

Optimización de Costos en Empresas Latinoamericanas con Algoritmos Genéticos durante 2015-2023

Cost Optimization in Latin American Companies with Genetic Algorithms during 2015-2023

Chap Kau Kwan Chung

Afiliación: Universidad Americana, Paraguay

Email: wendy505@hotmail.com

 <https://orcid.org/0000-0002-5478-3659>

Miguel Ángel Alegre Brítez

Universidad Nacional de Asunción, Paraguay

Afiliación: malegre333@gmail.com

 <https://orcid.org/0000-0003-4265-9391>

Líneas de publicación: 3 Innovación y Tecnología

Fecha de recepción: 12 de septiembre del 2024

Fecha De aceptación: 19 de enero 2025


Artículo revisado por doble pares ciego

Resumen

La contabilidad de costos en empresas latinoamericanas enfrenta el desafío de manejar grandes volúmenes de datos y realizar análisis precisos en un entorno económico volátil. La dificultad radica en la gestión eficiente de costos indirectos y la toma de decisiones en tiempo real, exacerbada por las fluctuaciones económicas y las presiones competitivas. El objetivo de este artículo fue: evaluar la eficacia de los algoritmos evolutivos, especialmente los algoritmos genéticos, en la optimización de procesos contables y financieros en empresas latinoamericanas durante el periodo 2015-2023. Se buscó mejorar la asignación de recursos y la precisión en la gestión de costos para enfrentar los desafíos económicos actuales. Se implementó un algoritmo genético para minimizar el costo unitario en procesos de producción. Se utilizaron datos simulados de costos indirectos y unidades producidas, el algoritmo simula procesos de selección, cruce y mutación para encontrar soluciones óptimas. Se generó una población inicial de soluciones, se evaluó la aptitud de cada solución, y se aplicaron técnicas de selección, cruce y mutación a lo largo de 50 generaciones para obtener la mejor asignación de recursos. El algoritmo genético demostró ser eficaz en la minimización del costo unitario al optimizar la asignación de recursos. Las soluciones generadas presentaron una reducción significativa en los costos unitarios en comparación con métodos tradicionales. La automatización y la precisión en el análisis de datos mejoraron, los cuales proporcionaron a las empresas información más útil para la toma de decisiones. La

Esta obra se comparte bajo la licencia Creative Common Atribución-No Comercial 4.0

International (CC BY-NC 4.0) Revista Trimestral del Instituto Superior Universitario Espíritu Santo



adopción de algoritmos evolutivos en la contabilidad de costos ofrece ventajas significativas en términos de eficiencia y precisión en la gestión financiera de empresas latinoamericanas. Aunque existen barreras como la necesidad de inversión en tecnología y capacitación, y la resistencia al cambio, los algoritmos evolutivos tienen el potencial de transformar los procesos contables al automatizar y optimizar la toma de decisiones.

Palabras clave: algoritmos genéticos, optimización de costos, contabilidad de costos, empresas latinoamericanas, automatización.

Abstract

Cost accounting in Latin American companies faces the challenge of managing large volumes of data and performing accurate analyses in a volatile economic environment. The difficulty lies in efficiently managing indirect costs and making real-time decisions, exacerbated by economic fluctuations and competitive pressures. The objective of this article was to evaluate the effectiveness of evolutionary algorithms, particularly genetic algorithms, in optimizing accounting and financial processes in Latin American companies during the period 2015–2023. The aim was to improve resource allocation and accuracy in cost management to address current economic challenges. A genetic algorithm was implemented to minimize unit costs in production processes. Simulated data on indirect costs and units produced were used. The algorithm simulated selection, crossover, and mutation processes to find optimal solutions. An initial population of solutions was generated, the fitness of each solution was evaluated, and selection, crossover, and mutation techniques were applied over 50 generations to achieve the best resource allocation. The genetic algorithm proved effective in minimizing unit costs by optimizing resource allocation. The solutions generated showed a significant reduction in unit costs compared to traditional methods. Automation and data analysis accuracy improved, providing companies with more useful information for decision-making. The adoption of evolutionary algorithms in cost accounting offers significant advantages in terms of efficiency and accuracy in the financial management of Latin American companies. Although barriers such as the need for investment in technology and training, as well as resistance to change, still exist, evolutionary algorithms have the potential to transform accounting processes by automating and optimizing decision-making.

