

Estudio del Efecto de Operadores de Mutación en un Problema de Secuenciación de Vehículos.

**Sánchez Márquez E.M., Puga Soberanes H.J., Manzanares Cuadros J.I.,
Carpio Valadez J.M., Ornelas Rodríguez M., Mancilla Espinoza L.E.**

*Tecnológico Nacional de México, Instituto Tecnológico de León,
León, Guanajuato, México
martinezbucita@gmail.com*

Recibido: 28 de mayo de 2020

Aceptado: 15 de agosto de 2020

RESUMEN

Se presenta un estudio del desempeño e influencia de los operadores de mutación clásicos; ED/RAND/1, ED/RAND/2, ED/BEST/1 y ED/BEST/2 en el algoritmo de evolución diferencial con reparador cromosómico (EDRC), en el contexto del problema de secuenciación de vehículos. El efecto de éstos en el proceso evolutivo del algoritmo se estableció a través de la calidad de sus resultados. Se implementaron los operadores y compararon los resultados con los reportados por el algoritmo de recocido simulado de Renault, pionero del problema de secuenciación de vehículos y promotor del concurso ROADEF, del cual se utilizaron 16 instancias catalogadas en tres categorías según la prioridad de objetivos: instancias de color, fáciles y difíciles. Los resultados muestran la importancia de considerar las características de un operador de mutación tales como el número de individuos seleccionados de la población, considerar o no al mejor individuo y el tipo de operaciones entre individuos. En este trabajo se observó que el operador de mutación ED/BEST/2 mejoró el proceso evolutivo del algoritmo, específicamente en la generación de nuevos individuos. A partir de los resultados se plantea como trabajo a futuro desarrollar un operador especializado considerando más información del problema para mejorar las soluciones, especialmente en las instancias difíciles.

Palabras clave: problema de secuenciación de vehículos, evolución diferencial, operador de mutación.

ABSTRACT

A study of the performance and influence of classical mutation operators is presented; ED/RAND/1, ED/RAND/2, ED/BEST/1 and ED/BEST/2 in the chromosome repair differential evolution algorithm (CR-DEA), in the context of the vehicle sequencing problem. The effect of certain on the evolutionary process of the algorithm will be modified through the quality of its results. The operators were implemented and compared the results with the reports by the simulated annealing algorithm of Renault, pioneer of the vehicle sequencing problem and promoter of the ROADEF contest, of which 16 instances cataloged in three categories according to the frequency of objectives will be used: instances colored, difficult and difficult. The results indicated the importance of considering the characteristics of a mutation operator, such as the number of selected individuals in the population, whether to consider the best individual and the type of operations between individuals. This work specifies that the ED / BEST / 2 mutation operator improved the evolutionary process of the algorithm, specifically in the generation of new individuals. From the results, it is proposed as a future work to develop a specialized operator more information about the problem to improve the solutions, especially in difficult instances.

Keywords: vehicle sequencing problem, differential evolution, mutation operator

1. INTRODUCCIÓN

En el problema de secuenciación de vehículos (CS), las fábricas de automóviles necesitan programar el orden de los automóviles que ingresaran en la línea de producción, buscando satisfacer ciertos requerimientos de los talleres (Andrzej Jaskiewicz, 2004). El problema CS comenzó como un problema de satisfacción de restricciones considerando un solo objetivo (M. Dincbas, 1988) no fue hasta el año 2005, que fue tratado como un problema combinatorio y multiobjetivo al ser un punto de referencia para el Desafío Roadef (Solnon, 2008), donde se estableció el concepto de suavizado de restricciones, en relación al objetivo de minimizar sobrecargas de trabajo en el taller de ensamblado; las cuales son clasificadas como duras y blandas, además de introducir un segundo objetivo donde se considera el tamaño de lote pintura, buscando minimizar el consumo de solventes en el taller de pintura.

