

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Un Algoritmo Genético para la Solución del Problema Flow Shop Minimizando el Consumo Energético.

Wendy Sanabria Palencia y Angie Alejandra Monsalve Serrano

Trabajo de grado para optar el título de Ingeniero Industrial

Director

Carlos Eduardo Díaz Bohórquez

Magister en Ingeniería Industrial

Codirector

Fabián Alexander Torres Cárdenas

Magister en Ingeniería Industrial

Universidad Industrial de Santander

Facultad de Ingenierías Físico-Mecánicas

Escuela de Estudios Industriales y Empresariales

Bucaramanga

2021

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Dedicatoria

A Dios, quien fue y sigue siendo mi guía y principal ayuda durante los momentos de dificultad, pero también de regocijo, con quien consulte y tome grandes decisiones para mi vida, mi mayor fuente de amor, paz y alegría.

A mis papas y mis hermanos, los motores de mi vida, su apoyo incondicional y respaldo fue fundamental para llegar a la meta, su amor y el querer siempre lo mejor para mí ha hecho posible la mujer que soy ahora. Gracias por cada sacudón, pero especialmente gracias por cada palabra de aliento, en los momentos difíciles de la carrera, por nunca dejar de creer en que yo lo lograría.

A todos los seres queridos que creyeron en mí y estuvieron pendientes de mi proceso y hoy están sintiendo la misma alegría que yo, especialmente a mi abuelita María, quien justo estuvo presente el día que inicio este gran sueño que hoy se hace realidad.

A mi compañero de aventuras, Eder, por estar a mi lado y escucharme en mis momentos de angustia, ser un apoyo incondicional, por todo el amor que me ha brindado y por siempre tener un abrazo reconfortante o un chiste con el cual hacerme sonreír. Gracias por creer en mí.

Tu ayuda ha sido fundamental.

A mi amiga y compañera de tesis, Wendy, por haber atravesado junto a mí por los momentos quizá más desafiantes de nuestras vidas, pero también momentos maravillosos, por haber forjado una amistad a través de todos estos años. Un día lo dijimos y hoy lo estamos cumpliendo, graduarnos juntas fue un sueño, fueron un millón de emociones ante cada dificultad y logro, y hoy juntas podemos decir, no fue fácil, pero lo logramos.

Con todo mi amor

Angie Alejandra Monsalve Serrano

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Dedicatoria

*A Dios por siempre poner un ángel en mi camino y por cada bendición en mi vida que ha
hecho esto posible.*

*A mis padres Luis y Nancy mis ángeles en la tierra a quien les debo cada uno de mis
logros, pues el sacrificio por sus hijos ha sido invaluable y sin su amor y apoyo incondicional
nada de este sería posible, han sido los héroes de mi vida por ellos estoy infinitamente
agradecida y de la misma manera los amo infinitamente.*

*A mis hermanos Jeffrey, Jason y Julián por su amor, ser mi ejemplo a seguir, por creer
en mí, todo el apoyo y palabras de aliento durante este proceso y especialmente ser mis
protectores en cada uno de los pasos que doy, los amo con todo mi corazón y algún día
encontraremos las siete esferas del dragón juntos.*

*To Jacob for his love and patience during all these years, having you in mi life is
priceless and I'm forever grateful for that, I'm also extremely thankful for your support every
step of the way, every advice, every long night listening to me when I was struggling and
specially for always believing in me, I love you deeply.*

*A mi compañera de tesis Angie pero mas importante gran amiga, los amigos son la otra
familia que elegimos y he sido muy afortunada de haber compartido este proceso contigo con
todos sus altibajos y ahora lograr este sueño juntas, le agradezco siempre a Dios por poner
personas tan extraordinarias en mi vida como tu.*

Wendy Sanabria Palencia

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Agradecimientos

A Dios, por habernos dado la fortaleza mental y física para hoy en día estar culminando de manera satisfactoria esta primera meta.

A nuestra amada Universidad por ser el lugar de crecimiento profesional y personal.

A nuestro director Carlos Díaz y a nuestro co-director y amigo Fabián Torres, por habernos dado la oportunidad de ser parte de este proyecto y trabajar junto a ellos, por su especial entrega, paciencia y dedicación, por haber estado en cualquier momento o circunstancia atentos y con la mejor disposición para ayudarnos.

A nuestras familias por el apoyo brindado en estos años, el amor y la confianza que depositaron en nosotras, por no dejar de creer en que algún día lo lograríamos, por el esfuerzo a través de los años para crear una mejor versión de nosotras.

A nuestros amigos, que siempre estuvieron ahí para brindarnos una mano y para reír o llorar juntos. En especial a Ximena y Angie con quienes empezamos este camino y con quienes compartimos gran parte de él, siempre estarán en nuestro corazón.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla de Contenido

	Pág.
Introducción	15
1. Planteamiento del Problema	18
2. Justificación del Proyecto	20
3. Objetivos	22
3.1 Objetivo General	22
3.2 Objetivos Específicos.....	22
4. Metodología	23
4.1. Fase 1: Revisión de Literatura y Definición del Problema	23
4.2. Fase 2: Diseño del Algoritmo de Solución.	24
4.3 Fase 3: Validación del Algoritmo.	25
4.4 Fase 4: Entregables	25
5. Revisión de Literatura.....	26
5.1 Antecedentes del FS.....	26
6. Marco Teórico.....	34
6.1 Flow Shop	34
6.2. Problema de Flow Shop (FSP).....	35
6.2.1 Flow Shop Permutado (PFS).....	36
6.2.2 Flow Shop sin Permutación (NPFS)	36
6.2.3 Flow Shop Flexible	36
6.2.4 Flow Shop sin Espera.....	36
6.3 Problema de Programación Lineal Entera	36

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

6.4 Complejidad Computacional	37
6.4.1 Problemas P	37
6.4.2 Problemas NP.....	38
6.4.3 Problemas NP-Completos	38
6.4.4 Problemas NP-Hard	38
6.5 Métodos de Optimización	39
6.5.1 Métodos Exactos	39
6.5.2 Métodos Heurísticos	39
6.5.3 Métodos Metaheurísticos	41
6.6. Análisis de la Varianza ANOVA.....	46
7. Formulación del Modelo Matemático para el FSCE	49
7.1 Ejemplo Ilustrativo.....	52
8. Desarrollo e Implementación.....	55
8.1. Instancias para la Validación del Modelo Matemático.....	55
8.2. Estructuras de Datos	56
8.2.1. Datos Generales	56
8.2.2. Trabajos y Máquinas.....	57
8.2. Representación de la Solución	58
8.3. Función de Aptitud	58
8.4. Adaptación del Algoritmo.....	59
8.4.1. Selección por Torneo	60
8.4.2. Operador de Cruzamiento	60
8.4.3. Operador de Mutación	61
9. Diseño de Experimentos	61

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

9.1 Análisis de Varianza Para la Instancia 20*5	62
9.2. Análisis de Varianza para la Instancia 20*10	65
9.3 Análisis de Varianza para la Instancia 20*20	68
9.4. Análisis de Varianza para la Instancia 50*5	71
9.5. Análisis de Varianza para la Instancia 50*10	74
9.6 Análisis de Varianza para la Instancia 50*20	77
9.7 Análisis de Varianza para la Instancia 100*5	80
9.8 Análisis de Varianza para la Instancia 100*10	83
9.. Análisis de Varianza para la Instancia 100*20	86
10. Resultados Computacionales	89
10.1 Resolución Instancias Pequeñas	90
10.2 Resolución Instancias Medianas	93
10.3 Resolución Instancias Grandes	94
10.4 Validación de Resultados para Instancias Medianas y Grandes.	95
11. Conclusiones	99
12. Recomendaciones	100
Referencias Bibliográficas	102

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Lista de Tablas

	Pág.
Tabla 1. Cumplimiento de Objetivos.....	17
Tabla 2. Clasificación de las instancias a evaluar.....	56
Tabla 3. Instancia del problema.....	57
Tabla 4. Tiempo de procesamiento del trabajo j en la máquina m.....	57
Tabla 5. Consumo de energía del trabajo j en la máquina m.....	57
Tabla 6. Consumo de energía de la maquina m cuando está desocupada.....	58
Tabla 7. Representación de la solución.....	58
Tabla 8. Factores y niveles del diseño experimental.....	62
Tabla 9. Análisis de varianza para la instancia 20*5.....	62
Tabla 10. Análisis de varianza para la instancia 20*10.....	65
Tabla 11. Análisis de varianza para la instancia 20*20.....	68
Tabla 12. Análisis de varianza para la instancia 50*5.....	71
Tabla 13. Análisis de varianza para la instancia 50*10.....	74
Tabla 14. Análisis de varianza para la instancia 50*20.....	77
Tabla 15. Análisis de varianza para la instancia 100*5.....	80
Tabla 16. Análisis de varianza para la instancia 100*10.....	83
Tabla 17. Análisis de varianza para la instancia 100*20.....	86
Tabla 18. Definición de parámetros para las instancias del PSFP.....	89
Tabla 19. Resultados obtenidos por el algoritmo Genético para la instancia 20*5.....	90
Tabla 20. Resultados obtenidos por el algoritmo Genético para la instancia 20*5.....	91
Tabla 21. Resultados obtenidos por el algoritmo Genético para la instancia 20*20.....	91

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla 22. Resultados obtenidos mediante el modelo PL y el algoritmo Genético para la instancia 10*5.....	92
Tabla 23. Comparación del algoritmo para el consumo de energía ECR.....	92
Tabla 24. Resultados obtenidos por el algoritmo Genético para la instancia 50*5	93
Tabla 25. Resultados obtenidos por el algoritmo Genético para la instancia 50*10	93
Tabla 26. Resultados obtenidos por el algoritmo Genético para la instancia 50*20	94
Tabla 27. Resultados obtenidos por el algoritmo Genético para la instancia 100*5	94
Tabla 28. Resultados obtenidos por el algoritmo Genético para la instancia 100*10	94
Tabla 29. Resultados obtenidos por el algoritmo Genético para la instancia 100*20	95
Tabla 30. Makespan obtenidos por otros algoritmos	97
Tabla 31. Comparación Makespan instancias grandes.	97
Tabla 32. Comparación makespan promedio de otras heurísticas con el AG	97