Keywords: genetic algorithms, cost optimization, cost accounting, Latin American companies, automation.



Introducción

El uso de algoritmos evolutivos en la contabilidad de costos experimenta un crecimiento significativo debido a su capacidad para optimizar procesos complejos en diversas áreas empresariales (González et al., 2024; Henriquez de Rocha Oliveira et al., 2024). La contabilidad de costos, disciplina crucial para la toma de decisiones financieras y administrativas, enfrenta el reto en la gestión de grandes volúmenes de datos, realización de análisis precisos que permitan una asignación adecuada de recursos y la maximización de beneficios (Bolígán Rojas et al., 2024; Rosas Sánchez & Vera Gómez, 2023). Este problema se intensifica en América Latina, donde las empresas operan en un entorno económico volátil, caracterizado por fluctuaciones de mercados y la presión constante por mejorar la competitividad. En este contexto, los algoritmos evolutivos, inspirados en procesos biológicos como la selección natural, ofrecen una solución innovadora mediante la automatización y optimización de procesos contables complejos (Martínez-López et al., 2023; Robles, 2023).

El periodo 2015-2023 marca un punto crítico para las empresas latinoamericanas, obligadas a adaptarse a cambios globales y regionales. La crisis económica generada por la pandemia de COVID-19, fluctuaciones de monedas locales y aumento de los costos operativos imponen nuevas exigencias, especialmente en la gestión de costos (Cáceres Malagón, 2023; Denis-Pérez et al., 2023). La adopción de algoritmos evolutivos se presenta como una herramienta clave para enfrentar estas dificultades al mejorar la eficiencia de los sistemas contables y facilitar la toma de decisiones basadas en datos actualizados (Crespo Sánchez et al., 2022; Llanos-Mosquera et al., 2022).


El presente estudio se justifica por la necesidad de incorporar tecnologías avanzadas que optimicen la gestión de costos en empresas de América Latina, particularmente en un entorno caracterizado por márgenes de ganancia reducidos y alta competitividad. Desde una perspectiva académica, esta investigación amplía la literatura sobre aplicaciones de algoritmos evolutivos en la contabilidad, un área que recibe poca atención en comparación con otros campos como la logística o la producción. A nivel práctico, el uso de estos algoritmos permite a las empresas el mejoramiento de su asignación en recursos, reducción en desperdicios y optimización de inventarios, factores que son críticos en sectores estratégicos como la manufactura y la agroindustria.

Además, este estudio tiene un impacto social al generar beneficios en el ecosistema empresarial de la región. La mejora en la rentabilidad empresarial fortalece la sostenibilidad de las organizaciones, también promueve la creación de empleos y contribuye al desarrollo económico regional (Aparici et al., 2021; Sol Dussaut et al., 2020). En este sentido, se espera que los resultados de esta investigación proporcionen herramientas metodológicas y teóricas útiles para empresas y académicos interesados en la innovación tecnológica de la contabilidad de costos.

Por todo lo expuesto, la presente investigación busca responder a la siguiente pregunta general: ¿Cómo influyen los algoritmos genéticos en la optimización de costos en empresas latinoamericanas durante el periodo 2015-2023? El objetivo general

Esta obra se comparte bajo la licencia Creative Common Atribución-No Comercial 4.0

International (CC BY-NC 4.0) Revista Trimestral del Instituto Superior Universitario Espíritu Santo



consiste en: Analizar la influencia de los algoritmos genéticos en la optimización de costos en empresas latinoamericanas durante el periodo 2015-2023.