El problema abordado en este artículo es un problema multiobjetivo con restricciones de suavizado. Para su solución se plantea una función fitness $F(S)$ con un enfoque lexicográfico escalonado, con descarte, que toma en cuenta tres componentes F_1, F_2, F_3 , cada una de esta asociada con un objetivo, respetando el orden de prioridad $F_1 > F_2 > F_3$. Este orden viene dado por las instancias utilizadas en el concurso.

Renault proporciono 3 conjuntos de instancias (A, X y B) de casos reales de empresas automotrices para la realización del concurso Roadef, en este artículo se trabajó con las instancias del conjunto A, además, se tomaron como referencia los resultados reportados por los participantes de dicho concurso, los cuales siguen vigentes como herramienta de comparación en trabajos recientes como son (Zufferey, 2016) (Xiang-yang, 2018).

Se busca minimizar dos objetivos: cambios de color del taller de pintura, y minimizar la sobrecarga en las estaciones de trabajo (número de violaciones a las restricciones de proporción) del taller de ensamblaje, a lo que se conoce como suavizado; en este taller cada auto se caracteriza por un conjunto diferente de opciones o (techo solar, ABS, aire acondicionado, etc.), donde algunos vehículos pueden requerir más trabajo, lo anterior se formaliza mediante las restricciones de proporción N_i/P_i , las cuales representan las capacidades de cada estación; en éstas N_i es la cota máxima de vehículos que puede atender la estación i , en un bloque de P_i vehículos. Cuando se rebasa la proporción ocurren sobrecargas, la cantidad de sobrecargas corresponde al número de vehículos que sobrepasan a N_i .

En este modelo, en general, las posibles soluciones están formadas por una secuencia de los últimos automóviles programados el día anterior (D-1), que no entraron a la línea de ensamblaje, más los automóviles del día actual (D).

Este artículo da continuidad al trabajo de investigación previo (E.M. Sánchez Márquez, 2019) donde se propuso por primera vez utilizar el algoritmo de evolución diferencial para resolver el problema CS, realizando adaptaciones incluyendo un reparador cromosómico. Al realizar la comparación de los 4 operadores de mutación se busca dar respuesta a la pregunta de investigación ¿Al modificar el operador de mutación dentro del proceso evolutivo del algoritmo ED, es factible observar cambios importantes en la calidad de las soluciones? Para darle respuesta se tiene como objetivo principal realizar un análisis comparativo en cuanto al comportamiento, eficiencia y desempeño entre los operadores de mutación durante el proceso evolutivo del algoritmo ED buscando mejorar la calidad de las soluciones aplicados a un problema CS.

El trabajo está organizado de la siguiente manera: dentro de la sección introductoria se describe brevemente el algoritmo EDRC y las ecuaciones de cada uno de los operadores de mutación clásicos implementados, en la sección 2 se muestra la metodología implementada, para que en la sección 3 presentar los resultados obtenidos. Finalizando con una discusión de los resultados, conclusiones y trabajo a futuro.

1.1 ALGORITMO DE EVOLUCIÓN DIFERENCIAL CON REPARADOR CROMOSÓMICO (EDRC)

La evolución diferencial (DE Differential Evolution por sus siglas en inglés) fue desarrollada por Rainer Storn y Kenneth V. Price alrededor de 1995. Inspirado por la solución a los problemas de los coeficientes polinómicos de Chebyshev, y la optimización de los coeficientes del filtro digital (Simon, 2013). DE es un algoritmo basado en la población donde cada individuo de está es un vector n-dimensional que representa una solución candidata al problema, al operar sobre una población se evita que la búsqueda quede atascada en óptimos locales, enfatizando la mutación y utilizando un operador de cruce a posteriori de la mutación.

