funciones en esta línea de investigación. Debido a lo anterior es que las metaheurísticas lograron abrirse paso en esta área de la física teórica y, siendo que esta línea es reciente, es posible ofrecer una visión desde la perspectiva de la computación científica y la ciencia de datos. En este trabajo se presentan los resultados preliminares obtenidos de 3 planteamientos en un trabajo previo sobre una función potencial de la teoría II B de cuerdas con torsión: 1) realización de una rejilla con AG, 2) realización de una rejilla que compare AIW-PSO contra IWO, 3) probar la reducción de dimensionalidad y modelos para la clasificación de vacíos (estable de Sitter, inestable de Sitter, estable Anti-de Sitter e inestable Anti-de Sitter).

Palabras clave: Borda; Teoría de Cuerdas; Metaheurísticas; Clasificación; Reducción de Dimensionalidad; Swampland.

Introducción

La exploración de paisajes de potenciales no lineales plantea un problema de optimización global cuando la función objetivo presenta regiones no convexas, múltiples óptimos locales e inestabilidades numéricas. En teoría de cuerdas, la búsqueda de vacíos consistentes con la teoría de cuerdas (Abel y Rizos, 2014) se reduce a localizar puntos críticos del potencial efectivo que satisfagan simultáneamente condiciones de estabilidad y energía positiva. La geometría irregular del espacio de búsqueda limita la utilidad de métodos deterministas y desplaza el problema hacia estrategias capaces de recorrer regiones multimodales sin imponer convexidad ni diferenciabilidad (Marquez-Salazar *et al*., 2026a).

Los métodos metaheurísticos han permitido trasladar esta búsqueda desde la enumeración directa hacia dinámicas poblacionales y estocásticas. En compactificaciones tipo IIB con torsión, el uso de Simulated Annealing combinado con refinamiento por gradiente permitió localizar vacíos metastables (Damian y Loaiza-Brito, 2022); posteriormente, un algoritmo genético reformuló el mismo problema mediante una función de penalización sobre los coeficientes de flujo, obteniendo 11 979 puntos críticos y recuperando configuraciones estables de de Sitter y anti-de Sitter (Marquez-Salazar *et al*., 2026).

Sin embargo, la capacidad de una metaheurística para encontrar vacíos no determina por sí misma su comportamiento frente a la topografía del potencial. El teorema de No Free Lunch establece que el desempeño de un algoritmo depende de la estructura particular del espacio de búsqueda (Wolpert y Macready, 1997); por tanto, el resultado obtenido mediante un algoritmo genético no permite inferir una superioridad general sobre otras arquitecturas. En el potencial tipo IIB con torsión, donde la multimodalidad y la sensibilidad numérica favorecen mecanismos capaces de escapar de óptimos locales, permanece abierta la comparación entre estrategias poblacionales que operan mediante dinámicas distintas a las propuestas evolutivas.

Desde esta perspectiva, Particle Swarm Optimization (PSO) e Invasive Weed Optimization (IWO) introducen dos mecanismos de exploración con estructuras demográficas diferentes. PSO desplaza partículas mediante vectores de velocidad gobernados por componentes cognitivos y sociales (Qin *et al*., 2006); IWO modifica la

población mediante dispersión de semillas dependiente del fitness, contrayendo progresivamente el radio de exploración y alternando expansión global con explotación local (Mehrabian y Lucas, 2006).

El estudio compara AIW-PSO e IWO sobre el mismo potencial efectivo y bajo las mismas configuraciones de los módulos, variando el mecanismo de búsqueda. Se registran los puntos críticos obtenidos, la distribución de sus valores, la convergencia de la función de fitness y el tiempo de ejecución; descriptores que permiten contrastar el comportamiento de ambas dinámicas frente a una misma topografía. Esencialmente, se realiza un análisis de Borda (Saari, 1999).