Marco Teórico

Los algoritmos evolutivos se basan en la simulación de procesos biológicos como la selección, la mutación y el cruce genético para optimizar soluciones a problemas complejos. Estas técnicas incluyen los algoritmos genéticos, que generan poblaciones de soluciones y las mejoran de forma iterativa, y las estrategias evolutivas, que se centran en la optimización de parámetros continuos (Araos, 2018; Castrillón et al., 2018). Estas herramientas tienen aplicaciones en campos diversos como la logística, la producción y la contabilidad de costos.

En América Latina, la contabilidad de costos resulta pertinente para la asignación precisa de recursos y apoyo en la toma de decisiones estratégicas. Las empresas de la región enfrentan retos específicos como altos costos operativos, márgenes de ganancia reducidos y fluctuaciones económicas (Gutiérrez Hidalgo, 2023; Romero-Nieto & Castro-Morales, 2022). Los métodos tradicionales, que son manuales o semiautomatizados, no responden de manera adecuada a la complejidad creciente del entorno empresarial actual.


La automatización mediante algoritmos evolutivos aporta ventajas significativas en la contabilidad de costos. Estos algoritmos asignan costos indirectos de forma eficiente, lo cual es especialmente relevante en sectores como la manufactura, donde una asignación inadecuada afecta la rentabilidad. También optimizan la gestión de inventarios, al mejorar la rotación de productos y al reducir los costos asociados con el almacenamiento y el desperdicio (Castro, 2018; Oviedo et al., 2018). Además, minimizan los errores en la toma de decisiones mediante simulaciones de escenarios complejos, que proporcionan análisis precisos basados en datos actuales.

Sin embargo, la implementación de algoritmos evolutivos presenta retos importantes. La inversión inicial elevada, que incluye la adquisición de infraestructura tecnológica y la capacitación del personal, constituye una barrera para las pequeñas y medianas empresas. También existe resistencia al cambio por parte del personal, especialmente en organizaciones que utilizaron métodos tradicionales de forma histórica (Battelli, 2020; Fernández Vicente, 2020). Por último, surgen preocupaciones relacionadas con la seguridad, como protección de datos y confiabilidad de los resultados, lo cual añade complejidad a la adopción de estas tecnologías.

A pesar de estos obstáculos, los algoritmos evolutivos generan mejoras significativas en la eficiencia operativa y uso de los recursos disponibles. En el contexto globalizado, estas tecnologías identifican patrones y tendencias en los datos que los métodos tradicionales no logran descubrir, lo que permite a las empresas el acceso a nuevas oportunidades (Aparici et al., 2021; Castro Y. et al., 2021). Además, incrementan la competitividad empresarial, al facilitar la adaptación a cambios económicos y al fortalecer la capacidad para superar desafíos globales, como los efectos económicos de la pandemia de COVID-19.

Esta obra se comparte bajo la licencia Creative Common Atribución-No Comercial 4.0

International (CC BY-NC 4.0) Revista Trimestral del Instituto Superior Universitario Espíritu Santo



Materiales y Métodos

A efectos de resolver el problema de la minimización del costo unitario en un proceso de producción, se diseñó e implementó un algoritmo genético con el lenguaje de programación Python y el software Microsoft Excel. Este algoritmo, basado en los principios de la evolución natural, optimizó la asignación de recursos con el propósito de reducir los costos relacionados con la producción. En este modelo, se emularon procesos biológicos como selección, reproducción y mutación, que evolucionaron una población de soluciones a través de múltiples generaciones.

En este sentido, se trabajó con datos simulados que representaron los costos indirectos y las unidades producidas. Los valores de los costos indirectos se fijaron en 1000, 1500, 1200 y 800, mientras que las unidades producidas correspondieron a 500, 700, 600 y 400, respectivamente. Estos datos se procesaron en Python y Microsoft Excel, proporcionaron una base pertinente para el cálculo del costo unitario y evaluación de efectividad del algoritmo en alcanzar soluciones óptimas.