El algoritmo de evolución diferencial, fue adaptado para resolver el problema de secuenciación de vehículos considerando cuatro aspectos: generación de la población inicial donde se utilizó un operador de mutación denominado basado en el cambio generando permutaciones a partir de la instancias original, estructura y factibilidad (viable) del individuo; mediante un reparador cromosómico y definiendo la estructura del individuo considerando dos cromosomas, ejecución del algoritmo; considerando dos enfoques, el primero orientado a la escalarización buscando perseguir un enfoque lexicográfico escalonado y el segundo un enfoque integral para tener una mayor explotación y exploración del espacio de búsqueda. Una descripción más a detalle se presenta en (E.M. Sánchez Márquez, 2019). El último aspecto orientado a los operadores de mutación y cruza fue considerado hasta el presente artículo, realizando una comparación de diversos operadores de mutación buscando identificar el beneficio de dicho procedimiento.

1.2 OPERADORES DE MUTACIÓN

En esta investigación, se implementaron 3 operadores de mutación, los cuales realizan el proceso de generar un individuo mutado considerando diferente cantidad de individuos seleccionados y en algunos casos incluyendo al mejor individuo de la población de acuerdo con su fitness.

Los operadores fueron implementados en el algoritmo EDRC considerando las mismas características utilizadas en el artículo (E.M. Sánchez Márquez, 2019) con el operador ED/RAND/1 para poder comparar los resultados reportados contra los otros operadores ED/RAND/2, ED/BEST/1 y ED/BEST/2. A continuación se describen brevemente las ecuaciones utilizadas por cada uno.

OPERADOR DE MUTACIÓN ED/RAND/1

Operador de mutación clásico (ED/RAND/1). El operador de mutación, definido en la ecuación 1, lleva implícito el proceso de selección, en el cual se eligen de la población, de manera aleatoria 3 individuos X_{r_1}, X_{r_2} y X_{r_3} diferentes entre sí, y diferentes de X_{r_i} que representa al individuo que se busca reemplazar. Observe que el individuo mutado X_m se obtiene realizando operaciones aritméticas, donde F representa al factor de mutación.

$$X_m = X_{r_1} + F(X_{r_2} - X_{r_3}) \text{ donde: } r_1 \neq r_2 \neq r_3 \neq r_i \in [1, N], 0 < F \leq 2 \quad (1)$$

OPERADOR DE MUTACIÓN ED/RAND/2

El operador de mutación clásico (ED/RAND/2) realiza el mismo procedimiento que el operador ED/RAND/1, con la modificación en el proceso de selección, en el cual se eligen de la población, de manera aleatoria 5 individuos $X_{r_1}, X_{r_2}, X_{r_3}, X_{r_4}$ y X_{r_5} diferentes entre sí, y diferentes de X_{r_i} que representa al individuo que se busca reemplazar. Observe que el individuo mutado X_m se obtiene realizando operaciones aritméticas, donde F representa al factor de mutación.

$$X_m = X_{r_5} + F(X_{r_1} + X_{r_2} - X_{r_3} - X_{r_4}), \quad r_1 \neq r_2 \neq r_3 \neq r_4 \neq r_5 \neq r_i \quad (2)$$

OPERADOR DE MUTACIÓN ED/BEST/1

El operador de mutación, definido en la ecuación 3, lleva implícito el proceso de selección, en el cual se eligen de la población, de manera aleatoria 2 individuos X_{r_1} y X_{r_2} diferentes entre sí, y diferentes de X_{r_i} que representa al individuo que se busca reemplazar. Además se selecciona al mejor individuo X_{best} de la población actual. Observe que el individuo mutado X_m se obtiene realizando operaciones aritméticas, donde F representa al factor de mutación.

$$X_m = X_{best} + F(X_{r_1} - X_{r_2}), \quad r_1 \neq r_2 \neq r_i \quad (3)$$

OPERADOR DE MUTACIÓN ED/BEST/2

El operador de mutación ED/BEST/2 al igual que el operador ED/BEST/1 consideran en su proceso de selección al mejor individuo de la población X_{best} , en lo único que difieren es en el número aleatorio de individuos seleccionados $X_{r_1}, X_{r_2}, X_{r_3}$ y X_{r_4} diferentes entre sí, y diferentes al individuo que se busca reemplazar X_{r_i} . Observe que el individuo mutado X_m se obtiene realizando operaciones aritméticas, donde F representa al factor de mutación. X_{best} es el mejor de la población actual.