El Teorema del No Free Lunch de Wolpert

Los métodos metaheurísticos, dado que generalmente funcionan mediante dos fases: 1) exploración y 2) explotación, permiten la búsqueda en funciones de topografía compleja y accidentada, donde criterios como la diferenciabilidad no se pueden cumplir si no es dentro de intervalos específicos. Funciones cuya forma es caprichosa e impredecible (Lones, 2014; Yang, 2010, 2017).

Tal como algunos métodos numéricos tradicionales, los metaheurísticos no pretenden encontrar una solución exacta, simplemente realizan aproximaciones de alta precisión (Yang, 2010, 2017).

Todo algoritmo metaheurístico tiene un conjunto de operadores que le permite decidir sus siguientes pasos durante el proceso de optimización. Generalmente, estos operadores son los que le dan nombre al método y suelen estar inspirados en comportamientos observados de sistemas, naturales, artificiales e inclusive de fenómenos matemáticos (Eiben y Smith, 2015; Lones, 2014; Ma *et al*., 2023).

La exploración es la fase en que el método distribuye soluciones sobre el lugar geométrico descrito por la función, proveyendo información que puede ser útil a los operadores para decidir el siguiente conjunto de soluciones. Y la explotación es el proceso mediante el cual, el algoritmo, al encontrar un punto, debido a sus reglas, cae naturalmente a intentar refinar la solución. Ambos comportamientos emergen debido a las reglas propuestas por el método (Lones, 2014; Ma *et al*., 2023; Yang, 2010, 2017).

Para cada operador y proceso interno de estos algoritmos es imprescindible tener en consideración que cada método requiere sintonización (*tunning* en inglés) de hiperparámetros. Los cuales definen la forma en que los operadores actúan sobre las soluciones encontradas (Eiben y Smith, 2015; Ma *et al*., 2023).

Para la optimización es necesario definir la función a optimizar. Dicha función dependerá del problema a resolver y deberá devolver (en implementaciones generales) un único valor escalar que será minimizado o maximizado. A esta función se le conoce como función de evaluación, de desempeño o de *fitness* (Eiben y Smith, 2015; Yang, 2010).

Los comportamientos de los métodos metaheurísticos suelen tener un componente estocástico, lo que exige una formalización para poder afirmar que el desempeño deseado se cumple. Estas métricas pueden hacerse de forma indirecta partiendo de las soluciones encontradas por diferentes instancias del proceso utilizando siempre los mismos hiperparámetros y funciones de evaluación (Eiben y Smith, 2015; Ma *et al*., 2023).

Finalmente, el NFL o *non-free-lunch theorem*, dentro del área de las metaheurísticas propone que ningún algoritmo es superior a otros en lo general. De modo que cada paradigma puede corresponder en mayor o menor medida al problema a resolver (Wolpert y Macready, 1997).

El *Swampland* en la Teoría de Cuerdas

Aquí tienes el texto con las citas IEEE cambiadas a **APA 7**, usando la lista de referencias proporcionada. También corregí “orientfolds” → **orientifolds** y “conherente” → **coherente**.

Dentro de la física de altas energías, en el dominio de la teoría de cuerdas, el concepto de *landscape* se refiere a la cantidad inmensa de posibles universos modelables: dependiendo de la topología y las contribuciones de elementos como branes y orientifolds, los modelos pueden generar funciones potenciales

generales, y estas funciones representan a una familia entera de posibles universos (Abel y Rizos, 2014; Bizet *et al*., 2020; Ooguri y Vafa, 2007).

Dentro de la investigación en teoría de cuerdas, existe el concepto de *swampland* que refiere a la intuición de que la cantidad de universos estables y consistentes con la teoría de la gravedad cuántica es significativamente menor a la cantidad de universos que no cumplen con los criterios propuestos para modelar un universo coherente con las observaciones astronómicas y el modelo estándar de partículas (Ooguri y Vafa, 2007; Palti, 2019; Vafa, 2005).