Cada posible solución se definió como un vector binario, donde cada bit especificó si un escenario particular se incluía en el cálculo del costo total o se excluía de este. La función de aptitud determinó el desempeño de cada solución mediante el cálculo del costo unitario, que se obtuvo al dividir la suma de los costos indirectos seleccionados entre las unidades producidas correspondientes. Para transformar este problema en uno de maximización, se invirtió el valor del costo unitario, lo cual favoreció a las soluciones con menor costo.

El algoritmo siguió un proceso estructurado en varias etapas. Inicialmente, se generó una población de vectores binarios aleatorios, que representaron posibles soluciones. Posteriormente, se evaluó la aptitud de cada individuo mediante la función de fitness, y se seleccionaron los mejores candidatos con el método de selección por torneo. En esta etapa, dos individuos se compararon, y el de mayor aptitud fue elegido progenitor.

La etapa de cruce combinó las características de los progenitores mediante un punto único, que creó nuevos vectores binarios como descendientes. Este proceso exploró nuevas combinaciones de soluciones, esto incrementó la diversidad de la población. La mutación se aplicó con una probabilidad del 10 %, lo que modificó de manera aleatoria un bit en el vector descendiente. Este paso introdujo variabilidad adicional en la población y redujo el riesgo de que el algoritmo quedara atrapado en soluciones subóptimas.

Finalmente, se realizó el reemplazo generacional, en el cual los descendientes sustituyeron a la población inicial. Este ciclo de evaluación, selección, cruce, mutación y reemplazo se repitió durante 50 generaciones. Al final del proceso, el algoritmo

Esta obra se comparte bajo la licencia Creative Common Atribución-No Comercial 4.0

International (CC BY-NC 4.0) Revista Trimestral del Instituto Superior Universitario Espiritu Santo



identificó la mejor solución en la población final, esto logró así minimizar el costo unitario en el proceso de producción.

Python fue utilizado para desarrollar el algoritmo, con bibliotecas como NumPy para optimizar cálculos y manejar estructuras de datos, y Matplotlib para generar visualizaciones que mostraron la evolución de la aptitud a lo largo de las generaciones. Por otro lado, Microsoft Excel facilitó la organización inicial de los datos y permitió validar los resultados de forma complementaria.

La implementación del algoritmo demostró la capacidad de los métodos genéticos para resolver problemas complejos de optimización en contextos industriales. Este enfoque validó la eficacia de las soluciones propuestas, optimizó recursos y redujo costos operativos. Además, ofreció una herramienta versátil y adaptable para futuras investigaciones en la gestión avanzada de procesos y costos.

Resultados y Discusión

A continuación, se presenta el desarrollo del algoritmo propuesto en el lenguaje Python

Resultados

```
import random
# Datos de ejemplo (reemplazar con datos reales)
costos_indirectos = [1000, 1500, 1200, 800]
unidades_producidas = [500, 700, 600, 400]
# Función de fitness (a evaluar y adaptar según los objetivos)
def calcular_fitness(individuo):
    costo_unitario = sum([costos_indirectos[i] / unidades_producidas[i] for i in
range(len(individuo)) if individuo[i]])
    return 1 / costo_unitario # Minimizar costo unitario
# Algoritmo genético simple
def algoritmo_genetico(poblacion_inicial, num_generaciones):
    poblacion = poblacion_inicial
    for generacion in range(num_generaciones):
        # Evaluar fitness de cada individuo
        fitness_scores = [calcular_fitness(individuo) for individuo in poblacion]
        # Selección (ej: torneo)
        padres = []
        for _ in range(len(poblacion)):
            candidatos = random.sample(poblacion, 2)
            ganador = candidatos[0] if fitness_scores[poblacion.index(candidatos[0])] >
fitness_scores[poblacion.index(candidatos[1])] else candidatos[1]
            padres.append(ganador)
        # Cruce (ej: punto simple)
        hijos = []
        for i in range(0, len(padres), 2):
            punto_cruce = random.randint(1, len(padres[0]) - 1)
```

Esta obra se comparte bajo la licencia Creative Common Atribución-No Comercial 4.0