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Lista de Figuras

	Pág.
Figura 1. Metodología creación propia.....	23
Figura 2. Configuración secuencia maquinas Flow Shop clásico.....	35
Figura 3. Clasificación de los problemas NP.....	38
Figura 4. Adaptado de Algoritmos Genéticos. Una visión práctica.	43
Figura 5. Estructura del Algoritmo Genético.....	44
Figura 6. Hipótesis nula y alternativa	47
Figura 7. Tabla Anova.	48
Figura 8. Indices de consumo Pej y lej para cada máquina.	53
Figura 9. Secuencia Flow Shop (a).	54
Figura 10. Secuencia Flow Shop (b).	54
Figura 11. Pseudocódigo Algoritmo Genético creación propia.	59
Figura 12. Operador de Selección por Torneo creación propia.	60
Figura 13. Operador de Cruzamiento creación propia.	60
Figura 14. Operador de Mutación creación propia.	61
Figura 15. Diagrama de Pareto de efectos estandarizados de la instancia 20*5.....	63
Figura 16. Diagrama de efectos principales para la instancia 20*5.....	63
Figura 17. Gráfica de interacciones para la instancia 20*5	64
Figura 18. Diagrama de Pareto de efectos estandarizados de la instancia 20*10.....	66
Figura 19. Diagrama de efectos principales para la instancia 20*10.....	66
Figura 20. Gráfica de interacciones para la instancia 20*10	67
Figura 21. Diagrama de Pareto de efectos estandarizados de la instancia 20*20.....	69

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 22. Diagrama de efectos principales para la instancia 20*20.....	69
Figura 23. Gráfica de interacciones para la instancia 20*20	70
Figura 24. Diagrama de Pareto de efectos estandarizados de la instancia 50*5.....	72
Figura 25. Diagrama de efectos principales para la instancia 50*5.....	72
Figura 26. Gráfica de interacciones para la instancia 50*5	73
Figura 27. Diagrama de Pareto de efectos estandarizados de la instancia 50*10.....	75
Figura 28. Diagrama de efectos principales para la instancia 50*10.....	75
Figura 29. Gráfica de interacciones para la instancia 50*10	76
Figura 30. Diagrama de Pareto de efectos estandarizados de la instancia 50*20.....	78
Figura 31. Diagrama de efectos principales para la instancia 50*20.....	78
Figura 32. Gráfica de interacciones para la instancia 50*20	79
Figura 33. Diagrama de Pareto de efectos estandarizados de la instancia 100*5.....	81
Figura 34. Diagrama de efectos principales para la instancia 100*5.....	81
Figura 35. Gráfica de interacciones para la instancia 100*5	82
Figura 36. Diagrama de Pareto de efectos estandarizados de la instancia 100*10.....	84
Figura 37. Diagrama de efectos principales para la instancia 100*10.....	84
Figura 38. Gráfica de interacciones para la instancia 100*10	85
Figura 39. Diagrama de Pareto de efectos estandarizados de la instancia 100*20.....	87
Figura 40. Diagrama de Pareto de efectos estandarizados de la instancia 100*20.....	87
Figura 41. Gráfica de interacciones para la instancia 100*20	88
Figura 42. Ecuación ECR	92
Figura 43. Valores de Makespan producidos por diferentes algoritmos	96

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Lista de Apéndices

Ver Apéndices adjuntos y pueden ser consultados en la base de datos de la biblioteca UIS.

Apéndice A. Análisis bibliométrico

Apéndice B. Código modelo exacto implementado en el software GAMS

Apéndice C. Código Algoritmo Genético GA implementado en el software MATLAB.

Apéndice D. Artículo de carácter publicable.

Apéndice E. Instancias numéricas.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

RESUMEN

Título del Proyecto: UN ALGORITMO GENÉTICO PARA LA SOLUCIÓN DEL PROBLEMA FLOW SHOP MINIMIZANDO EL CONSUMO ENERGÉTICO. *

Autores: Wendy Sanabria Palencia**

Angie Monsalve Serrano**

Palabras Claves: consumo energético, optimización, algoritmo genético, Flow shop, Makespan.

Descripción: La investigación que se presenta en este trabajo trata de implementar un algoritmo genético con el fin de dar solución al problema Flow shop para minimizar el consumo de energía. Para abordar este problema se desarrolla un modelo matemático, el cual representa la situación y en su solución se logra programar cada trabajo en determinado orden a cada máquina, para así minimizar el consumo de energía a través de la reducción de tiempos ociosos, que a su vez reducen el Makespan, ya que a menor Makespan menor consumo de energía. El Flow Shop es un problema de programación donde se planifican unas tareas, guiadas por una serie de trabajos organizados de tal manera que se reduzca el Makespan. Estos trabajos pasan a través de unas máquinas, en las cuales solo se realiza una tarea y trabajo a la vez, los trabajos pasan una única vez por cada máquina y finalmente el orden de las máquinas siempre se mantiene. Identificado esto se procede al objetivo principal, que es secuenciar los trabajos de forma que siguiendo las restricciones indicadas en el modelo logren una minimización del tiempo utilizado para completar todos los trabajos y a su vez la reducción del consumo de energía. Para la solución, se plantea la utilización del algoritmo genético, para el cual se utiliza la selección por torneo para mejorar la especie y llegar a la mejor solución. La complejidad de este trabajo se ve reflejada por la naturaleza combinatoria del problema lo que hace que se clasifique como un problema NP-Hard (polinómico no determinista). Para validar la presente investigación, se adaptaron instancias halladas en la literatura para comprobar la efectividad del algoritmo genético, usando un método exacto y comparándolo con la solución del algoritmo genético (MATLAB).

*Trabajo de grado

**Facultad de Ingenierías Físico-mecánicas. Escuela de Estudios Industriales y Empresariales. Director: MSc. Carlos Eduardo Díaz Bohórquez, Codirector: MSc. Fabián Alexander Torres Cárdenas

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

ABSTRACT

Title: A GENETIC ALGORITHM AS THE SOLUTION OF THE FLOW SHOP PROBLEM MINIMIZING ENERGY CONSUMPTION. *

Authors: Wendy Sanabria Palencia **

Angie Monsalve Serrano **

Keywords: energy consumption, optimization, genetic algorithm, flow shop, Makespan

Description: The research presented in this work aims to implement a genetic algorithm in order to solve the flow shop problem to minimize energy consumption. In order to approach this problem, a mathematical model is developed, which represents the situation and in its solution it is possible to program each work in a certain order to each machine, in order to minimize the energy consumption through the reduction of idle time, which in turn reduces the Makespan, since the lower the Makespan, the lower the energy consumption. The Flow Shop is a scheduling problem where some tasks are planned and guided by a series of jobs organized in such a way that the Makespan is reduced. These jobs pass through some machines, in which only one task and job is done at a time, the jobs pass only once through each machine and finally the order of the machines is always maintained. Once this is identified, the main objective is stated, which is to sequence the jobs in such a way that follows the restrictions indicated in the model and to achieve a minimization of the time used to complete all the jobs and at the same time the reduction of the energy consumption. For the solution, a genetic algorithm is proposed, in which the selection by tournament is used to improve the species and reach the best solution. The complexity of this work is reflected by the combinatorial nature of the problem, which makes it classified as an NP-Hard problem (non-deterministic polynomial). To validate the present research, instances found in the literature were adapted to check the effectiveness of the genetic algorithm, using an exact method and comparing it with the solution of the genetic algorithm (MATLAB).

*Bachelor Thesis

**Faculty of Physicomechanical Engineering, Industrial and Business School. Director: MSc. Carlos Eduardo Díaz Bohórquez, Codirector: MSc. Fabián Alexander Torres Cárdenas

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Introducción

En la actualidad el tema medio ambiental es una preocupación inminente en las organizaciones y la industria ha estado buscando los medios para disminuir el consumo energético que genera su producción, a su vez reduciendo o manteniendo una programación eficiente de sus operaciones. Según Fang et al., (2011) el sector industrial representa aproximadamente la mitad del consumo total de energía a nivel mundial, este consumo ha aumentado el doble en los últimos años y se espera que para el año 2030 aumente un 40% más que el año 2006.

La investigación para minimizar el consumo de energía de los sistemas de fabricación se ha centrado en tres perspectivas: la máquina, el producto y el sistema de fabricación (Dai et al., 2013). Debido a que en el sistema de fabricación se puede reducir el consumo de energía, optimizando la programación de su producción, que se puede definir como la especificación de la secuencia de operaciones de los trabajos en cada máquina (Ebrahimi et al., 2020), esta investigación se centrará en esta perspectiva.

Existen diferentes tipos de fabricación entre los cuales se encuentra el Flow Shop, el cual es definido como un conjunto determinado de trabajos a programar, que consiste en la definición de una secuencia de tareas u operaciones que deben ser procesados en un tiempo determinado por un conjunto de máquinas específicas en un mismo orden, (Fang et al., 2011). Teniendo en cuenta la anterior definición, se agregará una extensión a este tipo de problema Flow Shop, que tiene en cuanto como variable, el consumo energético de la maquinaria usada en los procesos, asociándolo también con el tiempo de inactividad y los tiempos de procesamiento de las maquinas (Makespan) ya que a mayor Makespan mayor consumo de energía. Desde 2008, diferentes autores han

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

propuesto modelos de solución a través de diferentes metaheurísticos para darle solución a esta problemática desde un punto de vista de programación de operaciones.

El objetivo principal de este proyecto es solucionar el problema del Flow Shop minimizando el consumo energético (FSCE). Siendo el Flow Shop un problema del tipo Np-Hard por su naturaleza combinatoria, es complejo determinar la mejor solución en el menor tiempo posible. En la literatura se evidenció el uso de métodos metaheurísticos, heurísticos y exactos para solucionar este tipo de problemas, sin embargo, a través del análisis literario se evidenció también que para el problema Flow Shop que busca minimizar el consumo energético el aporte de los autores en cuanto a investigaciones utilizando este tipo de métodos ha sido escaso.

Dicho lo anterior, este trabajo investigativo pretende generar un aporte al problema de Flow Shop minimizando el consumo energético, a través de un algoritmo genético como alternativa de solución y obtener como resultado una herramienta que soporte la toma de decisiones en las organizaciones. El documento se encuentra organizado de la siguiente manera: En el capítulo dos se puede observar la revisión de literatura, la cual se divide en análisis bibliométrico y análisis preliminar de literatura, en el tres, cuatro y cinco se encuentra el planteamiento del problema, los objetivos de la investigación y los resultados esperados.

En general el trabajo de investigación está organizado de la siguiente manera: En los capítulos 1, 2, 3 y 4 se data información general acerca del proyecto a desarrollar. El capítulo 5, muestra un resumen de la revisión de literatura. En el capítulo 6 se presenta el marco teórico. El capítulo 7 contiene la descripción del FSCE y un ejemplo ilustrativo. En los capítulos 8 y 9 se data el desarrollo e implementación del algoritmo, las instancias para la validación y el desarrollo del modelo matemático, en el capítulo 10 se muestran los resultados computacionales y la

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

comparación del AG para su validación. Finalmente, en el capítulo 11 y 12 se dan unas recomendaciones y conclusiones para investigaciones futuras.