Un vacío es el estado de mínima energía de un universo el cual puede ser clasificado en 3 tipos según el valor de su potencial efectivo (íntimamente relacionado a la constante cosmológica): i) vacíos de Sitter: aquellos con potenciales definidos positivos, ii) vacíos Anti-de Sitter: aquellos con potenciales definidos negativos, y iii) vacíos planos: aquellos con potenciales neutros (Damian y Loaiza-Brito, 2022; Kallosh *et al*., 2002).

Para la evaluación de potenciales efectivos es posible determinar si en algún punto, un vacío es o no estable, la estabilidad evaluada a partir de los autovalores de la matriz de masas que, matemáticamente, corresponde a la Hessiana del potencial efectivo. Si existe al menos un autovalor negativo, el vacío en dicho punto es inestable. Considerando que dicha inestabilidad implica partículas taquiónicas, se suele decir también que el universo es taquiónico (Damian *et al*., 2013; Damian y Loaiza-Brito, 2013; Gao y Zou, 2022).

Metodología Propuesta

A lo largo de esta investigación se han propuesto cinco experimentos, de los cuales los dos primeros han sido realizados y los restantes se encuentran en desarrollo. Los experimentos han tomado como base la función potencial de la teoría II-B de cuerdas (Eq. 1). Todos los experimentos considerados se listan a continuación:

- Una prueba de desempeño utilizando diferentes configuraciones de una versión base de AGs.
- Una rejilla/*benchmark* comparando el desempeño de AIW-PSO e IWO y su relación con resultados previos.
- Una rejilla/*benchmark* de reducción de dimensionalidad, acompañada de
- Una rejilla/*benchmark* para comparar el desempeño de diferentes clasificadores.

$$V_{\text{eff}} = \frac{A_{H_3} s}{\tau^3} + \frac{A_{F_3}}{s\tau^3} + \frac{A_{F_5}}{\tau^4} + \frac{A_3 \mathcal{N}_3}{\tau^3} + \frac{A_{\widehat{D5}}}{s^{1/2}\tau^{5/2}} \qquad (1)$$

Búsqueda de los parámetros óptimos del AG

El primer experimento evalúa el desempeño de distintas configuraciones de un algoritmo genético aplicado a la búsqueda de vacíos en el potencial efectivo de tipo IIB con torsión. El espacio de búsqueda está definido por cinco coeficientes de flujo, restringidos al intervalo [−100,100], mientras que las configuraciones de los módulos se mantienen fijas para cada modelo considerado. La función de fitness incorpora penalizaciones asociadas a las condiciones necesarias para identificar puntos críticos, estabilidad y energía positiva del potencial.

El algoritmo emplea una población de 20 individuos durante 50 generaciones, con selección por torneo, elitismo, cruce uniforme y mutación multipunto. Para cada configuración se realizaron 100 ejecuciones independientes. El desempeño se examinó a partir de los puntos críticos encontrados, sus valores de potencial, la cantidad de vacíos estables y la proporción de puntos que satisfacen las condiciones de estabilidad. En conjunto, las ejecuciones produjeron 11 979 puntos críticos.

Además de la búsqueda sobre el potencial base, se compararon configuraciones con y sin el término de *uplifting* $A_{\widehat{D5}}$, con el propósito de registrar la variación de los puntos críticos y de su clasificación entre los

distintos tipos de vacío. Los resultados de este experimento establecen la primera evaluación del comportamiento dse las configuraciones de AG empleadas en el estudio.