$$X_m = X_{best} + F(X_{r_1} + X_{r_2} - X_{r_3} - X_{r_4}), \quad r_1 \neq r_2 \neq r_3 \neq r_4 \neq r_i \quad (4)$$

2 METODOLOGIA

Para la ejecución de los experimentos se utilizó el conjunto A de las instancias proporcionadas por Renault, el cual pertenece al conjunto (A, X y B) de casos reales de empresas automotrices, tomadas de la Constraint Satisfaction Problem Lib repository (ver www.csplib.org). Cada instancia tiene 4 archivos: vehicles, ratios, paint_batch_limit y Optimization_objective.

En el archivo vehicles, se encuentran los parámetros c (número de vehículos a secuenciar del día actual) y (número de vehículos secuenciados del día anterior) c' , además de la configuración de cada vehículo de acuerdo con los objetivos a minimizar, los cuales son: suavizado de restricciones y cambios de color. En el caso de suavizado de restricciones existen dos tipos, aquellas que tiene alta prioridad (H) y las que tienen baja prioridad (L); son consideradas como restricciones suaves por que se busca satisfacerlas en la medida de lo posible; en el caso de cambios de color (C) se considera una restricción dura conocida como tamaño de lote (B), la cual debe ser respetada obligatoriamente. El archivo de ratios muestra las restricciones de proporción para cada opción H y L. El archivo paint_batch_limit muestra la restricción dura en cuanto al tamaño de lote (B) de colores consecutivos y Optimization objectives muestra la prioridad de los objetivos.

El algoritmo EDRC ejecutado con los diferentes operadores de mutación fue implementado en java y compilado con IntelliJ IDEA Community Edition 2018. Los experimentos fueron corridos en una computadora Toshiba con un procesador Intel i3-3217u y 6GB de memoria RAM con Windows 10.

Los parámetros utilizados para dicho algoritmo fueron: factor de mutación $F=1$, factor de cruza $CR=0.9$ y tamaño de población $N=10$, ambos parámetros utilizados en el estado del arte.

Para realizar un análisis estadístico de los resultados obtenidos se consideró aplicar una prueba de normalidad para verificar el comportamiento de los datos; se aplicó la prueba de Kolmogórov-Smirnov estructurada para cada operador de mutación y por cada uno de los objetivos (suavizado de restricciones H y L y cambios de color C) por separado. Acorde con los resultados obtenidos se aplicó la prueba no paramétrica Wilcoxon en el objetivo de suavizado de restricciones y la prueba paramétrica T-Student para el objetivo de cambios de color. Se realizaron las comparaciones entre los 4 operadores de mutación para identificar el de mejor desempeño y compararlo contra el estado de arte (Renault), esto en el caso del objetivo de suavizado. Para el objetivo de color se realizaron comparaciones por pares considerando todos los operadores de mutación y el estado de arte (Renault).

3 RESULTADOS

El desempeño del algoritmo EDRC con los diferentes operadores de mutación fue comparado con los resultados reportados por Renault y con los resultados del artículo (E.M. Sánchez Márquez, et al, 2019) donde fue utilizado el operador de mutación ED/RAND/1.

Se muestran los porcentajes relativos obtenidos por cada operador de acuerdo al tipo de instancia y además se contemplaron los fitness obtenidos por cada objetivo (H, L y C) para cada tipo de instancias para realizar un análisis estadístico con mayor profundidad.

Los fitness obtenidos son presentados en 3 tablas, una por cada tipo de instancias (color, difíciles y fáciles), considerando los objetivos H, L y C para cada uno de los operadores de mutación: ED/RAND/1 (E.M. Sánchez Márquez, et al, 2019), ED/RAND/2, ED/BEST/1 y ED/BEST/2, incluyendo los resultados obtenidos por la Renault. Posteriormente se muestran los porcentajes relativos obtenidos por cada caso y por último el resultado de un análisis estadístico.