Finalmente, el cumplimiento de los objetivos planteados para la presente investigación se presenta la Tabla 1.

Tabla 1

Cumplimiento de Objetivos.

Objetivos Específicos	Cumplimiento
Realizar una revisión de literatura sobre el problema Flow Shop con consumo energético, así como los diferentes enfoques propuestos por distintos autores.	Capítulo 5
Definir un modelo matemático que represente al problema Flow Shop minimizando el consumo de energía.	Capítulo 7
Diseñar un algoritmo genético en lenguaje de programación Matlab, como solución al problema Flow Shop con consumo energético.	Capítulo 8, 9.
Validar el algoritmo propuesto mediante instancias adaptadas de la literatura y generadas aleatoriamente.	Capítulo 10
Elaborar un artículo de carácter publicable que contenga los resultados del proyecto de investigación.	Apéndice D

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

1. Planteamiento del Problema

Las industrias manufactureras en su compromiso con un desarrollo sostenible han dirigido sus esfuerzos al cumplimiento del objetivo número doce de las naciones unidas de consumo y producción sostenible, los cuales se centran en una solución con un enfoque sistemático. Las primeras investigaciones para reducir el consumo de energía desde la programación de operaciones en sistemas productivos tipo Flow Shop, se dieron en el 2008. Liu X, Zou F y Zhang X proponen un modelo de integración mixta no lineal de optimización basado en el consumo energético para un problema Flow Shop flexible, dando así paso a múltiples investigaciones para obtener una eficiencia energética en entornos Flow Shop.

El Flow Shop o línea de flujo se define como un problema donde hay n máquinas y m trabajos. Cada trabajo contiene exactamente n operaciones y la i -ésima operación del trabajo debe ejecutarse en la i -ésima máquina teniendo en cuenta que ninguna máquina puede realizar más de una operación simultáneamente y para cada operación de cada trabajo, se especifica el tiempo de ejecución. Las operaciones dentro de un trabajo deben realizarse en el orden especificado esto quiere decir la primera operación se ejecuta en la primera máquina, luego cuando finaliza la primera operación, la segunda operación en la segunda máquina, y así hasta la n -ésima operación. Sin embargo, los trabajos se pueden ejecutar en cualquier orden. La definición del problema implica que esta orden de trabajo es exactamente la misma para cada máquina. El problema es determinar la disposición óptima de este tipo, es decir, la que tiene el menor Makespan total de ejecución de trabajo. (Li et al., 2018). En este orden de ideas, el problema Flow Shop con consumo energético es definir la secuencia de las tareas a procesar en un tiempo determinado, por los

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

recursos (Maquinas), cumpliendo con la restricción que las operaciones siempre tienen el mismo orden, teniendo en cuenta que la velocidad del procesamiento de las maquinas se relaciona con el Makespan.

Establecer la secuencia de los trabajos se vuelve una tarea compleja pues se busca un uso eficiente de las máquinas y un bajo consumo de energía. Adicionalmente, una mala programación de operaciones genera intervalos de tiempo donde estas máquinas consumen energía sin estar operando, haciendo un uso ineficiente de esta. Esta propuesta de investigación busca minimizar el tiempo de finalización de todas las tareas Makespan, y el consumo de energía en el problema Flow Shop, mediante un Algoritmo Genético, dado que este tipo de problemas es considerado de tipo Np-hard (Pinedo, 2016), debido a su naturaleza combinatoria, buscando obtener buenas soluciones en tiempo computacionales razonables, teniendo en cuenta que la programación de operaciones es de tipo operativo y el proceso de toma de decisión en la organizaciones debe ser ágil, por lo cual este método de solución permite obtener una solución factible en un tiempo menor y obtener como resultado el cronograma de actividades, es decir, la secuenciación de las tareas en las máquinas en balance con el Makespan.

En Colombia el 25% de la energía que se consume en el territorio nacional es por parte de sector industrial (Ministerio de minas y energías, 2017) por ello surge la necesidad y motivación de este proyecto para ofrecer una herramienta de solución como alternativa o soporte a la toma de decisiones en entornos de producción actual que generan un impacto positivo a indicadores ambientales a su vez que aumentan la productividad.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

2. Justificación del Proyecto

La programación de operaciones juega un rol crítico en el sistema productivo de las compañías manufactureras pues define a corto plazo el cronograma de actividades de los planes maestros de producción, una mala programación de operaciones puede resultar en pérdidas de eficiencia y tiempo lo cual significa grandes costos y pérdidas de recurso. Es por ello, que estos planes se enfocan en el mejor uso de recursos y capacidad teniendo en cuenta las restricciones técnicas de la producción. (Krajewski, Ritzman, & Malhotra, 2009).

Tradicionalmente la programación de operaciones se ha enfocado en incrementar positivamente indicadores de costo, eficiencia y calidad, pero en los últimos años las industrias manufactureras han evaluado el impacto que tiene sus operaciones frente a indicadores de desempeño ambientales como consumo de agua, generación de CO₂ y/o eficiencias energéticas, entre otros. Por tanto, se enmarca esta problemática en el campo de la programación de operaciones donde a partir de una buena secuenciación de los trabajos a realizar se puede disminuir el tiempo de los recursos (máquinas) utilizados y así disminuir estos indicadores positivamente.

Existen diferentes tipos de configuración en un sistema productivo un ejemplo de este tipo de sistemas es la línea de flujo de trabajo (Flow Shop, FS), en el cual se tiene un conjunto de trabajos conocidos y donde las máquinas se organizan de una forma secuencial, para así establecer la secuencia de estos trabajos en busca de un consumo mínimo de energía sin afectar los tiempos de fabricación. Esto para las organizaciones, se vuelve una tarea compleja.

La literatura se enfoca en tres perspectivas para la minimización el consumo de energía máquina, producto y el sistema de fabricación (Dai et al., 2013). A partir de este último se puede

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

reducir el consumo de energía, optimizando la programación de su producción, que se puede definir como la especificación de la secuencia de operaciones de los trabajos en cada máquina. Esta investigación se centra en esta perspectiva al ser la más frecuente dentro de las empresas, pues se trabaja con recursos propios y representan poca inversión a comparación de la adquisición de máquinas con menor consumo energético, pero de precios muy altos.

Cabe resaltar que el sector industrial consume a la mitad del total de energía a nivel mundial, este consumo ha aumentado el doble en los últimos años y se espera que para el año 2030 aumente un 40% más que el año 2006. según Fang et al., (2011). De esta manera el problema Flow Shop minimizando el consumo de energía se ha convertido en un problema relevante en el área de programación de operaciones debido a la dificultad de encontrar soluciones optimas en tiempos computaciones razonables por su naturaleza combinatoria siendo así un problema Np Hard. En la presente investigación se propone la aplicación de una metaheurística para resolverlo. Se plantea un Algoritmo Genético (GA), el cual es un método adaptativo, generalmente usado en optimización de parámetros que se basa en la reproducción sexual y en el principio de supervivencia del más apto (Fogel, 2005).

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

3. Objetivos

3.1 Objetivo General

Diseñar un algoritmo Genético como alternativa de solución al problema Flow Shop minimizando el consumo energético.

3.2 Objetivos Específicos

Realizar una revisión de literatura sobre el problema Flow Shop con consumo energético, así como los diferentes enfoques propuestos por distintos autores.

Definir un modelo matemático que represente al problema Flow Shop minimizando el consumo de energía.

Diseñar un algoritmo genético en lenguaje de programación Matlab, como solución al problema Flow Shop con consumo energético.

Validar el algoritmo propuesto mediante instancias adaptadas de la literatura y generadas aleatoriamente.


Elaborar un artículo de carácter publicable que contenga los resultados del proyecto de investigación.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

4. Metodología

Figura 1

Metodología creación propia



4.1. Fase 1: Revisión de Literatura y Definición del Problema

- Definición de palabras claves para la elaboración de la ecuación de búsqueda.
- Consultar en las bases de Datos Scopus, SciencesDirect, Web of Science, los diferentes documentos relacionados con el Flow Shop y su extensión en la cual se contemplan el consumo energético, haciendo uso de la ecuación de búsqueda previamente definida.
- Revisar los métodos y algoritmos empleados para dar solución al problema Flow Shop con consumo energético de manera que se pueda extraer y clasificar la información más relevante.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

- Comprender las bases de la teoría relevante del problema Flow shop teniendo en cuenta la minimización del consumo energético

- Plantear el problema a resolver, acorde a la teoría estudiada.

4.2. Fase 2: Diseño del Algoritmo de Solución.

- Determinar los criterios, restricciones, parámetros y variables a las que haya lugar con el propósito de representar el problema planteado en la fase anterior, así como determinar la función objetivo

- Definir la forma en que los tiempos de operación serán considerados en el modelo matemático, el impacto en el problema a tratar y las restricciones que surgirán para este.

- Definir la forma en que el consumo de energía será considerado en el modelo, las restricciones teóricas del problema, la relación entre tiempos de operación, máquinas y consumo de energía.

- Formular un modelo matemático que represente el problema de Flow shop con consumo energético

- Comprender las bases de la teoría relevante al uso de los algoritmos genéticos como heurística de solución para el problema Flow shop, así como los conceptos necesarios para realizar la programación en MATLAB.

- Determinar los criterios para la selección de la población inicial, los cruces y mutaciones del algoritmo.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

- Construir el Algoritmo Genético en el lenguaje de programación MATLAB para solucionar el FSCE.

4.3 Fase 3: Validación del Algoritmo.

- Determinar las instancias para la evaluación del método de solución, las instancias serán adaptadas de la literatura tomadas de la tesis E. Taillard, "Benchmarks for basic scheduling problems" y parámetros como el consumo de energía serán generados aleatoriamente.

- Validación del método de solución ejecutando el algoritmo para establecer que los resultados arrojados sean congruentes.

- Comparar los resultados obtenidos con la solución de métodos exactos del mismo problema.

- Analizar los resultados obtenidos luego de la respectiva comparación.

- Realizar las correcciones al algoritmo genético o al modelo matemático a las que haya lugar.

- Implementar el algoritmo genético para el problema Flow shop con consumo energético en donde se pueda encontrar el cronograma de tareas con el menor consumo de energía.

4.4 Fase 4: Entregables

- Libro del proyecto de grado.