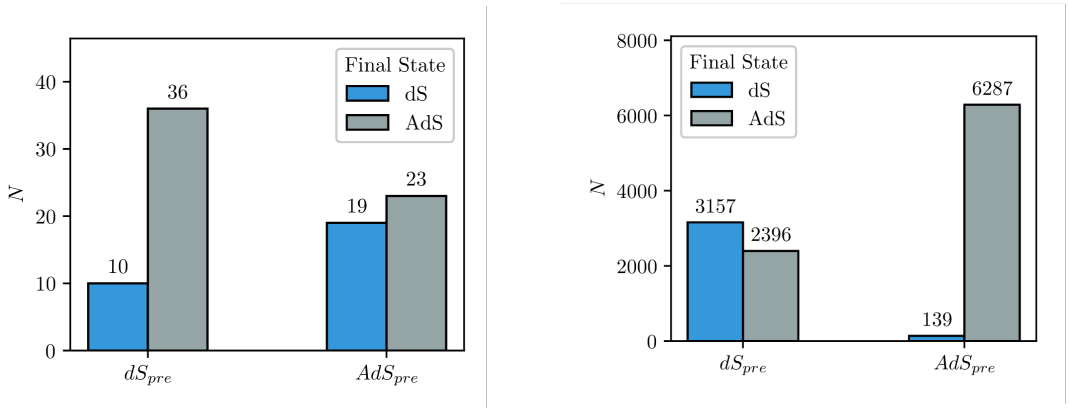


Figura 1. Comparación de vacíos encontrados. El color de la barra determina el estado final tras la adición de las contribuciones $A_{\widehat{nS}}$. La comparación se hace del dataset proporcionado previamente por (Damian y Loaiza-Brito, 2022) (izquierda) respecto a los encontrados en esta aproximación (derecha).
Fuente: (Marquez-Salazar et al., 2026).

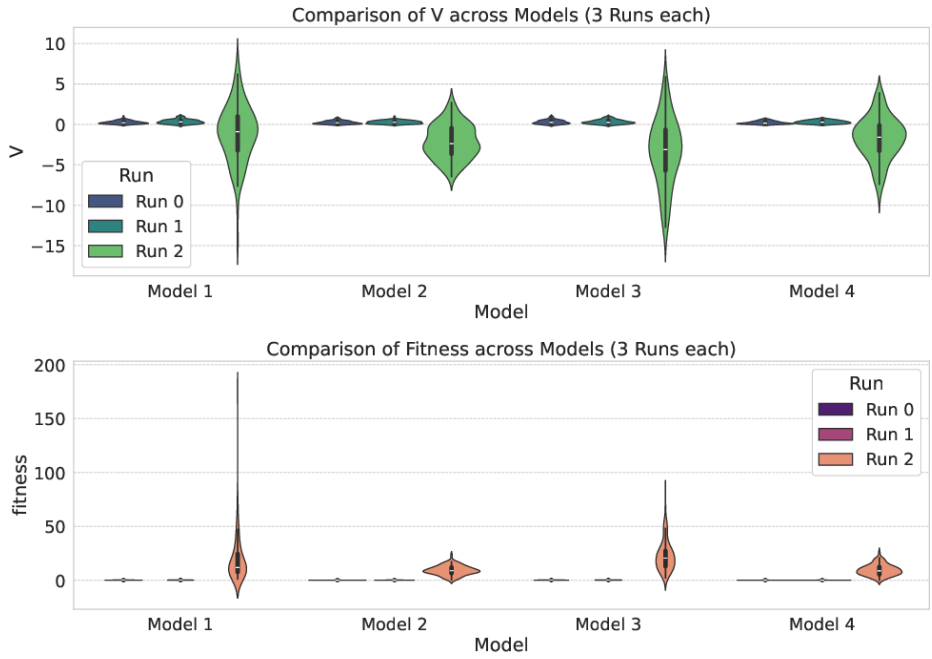


Figura 2. Gráfica de violín donde se logran observar las distribuciones del fitness y el valor del potencial efectivo V. Cada Run corresponde a una configuración específica de módulos s, τ. Cada Model representa una configuración diferente del AG.
Fuente: (Marquez-Salazar et al., 2026).