International (CC BY-NC 4.0) Revista Trimestral del Instituto Superior Universitario Espíritu Santo



```
hijo1 = padres[i][:punto_cruce] + padres[i + 1][punto_cruce:]
hijo2 = padres[i + 1][:punto_cruce] + padres[i][punto_cruce:]
hijos.extend([hijo1, hijo2])
# Mutación (ej: bit flip)
for individuo in hijos:
    if random.random() < 0.1: # Probabilidad de mutación
        indice_mutacion = random.randint(0, len(individuo) - 1)
        individuo[indice_mutacion] = 1 - individuo[indice_mutacion]
# Reemplazo (ej: generacional)
poblacion = hijos
# Encontrar el mejor individuo de la última generación
mejor_individuo = max(poblacion, key=calcular_fitness)
return mejor_individuo
# Ejemplo de uso
poblacion_inicial = [[random.randint(0, 1) for _ in range(len(costos_indirectos))] for _ in
range(10)] # Población inicial aleatoria
mejor_solucion = algoritmo_genetico(poblacion_inicial, 50) # 50 generaciones
print("Mejor solución encontrada:", mejor_solucion)
#### Comentario del código
```

Discusión

El código presentado implementa un algoritmo genético para minimizar el costo unitario en un proceso de producción, con utilización de costos indirectos y unidades producidas como datos de entrada.

1. Datos de ejemplo:

```
python
costos_indirectos = [1000, 1500, 1200, 800]
unidades_producidas = [500, 700, 600, 400]
```

Los vectores representan los costos indirectos y las unidades producidas en cuatro diferentes escenarios o productos.


2. Función de fitness:

```
python
def calcular_fitness(individuo):
    costo_unitario = sum([costos_indirectos[i] / unidades_producidas[i] for i in
range(len(individuo)) if individuo[i]])
    return 1 / costo_unitario
```

Esta función evalúa la aptitud de cada individuo, que es una lista binaria. Cada elemento del vector `individuo` determina si un producto (o escenario) se incluye o no en el

Esta obra se comparte bajo la licencia Creative Common Atribución-No Comercial 4.0

International (CC BY-NC 4.0) Revista Trimestral del Instituto Superior Universitario Espíritu Santo



cálculo del costo unitario. El objetivo es minimizar este costo unitario, por ello, la función de fitness devuelve el inverso del costo total.

3. Algoritmo genético

A continuación, se presenta la discusión en tablas con categorías y subcategorías de análisis.


Tabla 1. Fases clásicas de un algoritmo genético

Categorías	Subcategorías
Evaluación de aptitud	Fitness, desempeño
Selección	Torneo, candidatos, elección
Cruce	Combinación, punto de corte
Mutación	Alienación, probabilidad
Reemplazo generacional	Sustitución, iteración
Resultado final	Solución óptima, generaciones

Fuente: Elaboración propia

El algoritmo sigue las fases clásicas de un proceso genético. Primero, se evalúa la aptitud de cada individuo en la población mediante el cálculo de la función de fitness (Araos, 2018; Castrillón et al., 2018). Luego, se seleccionan los mejores individuos se utilizó el método de torneo, en el que se eligen dos candidatos al azar y se escoge al mejor de ellos (Castro, 2018; Oviedo et al., 2018). Una vez realizada la selección, se lleva a cabo el cruce, que consiste en combinar pares de individuos seleccionados mediante un punto simple de corte (Battelli, 2020; Fernández Vicente, 2020). Posteriormente, se introduce mutación en los individuos con una probabilidad del 10 %, lo que implica la alteración aleatoria de uno de sus bits (Carreno Muñoz & Avilés, 2022; Crespo Sánchez et al., 2022). Finalmente, el proceso culmina con el reemplazo generacional, en el cual la población actual es sustituida por los hijos generados en cada iteración (Bedoya-Zambrano et al., 2023; Bergua et al., 2023). Al término del número predefinido de generaciones, se devuelve el mejor individuo como la solución óptima.