En las tablas, los nombres asignados por la Renault a cada instancia corresponden a sus características en cuanto a nivel de dificultad y prioridad de objetivos. Las instancias están codificadas indicando un orden de prioridad de izquierda a derecha. En ellas aparecen las letras H, L o P que corresponden a restricciones de prioridad alta, baja y color respectivamente. Estas pueden ser precedidas de E o D que indican si son fáciles o difíciles respectivamente. Así la instancia PHEL1 indica que el color tiene primera prioridad, seguida de una alta prioridad de suavizado y ésta seguida a su vez de una baja prioridad de suavizado considerada fácil. Al final pueden contener un número identificador para distinguir a instancias con las mismas prioridades. En las tablas, los resultados obtenidos se muestran con tres distintos colores: azul para los resultados donde compite la propuesta, verde donde los resultados son mejores que los comparados y rojos donde la propuesta no compite.

3.1 TABLAS DE RESULTADOS

Instancias de color

Tabla 1: Resultados para las instancias de color.

Instancia	Objetivo H				
	Renault	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
PHE	392	469,2	435,37	419,8	392
PHEL1	197	197	200	195,7	186,9

PHEL2	48	54,3	49,8	48,8	48
PHEL3	462	461	502,55	488,8	463,1

Tabla 1.1: Resultados para las instancias de color.

Objetivo L					
Instancia	Renault	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
PHE	NA	NA	NA	NA	NA
PHEL1	61	61	63,5	60,6	59,2
PHEL2	5	6,9	4,7	5,3	5
PHEL3	883	843	854,44	850,3	844,1
Objetivo C					
Instancia	Renault	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
PHE	69	71	74,37	72,4	69
PHEL1	30	30	31,2	30	30
PHEL2	11	11	11	11	11
PHEL3	64	64	73,88	70,9	64,9

Instancias fáciles

Tabla 2: Resultados para las instancias fáciles.

Objetivo H					
Instancia	Renault	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
HELP	0	1,8	0,1	2,4	1,2
HEPL1	28	0,7	0	21,6	23,5
HEPL2	2	1,2	3,22	2	2
HEPL3	2	1,1	2,66	6,5	2
HEPL4	0	1	26,88	1,2	0
Objetivo L					
Instancia	Renault	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
HELP	2075	1979,3	2041	2074	2077
HEPL1	50	68,9	50,88	50	50,8
HEPL2	2	13,4	14,66	2	2
HEPL3	787	785,2	785	787,8	787
HEPL4	2075	2112,1	2163,44	2075,8	2074,8
Objetivo C					
Instancia	Renault	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
HELP	290	320,8	291,66	291,6	291,2
HEPL1	46	87,3	121,77	46	46,6
HEPL2	70	205,5	256,22	70	70
HEPL3	195	340,3	195,88	197,9	195
HEPL4	290	309,4	300,44	290	290

Instancias difíciles

Tabla 3: Resultados para las instancias difíciles.

Objetivo H					
Instancia	Renault	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
HDLP1	42	38,4	59,11	46,5	35
HDLP2	106	112,4	299,88	111,5	138,4
HDLP3	82	81,5	89,44	83,2	113,8
HDP	115	136,9	117,33	152,2	124,6
HDPL1	35	40	61,55	38,2	50
HDPL2	98	106	256,44	129,2	98
HDPL3	73	74	77,66	81	95
Objetivo L					
Instancia	Renault	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
HDLP1	98	864,9	828,44	869,2	863,7
HDLP2	134	136,6	249,77	134,2	146,4
HDLP3	77	79	132,66	77	106,7
HDP	NA	NA	NA	NA	NA
HDPL1	861	865	852,55	857	868,1
HDPL2	99	98	198,66	114,3	99
HDPL3	205	217	218,55	210	215,4
Objetivo C					
Instancia	Renault	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
HDLP1	334	186,6	199,33	185,1	182,8
HDLP2	392	484,4	464,22	393,1	401,4
HDLP3	464	476	563,88	465,2	471,5
HDP	229	350,8	397,33	159	178,1
HDPL1	182	190,5	187,66	183	184,4
HDPL2	468	526	537,33	472,8	468
HDPL3	363	449	536	368	368,8

3.2 PORCENTAJES RELATIVOS POR CASOS

De la información de las tablas de la sección 5.1, se obtuvieron los porcentajes relativos de desempeño por cada tipo de instancia considerando los 4 operadores de mutación.