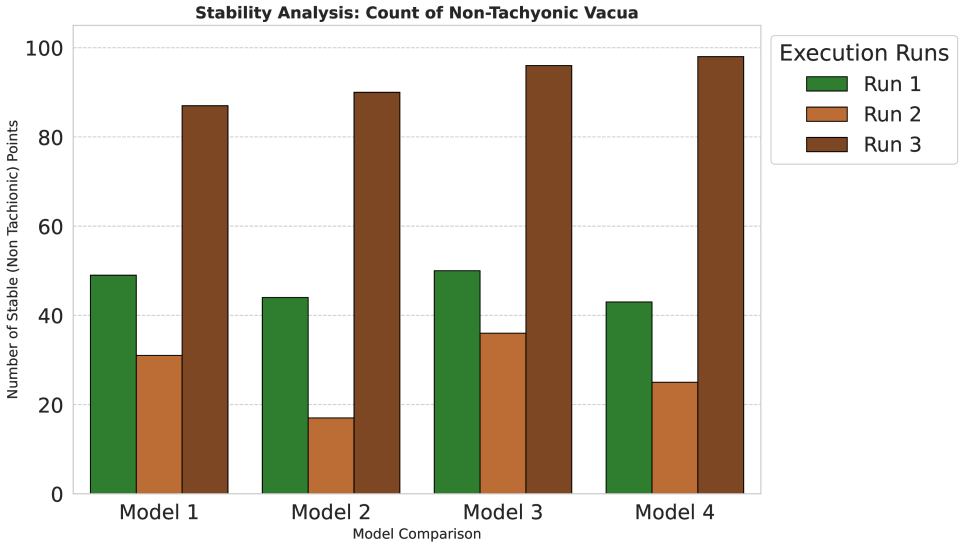


Figura 3. Conteo de vacíos estables por Model. Cada Run corresponde a una configuración específica de módulos S, T. Cada Model representa una configuración diferente del AG.
Fuente: (Marquez-Salazar et al., 2026).

Comparación contra AIW-PSO e IWO

El segundo experimento extiende la búsqueda hacia dos arquitecturas metaheurísticas distintas: Adaptive Inertia Weight Particle Swarm Optimization (AIW-PSO) e Invasive Weed Optimization (IWO). Ambos algoritmos se aplican al mismo potencial efectivo de tipo IIB con torsión y sobre un conjunto de configuraciones de los módulos, manteniendo los cinco coeficientes de flujo como variables de búsqueda.

El *benchmark* considera 88 pares de módulos y 100 ejecuciones independientes por configuración, para un total de 8 800 ejecuciones por algoritmo. El análisis registra la convergencia de la función de fitness, la distribución estadística de los puntos críticos, la proporción de vacíos estables y de de Sitter y el tiempo de ejecución. La evaluación conjunta se realiza mediante una clasificación de Borda con pesos iguales, incorporando simultáneamente los distintos criterios empleados para comparar el desempeño de ambos algoritmos. Los resultados del ranking por criterio, pares de criterio se muestran en las tablas 1 y 2. La tabla 3 muestra una comparación de los criterios **s5** y **s6** comparando un trabajo previo al actual.

Los criterios se mencionan a continuación: **s1**) valores medios minimizados cerca de 0, **s2**) menor asimetría al rededor del 0, **s3**) evita colas extendidas hacia energías positivas muy altas, **s4**) evita colas extendidas hacia energías negativas muy bajas, **s5**) proporción global de configuraciones estables maximizada, **s6**) proporción de vacíos de de Sitter (dS) estables maximizada, y **s7**) límites de convergencia de la función de fitness minimizados.

***Tabla 1**. Ganadores del Ranking según criterios independientes.*

Criterio	Ganador	Value
s1	PSO14	0.0901948358
s2	IWO1	0.7400678318
s3	IWO0	4.8921034412

s4	PSO13	-2.1034455829
s5	IWO1	0.3981818182
s6	PSO12	0.2845610236
s7	PSO14	0.0276629053

***Tabla 2**. Ganadores del Ranking según pares de criterios.*

Criterio	s1	s2	s3	s4	s5	s6	s7
s1	—	PSO4	PSO14	PSO13	IWO9	PSO7	PSO14
s2		—	IWO1	IWO7	IWO1	PSO0	IWO10
s3			—	PSO14	IWO1	PSO0	PSO14
s4				—	IWO13	PSO7	PSO13
s5					—	PSO1	PSO14
s6						—	PSO7
s7							—

El mejor, resultó ser el PSO14, pese a que **s6** no fue el más alto, los demás criterios jugaron a su favor. A pesar de que PSO12 e IWO1 tuvieron una mayor cantidad de estables, sus puntos describían vacíos de muy altas o muy bajas energías. Extremos que también se busca sean mitigados por el optimizador.