El algoritmo implementado sigue la estructura estándar de un algoritmo genético, según la literatura de optimización evolutiva (Bergua et al., 2023; Cáceres Malagón, 2023). Estos algoritmos están inspirados en la selección natural propuesta por Darwin y se utilizan con frecuencia para resolver problemas de optimización en los que las soluciones exactas resultan complejas de encontrar. En este caso particular, el objetivo es minimizar los costos unitarios de producción, lo cual es un aspecto fundamental en la optimización de procesos industriales.

**Tabla 2. Componentes principales en la representación y operadores de un algoritmo genético**

Categorías	Subcategorías
Representación	Vector binario, características
Función de fitness	Minimización, maximización
Selección	Torneo, equilibrio, eficacia
Cruce	Un punto, diversidad
Mutación	Alteración de bits, variabilidad

Fuente: Elaboración propia

La representación de la solución en este algoritmo se realiza mediante un vector binario. Este enfoque es consistente con los algoritmos genéticos, donde cada bit representa una característica específica de la solución (Bolígán Rojas et al., 2024; González et al., 2024; Henriquez de Rocha Oliveira et al., 2024). La función de fitness invierte el valor del costo unitario, se convierte un problema de minimización en uno de maximización, lo cual es una técnica común en la optimización con algoritmos genéticos (Goldberg, 1989). La selección por torneo es una estrategia eficaz para evitar la convergencia prematura de la población, mantiene un equilibrio entre la exploración de nuevas soluciones y la explotación de las mejores ya encontradas (Aparici et al., 2021; Sol Dussaut et al., 2020). Tanto el cruce de un punto como la mutación de bits son operadores clásicos que generan diversidad en la población, promueve el estancamiento en óptimos locales (Araos, 2018; Castrillón et al., 2018).

Conclusiones y Recomendaciones

Las conclusiones derivadas de la aplicación de algoritmos evolutivos en la contabilidad de costos de empresas latinoamericanas evidencian que estos enfoques avanzados presentan ventajas sustanciales en la optimización de procesos contables y financieros. La investigación destaca que la implementación de algoritmos evolutivos, como los algoritmos genéticos, potencia la eficiencia en la gestión de costos mediante la automatización tanto de cálculos como de decisiones. En el contexto latinoamericano, caracterizado por una economía volátil y desafíos particulares, dichos algoritmos ofrecen una ventaja competitiva al facilitar una asignación más eficiente de recursos y mejorar la precisión en los análisis financieros.

No obstante, el estudio también identifica diversas barreras que limitan la adopción de estas tecnologías. Entre los obstáculos se incluyen la necesidad de una inversión considerable en infraestructura tecnológica y la carencia de conocimientos especializados en algoritmos evolutivos. Asimismo, la resistencia al cambio y las inquietudes relacionadas con la seguridad de los datos representan dificultades sustanciales. A pesar de estos retos, el potencial transformador de los algoritmos



evolutivos para la contabilidad de costos y su capacidad en contribuir al éxito empresarial son considerablemente significativos.

En este contexto, se recomienda a las empresas latinoamericanas considerar la integración de algoritmos evolutivos como parte de sus estrategias de optimización de costos. Para facilitar esta transición, es fundamental realizar inversiones en capacitación del personal y actualización de la infraestructura tecnológica. Además, resulta importante promover la investigación y el desarrollo en el campo de la contabilidad de costos para expandir el conocimiento sobre la implementación de estos algoritmos y sus posibles beneficios.

En cuanto a futuras líneas de investigación, se sugiere explorar el impacto de los algoritmos evolutivos en diferentes sectores industriales, así como realizar comparaciones entre su efectividad y la de otros métodos de optimización. También es relevante investigar cómo estos algoritmos se adaptan a distintos entornos económicos y regulatorios, particularmente en contextos de alta volatilidad como el latinoamericano. De igual manera, se recomienda el desarrollo de estudios empíricos que evalúen la implementación práctica de estos algoritmos en empresas de diferentes tamaños y sectores, con el fin de obtener una visión más integral de sus beneficios y limitaciones. La exploración de nuevas técnicas dentro de los algoritmos evolutivos y su combinación con otras herramientas tecnológicas proporcionaría soluciones innovadoras y más eficientes para la contabilidad de costos en el futuro.