Tabla 4: Porcentajes relativos para las instancias de color.

	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
Gano	64%	28%	44%	82%
Compitió	18%	36%	28%	18%
Perdió	18%	36%	28%	0%

Para el caso de las instancias de color se puede observar que el operador ED/BEST/2 brindo mejores resultados con un 82% superando al estado del arte y un 0% de resultados no favorables.

Tabla 5: Porcentajes relativos para las instancias fáciles.

	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
Gano	33%	27%	54%	67%
Compitió	13%	33%	46%	33%
Perdió	54%	40%	0%	0%

De acuerdo con los porcentajes relativos de las instancias fáciles (Véase Tabla 5) de cada operador de mutación, los operadores ED/BEST/2 y ED/RAND/2 no obtuvieron malos resultados, ya que, ambos obtuvieron 0%; pero en cuanto al porcentaje de buenos resultados el operador con mejor desempeño fue ED/BEST/2.

Los porcentajes relativos obtenidos de acuerdo con las instancias difíciles fueron las siguientes:

Tabla 6: Porcentajes relativos para las instancias difíciles.

	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
Gano	20%	10%	20%	30%
Compitió	25%	15%	50%	15%
Perdió	55%	75%	30%	55%

Se observó que de acuerdo con el porcentaje de resultados ganados el mejor operador de mutación fue ED/BEST/2, sin embargo, el que obtuvo menor porcentaje de malos resultados fue ED/RAND/2.

3.3 ANÁLISIS ESTADÍSTICO DE RESULTADOS

Para determinar la significancia de los resultados obtenidos en los casos donde, de acuerdo con los porcentajes relativos de desempeño, los operadores de mutación clásicos son mejores o compiten, se realizó una prueba de normalidad kolmogorov-Smirnov para cada operador de mutación y para cada objetivo (suavizado de restricciones H y L y cambios de color C), planteando como hipótesis nula que los datos tienen un comportamiento de una distribución normal, con un nivel de significancia de 0.05. Los resultados obtenidos se muestran en la Tabla 7.

Tabla 7: Resultados de prueba de normalidad

Objetivo	Valores p			
	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2
H	0.10	0.014	0.040	0.021
L	0.008	0.010	0.007	0.007
C	0.200	0.200	0.176	0.149

En el caso de los objetivos H y L los resultados de la prueba de normalidad son menores al nivel de significancia, concluyendo que los datos no tienen comportamiento de una distribución normal. A partir de lo anterior se decidió realizar la prueba estadística no paramétrica de Wilcoxon usando un nivel de significancia de 0.05 y como hipótesis nula se planteó que el desempeño de los operadores de mutación clásicos entre ellos mismos y contra el estado de arte era el mismo.

Para el objetivo C la prueba de normalidad mostro valores p superiores al nivel de significancia establecido, por lo cual se concluyó que los datos se comportan como una distribución normal. Debido a lo anterior se decidió realizar

la prueba paramétrica T-Student, realizando comparaciones por pares considerando un nivel de significancia de 0.05.

Para el análisis estadístico primero se compararon los resultados obtenidos entre todos los operadores de mutación para los objetivos H y L, los cuales se muestran en la Tabla 8. Los cuales son mayores al nivel de significancia definido, permitiendo inferir que no existe diferencia significativa en el desempeño entre los operadores de mutación.