***Tabla 3**. Comparación entre el trabajo previo (Marquez Salazar et al. 2026a) y el mejor rendimiento actual (Marquez Salazar et al. 2026b) en los criterios de estabilidad.*

Criterio	s5	s6
Trabajo previo	0.2751481759	0.2994538834
Trabajo actual	0.3981818182	0.2845610236

Reducción de dimensionalidad y clasificación (resultados preliminares)

Partiendo de las clasificaciones propuestas previamente, surge la pregunta ¿qué información es relevante para la clasificación de los universos? A primera vista, la pregunta parece pertenecer al dominio de ciencia de datos; sin embargo, sus implicaciones dentro de la exploración del *landscape* podrían ser mayores, debido a que, finalmente, los puntos mínimos son descritos por un vector de contribuciones. La trivialidad o no trivialidad del problema queda por discutir.

Es preciso señalar que esta propuesta, en su concepción tuvo como propósito principal un mano a mano entre clasificación y optimización para reducir tiempos de evaluación. La clasificación busca distinguir entre 4 categorías: estable de Sitter, estable Anti-de Sitter, inestable de Sitter, inestable Anti-de Sitter.

Para el desarrollo de este experimento, se parte de un conjunto de datos construido a partir de los puntos encontrados en los benchmarks anteriores que luego pasará por un tratamiento para evitar sesgos, desbalances y errores de procesamiento (referido en adelante como original raw).

Tras el tratamiento del original raw, se realizó una rejilla con diferentes métodos de reducción de dimensionalidad; de cada método se obtuvo una nueva versión del *dataset*. Y el último paso consistió en una rejilla de clasificadores, en la que se procesó cada versión del *dataset*, el original raw inclusive.

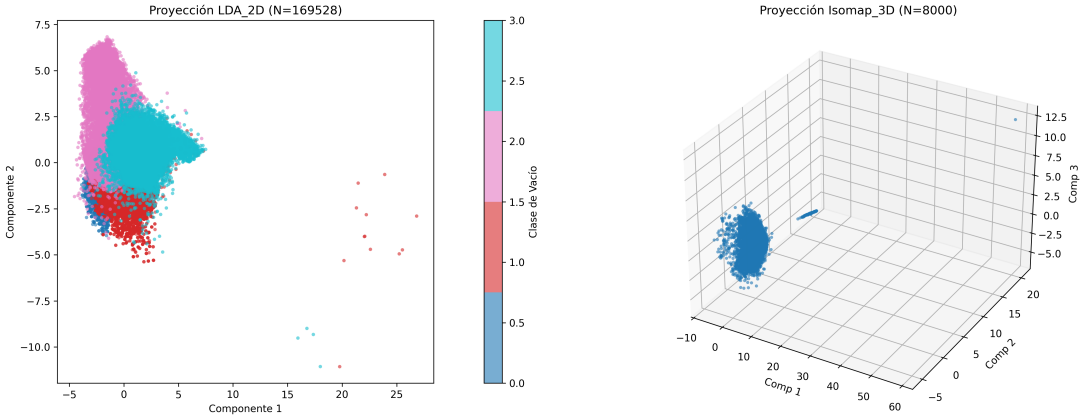


Figura 4. Resultados de dos de los métodos de reducción de dimensionalidad. Es posible notar la diferencia en el comportamiento de los métodos.