- Elaboración de un artículo de carácter publicable con los resultados obtenidos durante la investigación.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

5. Revisión de Literatura

5.1 Antecedentes del FS

En la literatura se pueden encontrar diversos estudios acerca del Flow Shop, encaminados a la reducción del tiempo de procesamiento (Makespan) ya que desempeña un gran papel en la mejora de la productividad industrial, esto a raíz de que se enfoca en el estricto orden de procesamiento de todas las máquinas teniendo en cuenta a su vez todas las operaciones necesarias para completar todos los trabajos.

Por otra parte el problema de Flow Shop ha sido estudiado a través del tiempo por distintos investigadores, quienes buscan progresivamente mejorar el flujo de trabajo en las grandes industrias y a esto se le une la necesidad de ayudar al medio ambiente, pero en la mayoría de estudios se ha encontrado que al aumentar la velocidad de operación de las máquinas, se reducen los tiempos de los procesos, pero el consumo de energía se aumenta considerablemente, y si se disminuye la velocidad de las máquinas, el tiempo de procesos aumenta, pero es en ese punto donde el consumo de energía disminuye también. Por tal razón Fang et al. (2011) hicieron una contribución muy importante creando la estrategia del escalado de velocidad, el cual se enfoca en cambiar las velocidades de las máquinas dependiendo del trabajo procesado.

A lo largo de las investigaciones han sido implementados distintos algoritmos metaheurísticos a los problemas de Flow Shop, entre estos se encuentran el algoritmo genético (GA) (que será utilizado en el presente trabajo), el algoritmo de recocido simulado (SA), la colonia de hormigas, el enjambre de abejas, etc. El algoritmo genético (GA) es útil para lograr encontrar de manera rápida una buena solución o muy cercana a esta en el espacio abarcado.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

El problema del consumo energético ha tomado gran fuerza en los últimos años y se ha vuelto de gran importancia para la investigación, la cual enfoca sus estudios en minimizar al máximo este consumo, usando diferentes estrategias para contribuir ambientalmente, ya que la mayor parte del consumo energético se da en las industrias manufactureras, las cuales abarcan un tercio del total del consumo mundial (Gielen et al., 2007).

Mansouri & Aktas (2016) en un trabajo denominado “Minimizing energy consumption and Makespan in a two-machine flowshop scheduling problem” muestran el desarrollo de una heurística constructiva y un algoritmo genético multi-objetivo (MOGA), considerando dos máquinas para abordar el tema del consumo de energía (medición de la sostenibilidad) y el Makespan (medición del servicio). Realizaron comparaciones del rendimiento de la heurística con el algoritmo genético multi-objetivo, teniendo en cuenta lo conflictivo que es el cumplir con el objetivo de minimizar el Makespan y el consumo de energía a la vez, a través de CPLEX, donde encontraron un sinnúmero de casos problemáticos, es así como dieron nuevas técnicas de solución escalable a los planificadores para la toma de decisiones que tuvieran en cuenta el consumo energético y la programación de la empresa.

Para darle solución al problema, los investigadores presentaron una nueva heurística constructiva (CH2) con la complejidad reducida $O(n^2)$, después de ello desarrollaron MOGA regulares e híbridos (denotados por R-MOGA y H-MOGA, respectivamente) para mejorar aún más la efectividad y la eficiencia de la búsqueda de la frontera de Pareto del problema. Y al final presentaron un método de restricción ϵ ejecutado en CPLEX y búsqueda aleatoria como dos enfoques de referencia ampliamente utilizados para evaluar el rendimiento estadístico de la búsqueda, con lo cual lograron encontrar a través de fronteras de Pareto óptimas para minimizar el consumo de energía.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Öztop et al. (2020) en su investigación llamada “Ensemble of metaheuristics for energy-efficient hybrid flowshops: Makespan versus total energy consumption” buscaron la forma de solucionar el problema de minimizar el Makespan y el consumo de energía total, buscando reducir los daños ambientales que producen ciertos procesos, para ello utilizaron una codificación basada en la permutación normalmente conocida como problema híbrido de programación del Flow Shop (hybrid Flow-shop scheduling problem) HFSP.

Su forma de aportar a las investigaciones existentes acerca de eficiencia energética y la programación híbrida para el Flow Shop fueron:

1. Aplicación del escalado de velocidades como estrategia para el HFSP.
2. Presentaron nuevos modelos de MILP y CP bi-objetivo para el problema híbrido de programación con eficiencia energética (energy-efficient hybrid flowshop scheduling problem) EHFSP.
3. Creación de una nueva heurística constructiva para el HFSP.
4. Propusieron nuevos enfoques para el cálculo de la heurística para el HFSP
5. Desarrollaron siete algoritmos metaheurísticos bi-objetivos que funcionarán para el EHFSP

En un estudio realizado sobre el consumo de energía, descubrieron que se podía reducir significativamente la cantidad de energía utilizada, si se apagaban las máquinas que no poseían cuello de botella en el tiempo que estas estuvieran fuera de actividad (Mouzon et al., 2007) y basados en este estudio dieron a conocer una propuesta de encendido y apagado para minimizar el consumo energético y el tiempo de finalización para el problema de programación en una máquina. Algo similar hicieron Pach et al. (2014) desarrollando un enfoque de programación reactiva para sistemas de fabricación flexible, en el cual la fuente de alimentación debía ser apagada si no tenía

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

ningún producto en ella durante cierto tiempo y se prendía en las horas donde el trabajo fuera demandante, para así lograr disminuir el consumo de energía.

Para saber en qué momento se debían encender y apagar las máquinas, Wu & Sun (2018) realizaron un algoritmo genético ordenado no dominado (NSGA) con el cual se podía ahorrar energía y saber qué velocidad se requería para realizar los procesos teniendo en cuenta el problema de Job-shop.

Una solución para la minimización del consumo de energía y el Makespan fue dado a través de un algoritmo de optimización híbrido multi-objetivo por Li et al. (2018) en su trabajo titulado “Efficient multi-objective optimization algorithm for hybrid Flow Shop scheduling problems with setup energy consumptions”, con el cual lograron:

1. Proponer un mecanismo de codificación y decodificación bien diseñado que se pudiera adaptar a las características del problema.
2. Ocho tipos de estructuras de vecindario y un mecanismo de selección de estructura de vecindario para mejorar las capacidades de explotación exploración.
3. Para mejorar el consumo de energía diseñaron un enfoque de desplazamiento de las actividades a la derecha.
4. Finalmente para equilibrar las capacidades de búsqueda global y local, crearon un método híbrido de explotación y exploración profunda.

Para probar su efectividad compararon el algoritmo diseñado con unos ya existentes y eficientes, demostrando la solidez y eficiencia del algoritmo EA-MOA, que propusieron los investigadores.

Dai et al. (2013), en su investigación titulada “Energy-efficient scheduling flexible Flow Shop using an improved genetic-simulated annealing algorithm” se dedicaron a explorar el

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

problema de programación multi-objetivo con eficiencia energética, con dos objetivos principales, analizar el Makespan y el consumo de energía en las fábricas. Para ello propusieron un modelo matemático que involucra el Flow Shop como herramienta para mirar la eficiencia energética en las líneas de trabajo. Uno de los pasos que usaron fue realizar Pareto para encontrar soluciones óptimas usando la función de utilidad aditiva ponderada, aparte de esta herramienta, utilizaron también un algoritmo de recocido simulado, el cual mejoraron genéticamente (que fue inspirado por el mecanismo de modulación hormonal). Realizaron distintas pruebas, para diferentes escenarios, los cuales mostraron que el algoritmo podía identificar un conjunto de buenas soluciones a través del análisis Pareto y que la relación entre el consumo de energía y el Makespan era conflictiva, pero haciendo una compensación entre los dos objetivos pudieron conseguir una programación factible.

El problema de optimización para la eficiencia energética con Flow Shop fue estudiado por Zhang et al. (2019) en su investigación titulada “Optimization for energy-efficient flexible Flow Shop scheduling under time of use electricity tariffs” en el cual presentaron una codificación cromosómica mejorada de tres niveles, para denotar la secuencia de procesamiento de la máquina, la herramienta y la hora de inicio del procesamiento (los cuales se pudieron programar en simultáneo). El Pareto entre el makespan y el costo de la electricidad lo generaron a través de SPEA2 (Strength Pareto Evolutionary Algorithm). El método que propusieron tenía la capacidad de compensar el costo de la electricidad y el tiempo de entrega, y se analizaba que en el mayor pico de producción se lograba mejorar la eficiencia energética, ya que reducían el costo de la electricidad.

En un estudio realizado por Liu et al. (2020) titulado “The mixed production mode considering continuous and intermittent processing for an energy-efficient hybrid Flow Shop

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

scheduling” fue propuesto un híbrido para el problema de programación Flow Shop con eficiencia energética, para ello eligieron una regla de clasificación para poder identificar la secuencia del proceso y una producción mixta. Dicho modelo fue experimentado en un caso real, con lo que corroboraron la eficacia para la solución del problema planteado. Este estudio logró establecer un modelo de producción mixto, que considerara el procesamiento intermitente y continuo con parámetros variables, para problemas de programación entre equipos, también propusieron un modelo matemático que considera múltiples factores de tiempo (espera, preparación, procesamiento, ajuste y transporte) para darle solución al problema de programación de la producción.

Por otro lado, crearon un nuevo método para determinar la relación de la secuencia de proceso, entre los requisitos del proceso continuo y el intermitente después del calentamiento de las máquinas. Con este método y modelo, lograron reducir efectivamente el consumo energético de los equipos de forja en la línea de producción.

Para la presente investigación, se tomaron como referencia y soporte cinco tesis de investigación, los documentos cuentan con información fundamental y conceptos relevantes acerca de la definición del problema Flow permitiendo así un mejor planteamiento del problema, dichas investigaciones son:

La tesis de doctorado por la Universitat Politècnica de València “Eficiencia Energética y robustez en problemas de scheduling” aborda los diferentes problemas o situaciones de scheduling presentados en la industria, con el objetivo de obtener soluciones tanto optimizadas como robustas. El proyecto se enfoca en el problema Job Shop con operadores limitados al ser el más común dentro del contexto industrial, primero modelan el problema Job-Shop (n, p) como un problema de satisfacción y optimización de Restricciones (CSOP), por sus siglas en inglés (Constraint

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Satisfaction Optimization Problem), posterior a esto resuelvo el Job shop con eficiencia energética a través de un algoritmo genético, el cual es un referente para el algoritmo genético a desarrollar en el presente proyecto, finalmente proponen un modelo dual que relaciona la optimización del consumo de energía y la robustez, el cual desarrollan a través de un algoritmo memético, teniendo en cuenta a su vez el Makespan por su relación directa con las variables consumo de energía y robustez, temas que contribuyen al planteamiento del problema de esta investigación. La mayoría de soluciones que se obtuvieron a partir del algoritmo memético generan un ahorro de consumo de energía (Fuster, 2016).