Tabla 8: Resultados pruebas estadísticas, comparación entre operadores

Objetivo	Valor p
H	0,122
L	0,503

Para comparar el desempeño de los operadores con el estado del arte, se seleccionó al operador ED/BEST/2 que obtuvo los mejores porcentajes relativos de desempeño con respecto a los demás operadores (Véanse Tablas 4, 5 y 6). Se aplicó la prueba de Wilcoxon, de la cual se obtuvieron los siguientes resultados.

Tabla 9: Resultados pruebas estadísticas, comparación operador ED/BEST/2 y estado de arte

Objetivo	Valor p
H	0,139
L	0,139

De acuerdo a los resultados de la Tabla 9, la prueba estadística no paramétrica no permite concluir que haya diferencia significativa entre el desempeño del operador de mutación ED/BEST/2 y los reportados, en el estado del arte, por Renault.

Para el objetivo de color C se realizaron comparaciones por pares entre todos los operadores de mutación y Renault, lo cual nos dio como resultado la matriz de la Tabla 10.

Tabla 10: Resultados pruebas estadísticas, objetivo C.

Operador	Valores p				
	ED/BEST/1	ED/RAND/1	ED/RAND/2	ED/BEST/2	Renault
ED/BEST/1	--	0,523	0,005	0,004	0,050
ED/RAND/1	0,523	--	0,009	0,007	0,040
ED/RAND/2	0,005	0,009	--	0,498	0,260
ED/BEST/2	0,004	0,007	0,498	--	0,291
Renault	0,050	0,040	0,260	0,291	--

La interpretación para cada operador es: el operador ED/BEST/1 tiene diferencia significativa con ED/RAND/2 y ED/BEST/2, con Renault la prueba no es capaz de definirlo y con ED/RAND/1 no existe diferencia significativa. ED/RAND/1 tiene diferencia significativa con ED/RAND/2, ED/BEST/2 y Renault, ED/RAND/2 tiene diferencia significativa con ED/BEST/1, ED/RAND/1 y por último ED/BEST/2 tiene diferencia significativa con ED/BEST/1 y ED/RAND/1. Comparando a Renault tenemos que con ED/BEST/1 y ED/RAND/1 existe diferencia significativa, pero con ED/RAND/2 y ED/BEST/2 no.

Debido a que las pruebas estadísticas muestran una diferencia significativa entre Renault y los operadores ED/BEST/1 y ED/RAND/1, se calculó la media de los resultados en las instancias para observar la posición relativa de su desempeño considerando mejor posicionados los que obtuvieron el valor menor o más cercano a cero. Los resultados obtenidos nos permiten concluir que Renault tiene el primer lugar en desempeño seguido del operador

ED/BEST/1 (Véase Tabla 10). Más concretamente esto quiere decir que ED/BEST/1 se aproxima a los resultados reportados por Renault, pero no logra competir. Por otro lado los algoritmos ED/RAND/2 y ED/BEST/2 con los que no se tiene diferencia significativa, de acuerdo a los resultados mostrados, logran competir y en algunos tipos de instancias mejorar los resultados reportados por Renault (Véase Tablas 1-3).

Tabla 11: Rangos para el objetivo C con existencia de diferencia significativa entre Renault y los operadores ED/RAND/1 y ED/BEST/1

Algoritmo	Media	Rango
Renault	218,56	1
ED/RAND/1	265,13	3
ED/BEST/1	256,41	2

A partir del análisis estadístico anterior y los porcentajes relativos de desempeño, es posible sugerir que para los objetivos H y L, el operador ED/BEST/2 es una opción para ser utilizado en el algoritmo EDRC ya que sus resultados compiten con el estado de arte, sin embargo, se debe seguir trabajando para mejorar la optimización en las instancias difíciles, específicamente en el objetivo H. En cuanto al objetivo C el operador con mejores resultados fue ED/BEST/1.