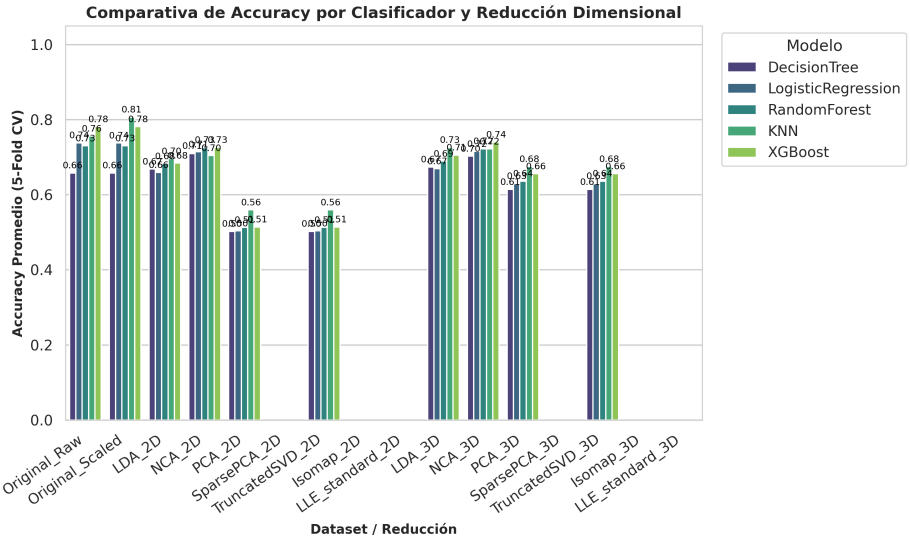


Figura 5. Rendimientos de accuracy en un 5-fold CV del benchmark de clasificadores. Abajo se puede encontrar cada versión del dataset, mientras que cada color representa un clasificador distinto.

Resultados y trabajos futuros

Los resultados de cada experimento se comentan a continuación.

Experimento 1. El primer experimento permitió encontrar una cantidad mayor de puntos interesantes que aproximaciones anteriores. Así mismo, es importante resaltar las distribuciones de la función potencial evaluada en los puntos obtenidos varía según los valores de los módulos. La relación de estas distribuciones respecto a la variación de los módulos permite comentar explícitamente la sensibilidad y complejidad topológica de la función potencial.

Experimento 2a. Los resultados del experimento permitieron demostrar que nuevas aproximaciones son capaces de lograr resultados interesantes, esto implica que es necesario explorar nuevos algoritmos y diferentes configuraciones.

Experimento 2b. Respecto al ranking Borda, se logró discriminar correctamente al mejor metaheurístico según los momentos estadísticos. Con esto, se espera aportar un proceso de evaluación concreto para futuros experimentos que involucren functiones potenciales distintas o nuevos algorimos de búsqueda/exploración. Es importante resaltar que la evaluación se hizo con una cantidad significativa de puntos que permiten observar una tendencia estadística. En otros casos, se deberá realizar algún método comparativo para *datasets* pequeños como Mann-Whitney U (Marquez-Salazar, 2026a).

Experimento 3. A pesar de presentar preliminares, el comportamiento de LDA ya nos da un indicio de que existe la posibilidad de discriminar con una cantidad inferior de parámetros. Esto tiene implicaciones relevantes dentro de la física teórica si, en futuras exploraciones o en nuevas aproximaciones dentro de esta línea de investigación, la reducción es posible, pues la búsqueda de una descripción basada en contribuciones es sumamente relevante dentro de esta línea de investigación.

Futuros trabajos estarán enfocados en encontrar coherencia del comportamiento numérico desde la perspectiva de la física de altas energías e, incluso, en la interpretación de dichos resultados.

Agradecimientos

El autor principal agradece a la SECIHTI por la beca de posgrado (referencia al CVU 1295151).