Vallejos Cifuentes (2017) en su proyecto para obtener el título de magister de la Universidad Nacional de Colombia “Uso de Algoritmos Genéticos para el logro de la eficiencia energética en plantas de manufactura bajo un enfoque de Programación de Operaciones”. Desarrolla diferentes algoritmos entre ellos un (AMOGA) para desarrollar un modelo de programación de operaciones que se enfoca en las variables consumo energético y Makespan en ambientes manufactureros, el cual es el mismo enfoque de este proyecto, contribuyendo así al planteamiento del problema, adicionalmente el autor estructura una revisión de literatura enfocado en programación de operaciones en el cual se encuentra una amplia información que soporta el objetivo número uno revisión de literatura del presente documento.

El proyecto de pregrado de la Universidad Nacional de Colombia “Solución de problemas tipo Flow Shop mediante algoritmos evolutivos” se enfoca en métodos de solución para este tipo de problemas de secuenciación, estudia diferentes metaheurísticas y heurísticas usados como referencia. Además, la autora propone una modificación al algoritmo genético Hafa, genera la población inicial a través de la heurística NEH y concluye que entre los mejores operadores

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

genéticos están la mutación de corrimiento y el cruce por emparejamiento parcial (Rodríguez Quiñones, 2014).

López Vargas & Arango Marín (2015) de la Universidad Nacional de Colombia, Sede Manizales en su proyecto “Algoritmo genético para reducir el Makespan en un Flow Shop híbrido flexible con máquinas paralelas no relacionadas y tiempos de alistamiento dependientes de la secuencia” proponen un algoritmo genético simple (AGS) como alternativa de solución para problemas de programación de operaciones, con el cual obtienen un nivel de convergencia del Makespan cercano al 2% y soluciones con tiempos computacionales bastantes razonables con un tiempo promedio de minuto y medio.

Por otro lado, el proyecto de pregrado de la Universidad Industrial de Santander “Solución al problema de “Flow-shop” permutado, minimizando los costos de inventario en proceso y penalización debido al retraso de lotes a través de un Algoritmo Genético” (Rico Castillo & Rodríguez López, 2019), plantea un modelo de costos que asocia multas por entregas tardía a clientes y a su vez el costo de mantener esos bienes en espera y el inventario WIP según los tiempos preestablecidos en los recursos (Máquinas).

Finalmente, fue escogido un artículo guía para la elaboración de la investigación, en el cual se discute el problema flow shop permutado, para así reducir el consumo de energía a través de un algoritmo genético (Marsetiya Utama y Setiya Widodo, 2019)

En este trabajo se aborda el FSP en el problema del consumo de energía, buscando un equilibrio óptimo en el cual se minimice este consumo sin ralentizar el flujo del proceso en gran proporción.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

6. Marco Teórico

Para la realización de este trabajo investigativo fueron tomados conceptos de revistas de investigación, páginas web, libros y artículos que se relacionaban con el tema de problemas de Flow Shop y eficiencia energética, teniendo en cuenta conceptos útiles e importantes para la comprensión teórica del proyecto.

6.1 Flow Shop

El Flow Shop es un sistema de procesamiento en el que se le da una secuencia específica a las tareas de cada trabajo, lo cual es normalmente conocido como precedencia de cadena y en el cual todos los trabajos visitan las máquinas en el mismo orden.

Las máquinas pueden numerarse 1, 2, ..., m y cada trabajo pasa por ellas en orden numérico. En un Flow Shop puro, cada trabajo tiene m tareas y pasa por todas las etapas. El Flow Shop simple se caracteriza por:

Cada una de las máquinas (m) puede manejar una operación a la vez.

Un número dado, n , de trabajos independientes requiere un procesamiento, cada uno compuesto de tareas bien ordenadas con requisitos específicos.

La secuencia de la máquina es la misma para todos los trabajos.

Todos los trabajos están disponibles simultáneamente al inicio y permanecen disponibles sin interrupción hasta que todo el trabajo esté terminado.

Cada trabajo puede estar en un solo lugar a la vez.

No se permite la preferencia: una vez iniciada una tarea debe procesarse para su terminación sin interrupción.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Cuando un trabajo completa el procesamiento en una máquina, está inmediatamente disponible para comenzar en la siguiente. (Emmons & Vairaktarakis, 2013).

Figura 2

Configuración secuencia maquinas Flow Shop clásico.



6.2. Problema de Flow Shop (FSP)

El problema Flow Shop consiste en definir la secuencia de tareas u operaciones que deben ser procesadas en un tiempo determinado por un conjunto de máquinas específicas en un mismo orden, teniendo en cuenta que las máquinas pueden funcionar a diferentes velocidades (Fang et al., 2011). Una mala programación de operaciones genera intervalos de tiempo donde estas máquinas consumen energía sin estar operando, haciendo un uso ineficiente de ésta. Adicional a la energía que consumen las máquinas mientras ejecutan las operaciones programadas, la velocidad determinada de esta ejecución está relacionada directamente con el consumo de energía.

El problema de programación de Flow Shop de N trabajos / M maquinas pertenece a la optimización global de permutaciones y lo hace un problema NP-hard. Puede tratarse como el problema indicador de la teoría práctica de programación de Flow Shop, por tal razón, muchos investigadores se involucran en este tipo de problemas, y desarrollan muchos algoritmos aplicados. Los algoritmos más conocidos incluyen el algoritmo de búsqueda tabú, el recocido simulado y el algoritmo genético. En este caso específico, se hará uso de un GA (Algoritmo Genético) para dar solución al problema de Flow Shop con minimización del consumo energético (Cheng & Chang, 2007).

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

6.2.1 Flow Shop Permutado (PFS)

En esta forma de flow shop, el orden en el que los trabajos pasan por la primera máquina se mantiene en todo el sistema. Esto quiere decir que el orden de procesamiento de los trabajos j en las máquinas m es el mismo en cada línea de producción.

6.2.2 Flow Shop sin Permutación (NPFS)

Este tipo de Flow-Shop consiste en que las estaciones se encuentran ordenadas en serie de acuerdo a una secuencia de las operaciones. Un grupo de n tareas será ejecutado en m máquinas. Para cada una de las tareas se tiene un mismo orden para pasar por cada una de las máquinas. Cada trabajo solo puede ejecutarse en una estación al mismo tiempo y solo lo hará una vez en cada estación.

6.2.3 Flow Shop Flexible

Para este tipo de Flow shop se ve la existencia de máquinas en paralelo, las cuales pueden ser idénticas o no. Estas estaciones paralelas ayudan a reducir los tiempos de los ciclos, es así como una tarea podría alcanzar a la que la precede.

6.2.4 Flow Shop sin Espera

Este tipo de flow shop no permite que se creen colas de las tareas entre cada máquina, es decir que cuando el trabajo J de inicio, no se detendrá y avanzará sin esperas a través de todas las máquinas de la línea productiva.

6.3 Problema de Programación Lineal Entera

Según Rodas (2011) son problemas de programación lineal en los cuales, al menos una de las variables incluidas en el modelo, debe adquirir valores enteros. Mediante esta nueva estructura

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

se pueden representar muchas situaciones reales que hasta ese momento no pueden ser abordadas por modelos de programación lineal. Por ejemplo, situaciones donde se involucran entidades indivisibles –como aviones, barcos o personas– en las que no tendría sentido dar como respuesta una solución con valores fraccionarios. Dentro de esta programación entera se encuentran unas subcategorías, las cuales son:

*Problemas enteros puros: se trata de PPL donde todas las variables deben asumir valores enteros.

* Problemas enteros binarios: son PPL en los que todas las variables deben ser enteras y, además, solo pueden valer 0 o 1.

* Problemas enteros mixtos: se trata de PPL en los cuales un grupo de variables –no todas– deben asumir valores enteros.

6.4 Complejidad Computacional

La complejidad algorítmica establece una clasificación de los distintos tipos de problemas por su grado de dificultad de acuerdo con la complejidad computacional del algoritmo más sencillo que permite asegurar su resolución. Los distintos tipos de complejidad computacional según (Díaz, P. M., Fernández, G. H., Sánchez Allende, J., & García Manso, A., 2007) son:

6.4.1 Problemas *P*

Un problema tratable o un problema de la clase *P*, es un problema que se puede resolver siempre utilizando un algoritmo que conlleva un número de pasos que es función polinomial del tamaño de entrada del problema. En resumen, se puede decir que los problemas de la clase *P* se pueden resolver en tiempo polinomial y los intratables no se pueden resolver en tiempo polinomial.


SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

6.4.2 Problemas NP

Los problemas de la clase NP son los que se pueden resolver utilizando una máquina imaginaria llamada máquina de Turing no determinista (NDTM, Non-Deterministic Turing Machine), en un número de pasos polinomial muchos de los problemas de la clase NP son problemas muy comunes, que aparecen de forma habitual en distintos áreas de la ingeniería e incluyen, entre otros, problemas de partición de conjuntos, diseño de redes, planificación, optimización, recuperación de información, etc.

Figura 3

Clasificación de los problemas NP



6.4.3 Problemas NP-Completos

La propiedad de la clase NP-completo es que todo problema de la clase NP se puede transformar polinomialmente en él. Cuando se logra resolver un problema NP-Completo, a su vez se logra dar solución a todos los problemas NP de una forma rápida, sin embargo, los problemas NP-Completo es de los más difíciles de resolver.

6.4.4 Problemas NP-Hard

Para los problemas de optimización NP-Hard no existe ningún algoritmo en tiempo polinomial que permita determinar la solución óptima al problema. Por ello se utilizan métodos

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

aproximados mediante heurísticas que permiten aproximarse a una solución óptima, generando soluciones factibles al problema que resulten de utilidad práctica.

6.5 Métodos de Optimización

Optimizar significa poco más que mejorar; sin embargo, en el contexto científico la optimización es el proceso de tratar de encontrar la mejor solución posible para un determinado problema. En un problema de optimización existen diferentes soluciones y un criterio para discriminar entre ellas. Los métodos más conocidos reciben el nombre de algoritmos heurísticos, metaheurísticos o sencillamente exactos (Martí, 2001).