4 DISCUSIÓN

En esta investigación se planteó la pregunta: ¿Al modificar el operador de mutación dentro del proceso evolutivo del algoritmo ED, es factible observar cambios importantes en la calidad de las soluciones? El análisis de los resultados presentados en la sección anterior muestra sensibilidad de los operadores a las variables de número de individuos seleccionados, selección o no del mejor individuo y a las operaciones entre los individuos. Si bien se observaron cambios en los individuos generados y en la calidad de estos, los resultados no permiten establecer una relación causal directa entre el cambio en las variables y los resultados obtenidos por el algoritmo EDRC al problema de secuenciación de vehículos.

Sin embargo, es posible observar que para el objetivo de suavizado de restricciones, el operador ED/BEST/2 mostró mejores soluciones; con lo cual se puede establecer que para este objetivo es necesario considerar al mejor individuo y contar con mayor información. Por otra parte, para el objetivo de cambios de color, el operador ED/BEST/1 brinda mejores soluciones, cambiando la cantidad de individuos seleccionados, pero manteniendo al mejor individuo. Lo anterior nos permite plantear que un estudio profundo de casos anómalos y de bajo desempeño puede ser una fuente de información que permita mejorar el desempeño del EDRC.

5 CONCLUSIONES

El objetivo de este trabajo de investigación fue estudiar y analizar el comportamiento del algoritmo EDRC al implementar diferentes operadores de mutación: ED/RAND/1, ED/RAND/2, ED/BEST/1 y ED/BEST/2, comparadas con el estado de arte. Se observó que la estructura e información que utiliza el operador de mutación es crucial para obtener mejores soluciones durante el proceso evolutivo.

Los resultados y el análisis estadístico muestran que modificar las características de un operador de mutación, dentro del proceso evolutivo del algoritmo EDRC, por ejemplo: cantidad de individuos seleccionados de la población, considerando al mejor individuo y el tipo de operaciones realizadas entre los individuos, afectan en la calidad de las soluciones obtenidas respecto al número de violaciones o cambios de color y la secuencia de vehículos generados. En la investigación se aplicaron operadores de mutación clásicos, lo cual nos permite considerar, como trabajo

futuro, el estudio de la generación de operadores de mutación especializados en el proceso evolutivo del EDRC incorporando las características del problema de secuenciación de vehículos para mejorar el desempeño y alcanzar resultados que compitan con el estado del arte.

6 AGRADECIMIENTO

Agradecimientos. Los autores desean agradecer al Consejo Nacional de Ciencia y Tecnología (CONACYT) de México, a través de la beca para estudios de posgrado: 634738 (E. Sánchez) y al Tecnológico Nacional de México/Instituto Tecnológico de León, por el apoyo brindado para la realización de esta investigación.

7 REFERENCIAS BIBLIOGRAFICAS

- Andrzej Jaskiewicz, P. K. (2004). Adaptation of the Genetic Local Search Algorithm to a Car Sequencing Problem.
- E.M. Sánchez Márquez, H. P. (2019). Algoritmo de Evolución Diferencial con Reparador Cromosómico aplicado a un problema de secuenciación de vehículos. *Research in Computing Science*, 148(7).
- M. Dinbas, H. S. (1988). Solving the car-sequencing problem in constraint logic programming. *Proceedings of the European Conference on Artificial Intelligence (ECAI-88)*, 290-295.
- Simon, D. (2013). *Evolutionary optimization algorithms: Biologically-Inspired and Population-Based Approaches to Computer Intelligence*. Cleveland: Wiley.
- Solnon, C. (2008). The car sequencing problem: overview of state-of-the-art methods and industrial case-study of the ROADEF'2005 challenge problem. *European Journal of Operational Research*, 191, 912-927.
- Xiang-yang, Z. &.-D. (2018). A hybrid algorithm based on tabu search and large neighbourhood search for car sequencing problem. *Journal of Central South University*, 25, 1-16.
- Zufferey, N. (2016). Tabu Search Approaches for Two Car sequencing problems with smoothing constraints. En F. Y. El-Ghazali Talbi, *Metaheuristics for production systems* (Vol. 60, págs. 167-190). Francia: Springer.