Referencias

Abel, S., y Rizos, J. (2014). Genetic algorithms and the search for viable string vacua. *Journal of High Energy Physics, 2014*(8), 010. https://doi.org/10.1007/JHEP08(2014)010

Bizet, N. C., Damian, C., Loaiza-Brito, O., Mayorga-Peña, D. K., y Montañez-Barrera, J. A. (2020). Testing swampland conjectures with machine learning. *The European Physical Journal C, 80*(8), 766. https://doi.org/10.1140/epjc/s10052-020-8332-9

Damian, C., Díaz-Barrón, L. R., Loaiza-Brito, O., y Sabido, M. (2013). Slow-roll inflation in non-geometric flux compactification. *Journal of High Energy Physics, 2013*(6), 109. https://doi.org/10.1007/JHEP06(2013)109

Damian, C., y Loaiza-Brito, O. (2013). More stable de Sitter vacua from S-dual nongeometric fluxes. *Physical Review D, 88*(4), 046008. https://doi.org/10.1103/PhysRevD.88.046008

Damian, C., y Loaiza-Brito, O. (2022). Metastable vacua from torsion and machine learning. *The European Physical Journal C, 82*, 1129. https://doi.org/10.1140/epjc/s10052-022-11118-x

Eiben, A. E., y Smith, J. E. (2015). *Introduction to evolutionary computing*. Springer. https://doi.org/10.1007/978-3-662-44874-8

Gao, X., y Zou, H. (2022). Applying machine learning to the Calabi-Yau orientifolds with string vacua. *Physical Review D, 105*(4), 046017. https://doi.org/10.1103/PhysRevD.105.046017

Kallosh, R., Linde, A., Prokushkin, S., y Shmakova, M. (2002). Gauged supergravities, de Sitter space, and cosmology. *Physical Review D, 65*(10), 105016. https://doi.org/10.1103/PhysRevD.65.105016

Lones, M. A. (2014). Metaheuristics in nature-inspired algorithms. In *Proceedings of the Companion Publication of the 2014 Annual Conference on Genetic and Evolutionary Computation* (pp. 1419–1422). Association for Computing Machinery. https://doi.org/10.1145/2598394.2609841

Ma, Z., Wu, G., Suganthan, P. N., Song, A., y Luo, Q. (2023). Performance assessment and exhaustive listing of 500+ nature-inspired metaheuristic algorithms. *Swarm and Evolutionary Computation, 77*, 101248. https://doi.org/10.1016/j.swevo.2023.101248

Marquez-Salazar, B., Damian, C., y Diaz-Pacheco, A. (2026a). *Genetic algorithm search for stable vacua in Type IIB string theory: A computational approach*. https://doi.org/10.1007/978-3-032-37444-8_48

Marquez Salazar, B., Damián Ascencio, C. E., y Díaz Pacheco, Á. (2026b). Particles and weed into the swampland: Testing metaheuristics ability for vacua search in string theory.

Mehrabian, A. R., y Lucas, C. (2006). A novel numerical optimization algorithm inspired from weed colonization. *Ecological Informatics, 1*(4), 355–366. https://doi.org/10.1016/j.ecoinf.2006.07.003

Ooguri, H., y Vafa, C. (2007). On the geometry of the string landscape and the swampland. *Nuclear Physics B, 766*(1–3), 21–33. https://doi.org/10.1016/j.nuclphysb.2006.10.033

Palti, E. (2019). The swampland: Introduction and review. *Fortschritte der Physik, 67*(6), 1900037. https://doi.org/10.1002/prop.201900037

Qin, Z., Yu, F., Shi, Z., y Wang, Y. (2006). Adaptive inertia weight particle swarm optimization. In *Artificial intelligence and soft computing – ICAISC 2006* (pp. 450–459). Springer. https://doi.org/10.1007/11785231_48

Saari, D. G. (1999). Explaining all three-alternative voting outcomes. *Journal of Economic Theory, 87*(2),
313–355. https://doi.org/10.1006/jeth.1999.2541

Vafa, C. (2005). *The string landscape and the swampland. arXiv.* https://doi.org/10.48550/arXiv.hep-th/0509212

Wolpert, D. H., y Macready, W. G. (1997). No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation, 1*(1), 67–82. https://doi.org/10.1109/4235.585893

Yang, X.-S. (2010). *Nature-inspired metaheuristic algorithms(2da, Eds)*. Luniver Press.

Yang, X.-S. (2017). *Nature-inspired algorithms and applied optimization*. Springer. https://doi.org/10.1007/978-3-319-67669-2