6.5.1 Métodos Exactos

Según Rodas (2011), son procedimientos que garantizan la obtención del óptimo. Si bien la pertenencia a la clase NP-Hard indica que el tiempo requerido para encontrar la solución óptima puede resultar prohibitivo, los algoritmos exactos no son dejados de lado. La posibilidad de resolver en forma exacta instancias cada vez más grandes aumenta debido al desarrollo de mejores algoritmos y a la aparición de nuevas tecnologías. Dentro de la primera familia de métodos, las técnicas Branch-and-Bound y Branch-and-Cut – basadas en la teoría poliedral– han demostrado ser una de las mejores herramientas para tratar este tipo de problemas. Una de las características más destacables de estos algoritmos es su flexibilidad, la cual les permite adaptarse a las distintas formulaciones y, de esa manera, explotar características propias de cada problema.

6.5.2 Métodos Heurísticos

Un método heurístico es un procedimiento para resolver un problema de optimización bien definido mediante una aproximación intuitiva, en la que la estructura del problema se utiliza de forma inteligente para obtener una buena solución (Díaz, 1996). Los métodos heurísticos se

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

encargan de dar una buena solución, lo que no quiere decir que sea estrictamente la solución óptima. Algunas categorías de los métodos heurísticos ampliamente descritas son dadas por Martí (2001) estas son:

Métodos de descomposición. El problema original se descompone en subproblemas más sencillos de resolver, teniendo en cuenta, aunque sea de manera general, que ambos pertenecen al mismo problema.

Métodos Inductivos. La idea de estos métodos es generalizar versiones pequeñas o más sencillas al caso completo. Propiedades o técnicas identificadas en estos casos más fáciles de analizar pueden ser aplicadas al problema completo.

Métodos de Reducción. Consiste en identificar propiedades que se cumplen mayoritariamente por las buenas soluciones e introducirlas como restricciones del problema. El objetivo es restringir el espacio de soluciones simplificando el problema. El riesgo obvio es dejar fuera las soluciones óptimas del problema original.

Métodos constructivos. Consisten en construir literalmente paso a paso una solución del problema. Usualmente son métodos deterministas y suelen estar basados en la mejor elección en cada iteración. Estos métodos han sido muy utilizados en problemas clásicos como el del agente viajero.

Métodos de Búsqueda Local. A diferencia de los métodos anteriores, los procedimientos de búsqueda o mejora local comienzan con una solución del problema y la mejoran progresivamente. El procedimiento realiza en cada paso un movimiento de una solución a otra con mejor valor. El método finaliza cuando, para una solución, no existe ninguna solución accesible que la mejore.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

6.5.3 Métodos Metaheurísticos

Los procedimientos Metaheurísticos son una clase de métodos aproximados que están diseñados para resolver problemas difíciles de optimización combinatoria, en los que los heurísticos clásicos no son efectivos. Los Metaheurísticos proporcionan un marco general para crear nuevos algoritmos híbridos combinando diferentes conceptos derivados de la inteligencia artificial, la evolución biológica y los mecanismos estadísticos (Osman & Kelly, 1996).

Las principales metaheurísticas utilizadas en problemas relacionados con el Flow Shop son:

Búsqueda Tabú (TS). Se ha demostrado a través de muchos estudios computacionales que la búsqueda tabú es una de las mejores técnicas de aproximación y puede fácilmente competir con las demás técnicas, ya que su flexibilidad hace que supere otros modelos clásicos; su forma de trabajar es con los vecinos locales, cada solución S tiene un conjunto asociado de vecinos $N(S)$. Se puede alcanzar una solución $S' \in N(S)$ desde S mediante una operación llamada movimiento. TS puede verse como una técnica iterativa que explora un conjunto de soluciones de problemas, haciendo movimientos repetidos de una solución S a otra solución S' ubicada en la vecindad $N(S)$ de S . Básicamente lo que realiza esta técnica es que, al encontrar una solución, busca al mejor vecino que sea admisible. Para evitar los ciclos, las soluciones que ya se han explorado recientemente se declaran tabú durante varias iteraciones, es decir, no pueden ser tomadas. El estado tabú de una solución se anula cuando se satisfacen ciertos criterios (criterios de aspiración). En ocasiones, se utilizan estrategias de intensificación y diversificación para mejorar la búsqueda. En el primer caso, la búsqueda se acentúa en las regiones prometedoras del dominio factible. En el segundo caso, se intenta considerar soluciones en un área amplia del espacio de búsqueda (Marinaki, 2008).

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Algoritmo Genético (GA). El uso de un GA se realiza a través de un procedimiento de búsqueda, los cuales se centran en la forma de selección y genética natural. El primer GA fue desarrollado por John H. Holland en la década de los 60's con el fin de que a través de métodos computacionales se desarrollaran soluciones a problemas de búsqueda y combinatorios (Holland, 1975). Para el caso del Flow Shop los algoritmos genéticos son de gran utilidad ya que su efectividad es bastante alta para la búsqueda global en espacios grandes, no lineales y desconocidos, además de ser efectivos para la resolución de problemas a gran escala. Los GA tienen su nombre por imitar el proceso de evolución biológica de la naturaleza, en el que se desarrollan nuevas y mejores poblaciones con cada proceso evolutivo entre las diferentes especies. Lo que diferencia el GA de la mayoría de heurísticas, es que usan información de una población de soluciones, para llegar a una mejor solución. Un GA es un procedimiento iterativo estocástico que mantiene constante el tamaño de la población en cada iteración, llamada generación. La operación básica es el acoplamiento de dos soluciones para formar una nueva solución. Para formar una nueva población, se aplica un operador binario, llamado crossover, y un operador unario, llamado mutación (Marinaki, 2008).

El algoritmo genético está compuesto por cinco procedimientos básicos (Michalewicz, 2000).


- 1) Demostrar características del problema o soluciones en formas genéticas.
- 2) Creación de cualquier cantidad de soluciones iniciales.
- 3) Establecimiento de la función de evaluación: el diseño de la función de aptitud.
- 4) Utilizando el operador genético para producir descendencia, y los operadores genéticos

más comúnmente vistos son los siguientes tres:

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 4

Adaptado de Algoritmos Genéticos. Una visión práctica.



Selección: La selección es uno de los principales operadores en algoritmos genéticos, su objetivo principal es asegurar que el conjunto de soluciones mantenga las mejores soluciones. Este operador no produce nuevas soluciones, pero si selecciona el mejor, elimina los peores y copia las mejores soluciones seleccionadas al conjunto de soluciones.

Cruce: En el sistema biológico, el cruce es un procedimiento complejo que ocurre entre un par de cromosomas. En un conjunto de cromosomas coincidentes, las divisiones y las combinaciones se produjeron en un solo punto o en varios puntos individualmente en función de ubicaciones específicas. Este mecanismo dio como resultado la diversidad cromosómica.

Mutación: La función de este operador funciona cambiando aleatoriamente genes individuales, introduciendo nuevas formas individuales y aumentando el nuevo espacio de

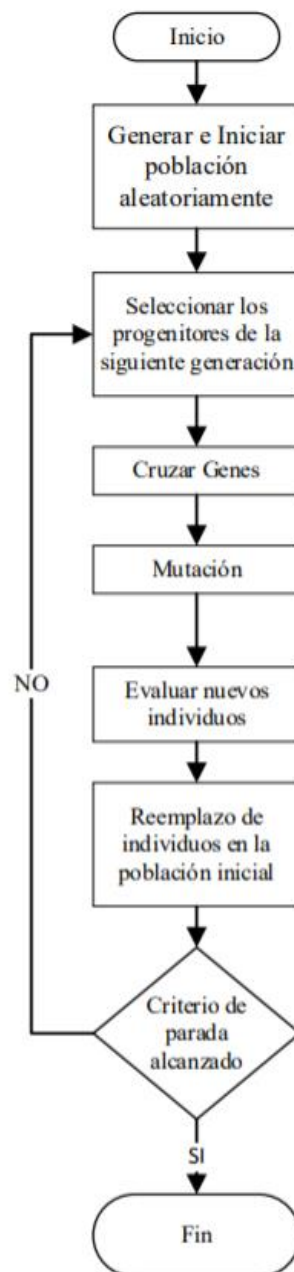
SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

búsqueda. La mutación ocurre al azar para que se puedan buscar nuevas áreas en el proceso de encontrar soluciones para evitar la optimización local.

La estructura de un Algoritmo Genético se muestra en la Figura 5.

Figura 5

Estructura del Algoritmo Genético



SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Búsqueda en Vecindario Variable (VNS). Es una metaheurística para resolver problemas de optimización combinatoria cuya idea básica es el cambio sistemático del vecindario dentro de una búsqueda local. A diferencia de otras metaheurísticas basadas en métodos de búsqueda locales, VNS no sigue una trayectoria, sino que explora sus vecinos cada vez más distantes de la solución actual, y salta de esta solución a una nueva, si y solo si se ha realizado una mejora. De esta manera, las características favorables de la solución establecida, por ejemplo, que muchas variables ya están en su valor óptimo, se mantendrán y utilizarán para obtener soluciones vecinas prometedoras. Además, una rutina de búsqueda local se aplica repetidamente para obtener de estas soluciones vecinas los óptimos locales. Esta rutina también puede usar varios vecindarios. Por lo tanto, para construir diferentes estructuras de vecindario y realizar una búsqueda sistemática, se necesita tener una manera de encontrar la distancia entre dos soluciones, es decir, es necesario suministrar el espacio de solución con alguna métrica (o cuasi métrica) y luego inducir vecindarios de ahí (P Hansen, N Mladenović., 2001).