Referencias


- Aparici, R., Bordignon, F. R. A., & Martínez-Pérez, J. (2021). Alfabetización algorítmica basada en la metodología de Paulo Freire. *Perfiles Educativos*, 43(Especial), 36-54. <https://doi.org/10.22201/iisue.24486167e.2021.Especial.61019>
- Araos, F. (2018). Navegando en aguas abiertas: Tensiones y agentes en la conservación marina en la Patagonia chilena. *Revista de Estudios Sociales*, 64, 27-41. <https://doi.org/10.7440/res64.2018.03>
- Battelli, E. (2020). La decisión robótica: Algoritmos, interpretación y justicia predictiva. *Revista de Derecho Privado*, 40, 45-86. <https://doi.org/10.18601/01234366.n40.03>
- Bedoya-Zambrano, D. M., Lara Valencia, L. A., & Blandón-Valencia, J. J. (2023). Desarrollo de un algoritmo híbrido de control de amortiguadores magnetoreológicos para optimizar la respuesta dinámica en pórticos. *Entramado*, 20(1). <https://doi.org/10.18041/1900-3803/entramado.1.10270>
- Bergua, J. Á., Montañés, M., & Báez, J. M. (2023). Riders, algoritmos y negociación de la realidad. *Empiria. Revista de metodología de ciencias sociales*, 59, 81-102. <https://doi.org/10.5944/empiria.59.2023.37939>
- Bolígán Rojas, G., Trinchet Varela, C. A., & Pérez Rodríguez, R. (2024). Optimización multiobjetivo mediante algoritmos evolutivos, para el diseño de desalinizadores solares de humidificación deshumidificación. *RILCO DS: Revista de Desarrollo*



- sustentable, *Negocios, Emprendimiento y Educación*, 6(53), 53-67. <https://dialnet.unirioja.es/servlet/articulo?codigo=9527912>
- Cáceres Malagón, J. A. (2023). ¿Sueñan las máquinas con contratar? Un estudio sobre smart contracts y consentimiento algorítmico. *Revista de Derecho Privado*, 46, 155-185. <https://doi.org/10.18601/01234366.46.07>
- Carreno Muñoz, C., & Avilés, J. P. (2022). Localización Óptima de Equipos de Regulación de Voltaje y Compensación de Reactivos para Alimentadores de Medio Voltaje, Mediante Algoritmos Evolutivos. *INGENIO*, 5(1), 43-59. <https://doi.org/10.29166/ingenio.v5i1.3578>
- Castrillón, O. D., Sarache, W., Ruiz, S., Castrillón, O. D., Sarache, W., & Ruiz, S. (2018). Desempeño de Técnicas Tradicionales de Programación de la Producción Frente a un Algoritmo Evolutivo. *Información tecnológica*, 29(2), 141-154. <https://doi.org/10.4067/S0718-07642018000200141>
- Castro, J. C. L. D. (2018). Redes sociais como modelo de governança algorítmica. *MATRIZES*, 12(2), 165-191. <https://doi.org/10.11606/issn.1982-8160.v12i2p165-191>
- Castro Y., S., Plaza Ñ., L., & Torres S., L. C. (2021). Algoritmos para la fiscalización inteligente en el Valle del Cauca. *Revista de Derecho Fiscal*, 20, 267-278. <https://doi.org/10.18601/16926722.n20.07>
- Crespo Sánchez, G., Pérez Abril, I., García Sánchez, Z., Crespo Sánchez, G., Pérez Abril, I., & García Sánchez, Z. (2022). Exploración científica de los algoritmos evolutivos en la reconfiguración óptima de redes de distribución eléctrica. *Revista Universidad y Sociedad*, 14(1), 303-319. http://scielo.sld.cu/scielo.php?script=sci_abstract&pid=S2218-36202022000100303&lng=es&nrm=iso&tlng=es
- Denis-Pérez, A., Álvarez-Valdés, M. V., Cañete-Villafranca, R., & Monet-Fernández, Y. E. (2023). Algoritmo para la indicación del estudio por imágenes en pacientes politraumatizados. *Revista Médica Electrónica*, 45(4), 617-628. <https://www.redalyc.org/journal/3782/378277430009/>
- Fernández Vicente, A. (2020). Hacia una teoría crítica de la razón algorítmica. *Palabra Clave*, 23(2), 1-26. <https://doi.org/10.5294/pacla.2020.23.2.2>
- González, B., Frutos, M., Rossit, D. A., & Méndez, M. (2024). Consideración de las soluciones overlapping en la selección y parametrización de los operadores genéticos de un algoritmo evolutivo aplicado al flow-shop. *Memorias de las JAIIO*, 10(14), 405-408. <https://publicaciones.sadio.org.ar/index.php/JAIIO/article/view/913>
- Gutiérrez Hidalgo, F. (2023). Evolución histórica de la contabilidad de costes y de gestión (1885-2005). *De Computis, Revista Española de Historia de la Contabilidad*, 2(2), 100-122. <https://doi.org/10.26784/issn.1886-1881.v2i2.229>
- Henriquez de Rocha Oliveira, Á., Araujo Moraes, Y., Moraes Rego Sobrinho, R. P., Moraes Maia, J., & Silva Chaves, M. (2024). Parametrização automática de redes neurais utilizando algoritmos evolutivos. *Seven Editora*, 1191-1212. <https://sevenpublicacoes.com.br/editora/article/view/4246>
- Llanos-Mosquera, J.-M., Muriel-López, G.-L., Triana-Madrid, J.-D., & Bucheli-Guerrero, V.-A. (2022). Algoritmos evolutivos guiados por redes complejas libres