Recocido Simulado (SA). El recocido simulado es una técnica de optimización que explota una analogía entre los problemas de optimización combinatoria y la mecánica estadística de los sistemas físicos. La analogía da lugar a un algoritmo para encontrar soluciones casi óptimas a cualquier problema dado mediante la simulación del enfriamiento del sistema físico correspondiente. Así como la naturaleza, en la mayoría de las condiciones, puede enfriar un sistema macroscópico hasta, o muy cerca de, su estado de suelo en un corto período de tiempo (aunque sus grados de libertad sean del orden del número de Avogadro), el recocido simulado encuentra rápidamente una buena aproximación a la solución del problema planteado (Kirkpatrick y otros, 1983)

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Colonia de Hormigas (ACO). Esta metaheurística es una técnica relativamente nueva para resolver problemas de optimización combinatoria. Basado fuertemente en el sistema metaheurístico de hormigas desarrollado por Dorigo, Maniezzo y Colorni, la optimización de colonias de hormigas se deriva del comportamiento de búsqueda que realizan las hormigas reales en la naturaleza. La idea principal de ACO es modelar el problema como la búsqueda de una ruta de costo mínimo en un gráfico. Las hormigas artificiales recorren este gráfico en busca de buenos caminos. Cada hormiga tiene un comportamiento bastante simple, por lo que normalmente solo encontrará caminos de baja calidad por sí solo. Se encuentran mejores caminos como resultado emergente de la cooperación global entre las hormigas en la colonia. Un algoritmo ACO consta de varios ciclos (iteraciones) de construcción de soluciones. Durante cada iteración, varias hormigas (que es un parámetro) construyen soluciones completas utilizando información heurística y las experiencias recopiladas de grupos anteriores de hormigas (Marinaki M., 2008)

6.6. Análisis de la Varianza ANOVA

Según Xian Liu, (2016), el ANOVA es una metodología para evaluar estadísticamente las diferencias entre las medias de dos o más muestras de población. ANOVA de un factor hace referencia a una sola covariable, como el tratamiento médico, el género y el estado civil. Suponiendo que un solo factor consta de K niveles y que la media poblacional de una medida de respuesta dada para cada nivel se denota por $\mu_1, \mu_2, \dots, \mu_K$, respectivamente. Las hipótesis nula y alternativa para realizar un análisis ANOVA vienen dadas por:

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 6

Hipótesis nula y alternativa

$H_0 : \mu_1 = \mu_2, = \dots = \mu_K$ $H_1 : \text{not all } \mu\text{'s are equal.}$
--

Estas hipótesis son utilizadas para probar si existe una diferencia en la medición en todos los niveles de K del factor. Dado un valor predeterminado de α , se diseñan varios métodos ANOVA para probar las hipótesis dentro de un procedimiento estadístico integrado.

El ANOVA clásico tiene varios supuestos restrictivos, entre ellos:

Requiere que las muestras de la población se obtengan de forma independiente.

Las observaciones de la población en cada nivel deben seguir una distribución normal.

Las observaciones distribuidas normalmente en varios niveles deben tener una varianza común σ^2 .

Dadas estas restricciones, en ciertas ocasiones es necesaria la transformación de datos para satisfacer la normalidad y varianza constante. El ANOVA también requiere que la medición del resultado sea una variable de intervalo y que el factor sea una variable de clasificación.

Para poder realizar un ANOVA, se debe seguir según Ruiz (2009), la siguiente metodología:

- Fijar el nivel de significación para el contraste, por ejemplo, $\alpha=95\%$.
- Establecer el contraste de hipótesis:
 - $\Rightarrow H_0$: Los tratamientos son todos iguales: $\mu_1=\mu_2=\mu_3\cdots=\mu_K$.
 - $\Rightarrow H_1$: Alguno de los tratamientos es diferente.
- Calcular los estimadores SR^2 y ST^2 .

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

- Calcular el valor del estadístico $\frac{S^2T}{S^2R}$

- Calcular el valor de $F_{k-1, n-k}$ para el nivel de significación prefijado. Si:

$\Rightarrow \frac{S^2T}{S^2R} > F_{k-1, n-k}$ la diferencia entre los tratamientos es estadísticamente significativa con

un nivel de significación α .

Por facilidad visual, se tiende a presentar el análisis de la varianza en forma de tabla como se muestra a continuación:

Figura 7

Tabla Anova.

TABLA ANOVA				
Fuentes de Variación	Sumas de Cuadrados	Grados de libertad	Cuadrados Medios	F_{exp}
Entre grupos	$SCTr$	$I - 1$	CMT_r	$\frac{CMT_r}{CMR}$
Dentro de grupos	SCR	$n - I$	CMR	
TOTAL	SCT	$n - 1$	CMT	

Nota. Adaptado de: Diseño estadístico de experimentos, análisis de la varianza y temas relacionados.

Donde:

$$SCT = SCTr + SCR$$

SCT: Suma de cuadrados total

SCTr: Suma de cuadrados entre tratamientos

SCR: Suma de cuadrados dentro de los tratamientos o residual.

CMT : Cuadrado medio total: $CMT = SCT/(N - 1)$

CMT_r : Cuadrado medio entre tratamientos: $CMT_r = SCT_r/(I - 1)$

CMR : Cuadrado medio residual: $CMR = SCR/(N - I)$

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

7. Formulación del Modelo Matemático para el FSCE

Para la solución del problema planteado se tomó como referente el modelo matemático planteado por Utama y Widodo (2019). Estos autores consideran un Flow shop permutado con un conjunto de n trabajos y m maquinas las cuales se organizan de una forma secuencial, es decir, cada trabajo pasa por una maquina lo que determina una secuencia específica, la cual será la misma para cada trabajo siguiente.

A continuación, se presenta la formulación del modelo matemático utilizado para la solución al FSCE. El problema tiene como objetivo programar cada trabajo y las operaciones de cada trabajo en cada una de las máquinas las cuales se secuencian de la misma manera con el fin de minimizar el consumo de energía total (TEC). Cabe resaltar, en este modelo no se tienen en cuenta tiempos de alistamientos.

Para ello se indexó un consumo de energía generado aleatoriamente a cada operación de cada trabajo de acuerdo al tiempo de procesamiento donde existe una relación directamente proporcional entre consumo de energía y la duración de las operaciones de cada trabajo que va relacionado al Makespan; por tanto, a mayor tiempo de procesamiento más consumo de energía y viceversa. Adicionalmente las máquinas tienen indexado un consumo de energía sin estar operando o en tiempo ocioso también llamado como “Idle Time”, al reducir este tiempo y consumo de energía cuando las máquinas están ociosas se logra reducir tanto el consumo de energía total TEC como el Makespan, este *idle time* viene dado según el cronograma de tareas del Flow Shop.

Algunos supuestos tomados para el FSCE son los siguientes:

1. El grupo de trabajos está preparado en máquinas en la misma secuencia.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

2. Cada máquina puede procesar una tarea en cada período.
3. Preferencia laboral está prohibida.
4. Cada trabajo está listo en el período $t = 0$.
5. Un trabajo comenzará en la máquina j solo si tiene completado el proceso en la máquina $j-1$;
6. No hay relación de precedencia entre trabajos.
7. Cada máquina comienza en el período $t = 0$.
8. Cada máquina se detiene cuando el último trabajo ha sido completado (cada máquina se detiene independientemente de otras máquinas).
9. *Set up* time está cubierto en el tiempo de procesamiento.

Índices

i : índice de trabajos, $i = 1, 2, \dots, n$

j : índice de máquinas, $j = 1, 2, \dots, m$

n : número total de trabajos

m : número total de máquinas

Parámetros

$P_{i,j}$: tiempo de procesamiento de la secuencia de trabajo i en la máquina j

$P_{e,j}$: índice de consumo de energía de la máquina j

$l_{e,j}$: índice de consumo de energía de la máquina j cuando está en reposo

Variables

$C_{i,j}$: tiempo de finalización de la secuencia de trabajo i en la máquina j

T_j : Tiempo de terminación en máquinas j

B_j : Tiempo total ocupado en máquinas j

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

I_j : Tiempo total ocioso en máquinas j

TEC: Consumo de Energía total.

$$\text{Función Objetivo: } Z = \min TEC \quad (1)$$

$$C_{1,1} = P_{1,1} \quad (2)$$

$$C_{1,j} = C_{1,j-1} + P_{1,j}, \quad j = 2..m \quad (3)$$

$$C_{i,1} = C_{i-1,1} + P_{i-1,1}, \quad i = 2..n \quad (4)$$

$$C_{i,j} = \max(C_{i-1,j}, C_{i,j-1}) + P_{i,j}, \quad i = 2..n, j = 2..m \quad (5)$$

$$B_j = \sum_{i=1}^n P_{i,j}, \quad \forall j = 1..m \quad (6)$$

$$T_j = \max(C_{i,j}), \quad \forall i = 1..n, j = 1..m \quad (7)$$

$$I_j = T_j - B_j, \quad \forall j = 1..m \quad (8)$$

$$TEC = \sum_{j=1}^m (B_j \cdot P_{e,j} + I_j \cdot I_{e,j}) \quad (9)$$

Por lo tanto, el objetivo final del FSCE es determinar la secuencia de trabajos que tiene un menor consumo de energía. La función objetivo del modelo es calcular el consumo total de energía (TEC) para esto toma en cuenta diferentes tipos de tiempos durante el proceso como el *busy time* que es el consumo de las maquinas cuando están operando y el *idle time* que sería el tiempo ocioso, a estos tiempos se les indexa un consumo de energía para así calcular el total de este. Las

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

restricciones del modelo FSCE para minimizar el consumo de energía. Estas restricciones en el modelo son las ecuaciones 1 a 8.

La ecuación 2 describe el tiempo de finalización del trabajo de secuencia uno en la máquina uno ya que al iniciar el cronograma de tareas esta será la primera tarea a ejecutar; por lo tanto, en ese instante sería el tiempo de procesamiento para todo i y j .

La restricción 3 describe el tiempo de procesamiento que toman el trabajo 1 en todas las máquinas j iniciando con $j=2$ ya que en la ecuación anterior se evaluó para la posición 1,1. resaltar que el tiempo de procesamiento es una matriz que va acumulando los vectores. La ecuación 4 describe el tiempo de finalización de todos los trabajos de secuencia i en la máquina de posición 1.

Por otra parte, la ecuación 5 describe el tiempo que procesamiento que toma completar todos los trabajos i en total de las máquinas j . Las ecuaciones 6 y 7 permiten calcular el tiempo de finalización activo de todas las máquinas j y el tiempo de finalización de todas las tareas (Makespan) respectivamente. El valor del tiempo idle ecuación 8 se calcula con la resta del Makespan menos el tiempo activo de las maquinas.

Por último, la ecuación 9 describe el TEC de la permutación. Estos valores se hallan sumando los valores del tiempo activo y ocioso multiplicados por sus respectivos consumos de energía.

7.1 Ejemplo Ilustrativo

Con el fin de complementar la información presentada en el modelo, se muestra el siguiente ejemplo adaptado del presentado por Utama y Widodo (2019), en el que hay tres trabajos y tres máquinas (ver Figura 8). En la Figura 9 y la Figura 10 se muestra el tiempo de finalización de cada trabajo, si las secuencias $J1, J3, J2$ (a) son 6, 9 y 11. Basados en la ecuación 1 ($C_{1,1} = P_{1,1}$), el

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

cálculo del consumo de energía es de 42 W. Sin embargo, cuando la secuencia es J2, J3, J1 (b), los tiempos de realización de cada trabajo son 6, 9 y 11, con un consumo de energía de 43 W.