Esta obra se comparte bajo la licencia Creative Common Atribución-No Comercial 4.0

International (CC BY-NC 4.0) Revista Trimestral del Instituto Superior Universitario Espiritu Santo



- de escala. *Revista Científica*, 44(2), 228-241. <https://doi.org/10.14483/23448350.18039>
- Martinez-Lopez, Y., Bethencourt-Mayedo, M., Madera-Quintana, J., & Sutherland, J. (2023). Algoritmos evolutivos aplicados a la gestión de las unidades generadoras de la microred eléctrica de Cayo Coco. *Revista Cubana de Transformación Digital*, 4(4), e232:1-13. <https://rctd.uic.cu/rctd/article/view/232>
- Oviedo, B., Puris, A., & Zhuma, E. (2018). Algoritmos meta heurísticos para el aprendizaje de redes bayesianas1. *Revista Lasallista de Investigación*, 15(2), 353-366. <https://www.redalyc.org/journal/695/69559233028/>
- Robles, H. (2023). *Nuevos métodos para clustering basado en algoritmos evolutivos* [Http://purl.org/dc/dcmitype/Text, Universidad de Córdoba (ESP)]. <https://dialnet.unirioja.es/servlet/tesis?codigo=327186>
- Romero-Nieto, A. E., & Castro-Morales, L. G. (2022). La contabilidad de costos y los sistemas de evaluación de costo en las organizaciones. *CIENCIAMATRIA. Revista Interdisciplinaria de Humanidades, Educación, Ciencia y Tecnología*, 8(3), 304-316. <https://doi.org/10.35381/cm.v8i3.760>
- Rosas Sánchez, G. A., & Vera Gómez, E. X. (2023). Algoritmo social de elección: Alternativa al determinismo neoclásico. *Revista de Economía Institucional*, 26(50), 105-128. <https://doi.org/10.18601/01245996.v26n50.05>
- Sol Dussaut, J., Ponzoni, I., Olivera, A. C., & Vidal, P. J. (2020). Algoritmos Evolutivos Multiobjetivo aplicados a la Selección de Características en Microarrays de Datos de Cáncer. *Entre ciencia e ingeniería*, 14(28), 40-45. <https://doi.org/10.31908/19098367.2014>