Las dos opciones (a y b) pueden ser seleccionada como la mejor solución si el objetivo de la programación es reducir al mínimo tiempo de finalización. Aunque tienen el mismo tiempo de finalización, si el objetivo es minimizar el TEC, la secuencia (a) muestra el mejor resultado. El tiempo total de inactividad (idle time) de la secuencia (a) es de 10, mientras que el idle time de la secuencia (b) es 11. El tiempo total de inactividad y el FEC de la secuencia (a) son menores que los de la (b). Se evidencia que el idle time de cada máquina influye en la variación del TEC en los problemas del Flow Shop. Por tal razón, el TEC en la secuencia (a) es menor que en la secuencia (b).

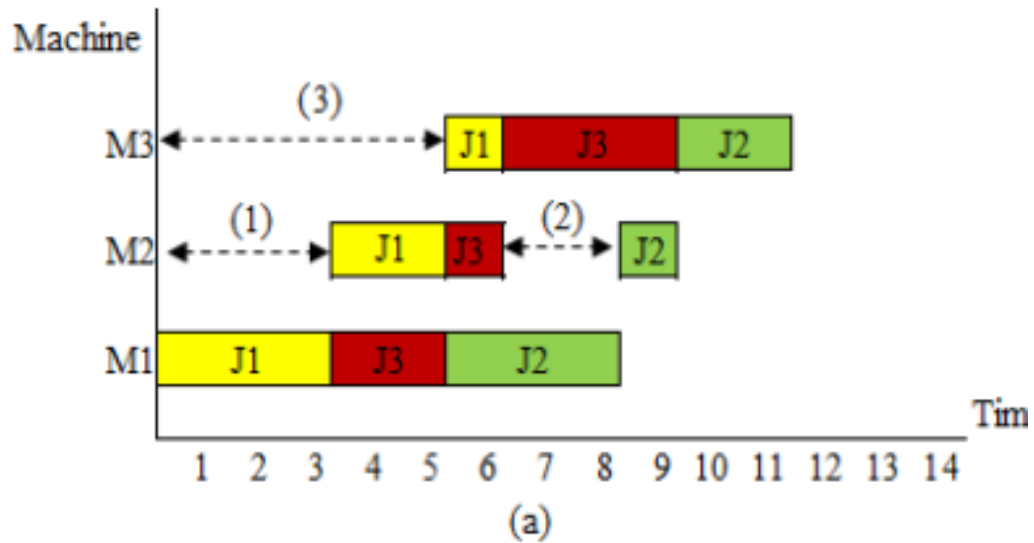
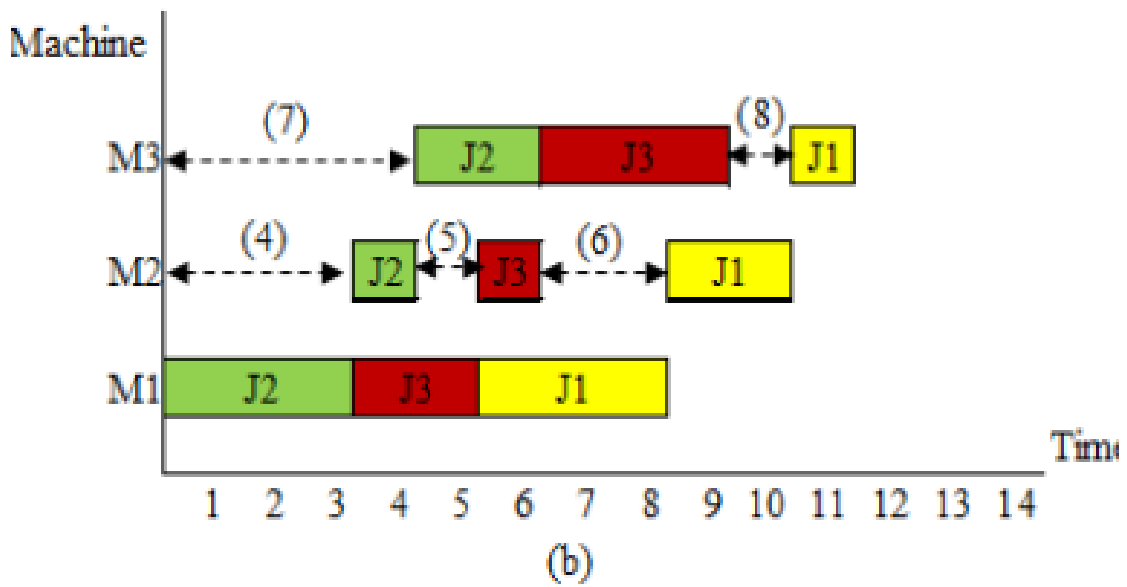
Figura 8

Indices de consumo Pej y lej para cada máquina.

Job	Machine		
	M1	M2	M3
J1	3	2	1
J2	3	1	2
J3	2	1	3
<i>Pej</i>	2	1	2
<i>lej</i>	1	1	1

Nota. Adaptado de Utama y Widodo (2019)

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 9*Secuencia Flow Shop (a).**Nota.* Adaptado de Utama y Widodo (2019)**Figura 10***Secuencia Flow Shop (b).**Nota.* Adaptado de Utama y Widodo (2019)

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

8. Desarrollo e Implementación

Se propone abordar el problema planteado en el capítulo 7, mediante el uso de una metaheurística basada en el Algoritmo Genético, el cual permite iterar soluciones hasta alcanzar una buena solución en un tiempo computacional razonable.

El algoritmo para la solución del problema PSFP, fue ejecutado en un computador con procesador Intel® Core™ i5-5200U CPU @ de 2,20 GHz, memoria RAM instalada de 8.00 GB y un sistema operativo Microsoft Windows 10 (Build 19041.685) de 64 bits. El software empleado fue Matlab en su versión: 9.8.0.1417392 (R2020a) Update 4, con el solver Global Optimization Toolbox y el solver Optimization Toolbox.

8.1. Instancias para la Validación del Modelo Matemático.

Las instancias por tratar son las presentadas en el Apéndice E, las cuales constan de tres tamaños diferentes según la cantidad de trabajos y maquinas que deban programarse. En Tabla 2 se muestran las instancias representativas para problemas de tamaño pequeño, mediano y grande para dar solución al problema de Flow Shop.

Las instancias que se describen en la tabla fueron adaptadas de la literatura tomadas de la tesis E. Taillard, "Benchmarks for basic scheduling problems". Mientras que parámetros como el consumo de energía serán generados aleatoriamente, para el consumo de energía cuando la maquina esta activa se sigue una distribución uniforme (1,100) para cada operación y el consumo de energía en la maquina en reposo es (1,10) en cada máquina, unidad vatios (W). Estos valores fueron tomados según la experimentación de Utama y Widodo (2019) mismos autores del modelo matemático utilizado en esta investigación.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla 2*Clasificación de las instancias a evaluar*

ITEM	Instancias problema tamaño pequeño	Instancias problema tamaño mediano	Instancias problema tamaño grande
1.	20*5	50*5	100*5
2.	20*10	50*10	100*10
3.	20*20	50*20	100*20

Dado que, las soluciones obtenidas por métodos metaheurísticos son aproximadas, existe la necesidad de comparar los resultados obtenidos por dichos métodos con un método de solución exacto. En esta investigación, con el fin de validar la precisión y efectividad del Algoritmo Genético, se comparan los resultados con los obtenidos para una instancia de prueba de tamaño pequeño en este caso la instancia de 20 trabajos, 5 máquinas, 10 máquinas y 20 máquinas; dicha comparación se realiza con el modelo de programación lineal usando la herramienta GAMS. El motivo que lleva a evaluar solamente un tamaño de instancia de prueba consiste en que el tiempo computacional requerido en las instancias de mayor tamaño es demasiado elevado. Por tal razón para estas instancias será utilizado el GA, el cual se encargará de dar las soluciones aproximadas .

8.2. Estructuras de Datos

A continuación, se describen los datos requeridos por el algoritmo. Los valores numéricos son ilustrativos y no representan las instancias evaluadas.

8.2.1. Datos Generales

Corresponden a los datos relacionados al número de trabajos y maquinas disponibles en el problema, los cuales definen el tamaño de la instancia del problema.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla 3*Instancia del problema.*

Instancia	Número de trabajos	Máquinas disponibles
1	20	5

8.2.2. Trabajos y Máquinas

Las siguientes tablas resumen la información relacionada a los trabajos y maquinas, el tiempo de ejecución y consumo de energía de cada trabajo en cada máquina. Por último, se presenta el consumo de energía cuando cada máquina se encuentra vacía.

Tabla 4*Tiempo de procesamiento del trabajo j en la máquina m*

Máquinas	Trabajos				
	j1	j2	j3	j4	j5
m1	54	83	15	71	77
m2	79	3	11	99	56
m3	16	89	49	15	89
m4	66	58	31	68	78
m5	58	56	20	85	53

Tabla 5*Consumo de energía del trabajo j en la máquina m*

Máquinas	Trabajos				
	j1	j2	j3	j4	j5
m1	19	80	33	76	24
m2	64	20	46	48	73
m3	8	48	55	19	85
m4	33	16	65	39	37
m5	16	43	20	49	91

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla 6

Consumo de energía de la maquina m cuando está desocupada.

Máquinas	Idle
m1	5
m2	3
m3	10
m4	2
m5	4

8.2. Representación de la Solución

La representación de la solución consta de un vector unidimensional, donde la posición de cada trabajo indica en qué momento debe iniciar su procesamiento.

Tabla 7

Representación de la solución

6	4	7	2	1	5	10	8	9	3
---	---	---	---	---	---	----	---	---	---

La solución presenta un problema en el cual se deben procesar 10 trabajos, en donde el primer trabajo a procesar corresponde al trabajo 6, seguido del trabajo 4 y así sucesivamente hasta terminar procesando el trabajo 3. Esta representación de la solución nos indica el cronograma de tareas para el Flow Shop que minimiza el consumo de energía y Makespan.

8.3. Función de Aptitud

Se define una función de aptitud con el objetivo de minimizar el consumo de energía $F(s)$ de la solución s , dicha función se encarga de medir el consumo de energía de las maquinas cuando están en procesamiento y cuando están vacías.

$$F(s) = TEC$$

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Para ello, el algoritmo se encarga de determinar el momento de inicio de cada trabajo en las diferentes máquinas, respetando las restricciones duras, es decir, permiten que no se traslapen dos trabajos en una misma máquina y se respeten las secuencias.

8.4. Adaptación del Algoritmo

Se inicia definiendo la instancia y los valores de los parámetros involucrados. El algoritmo inicia generando una población de soluciones en las cuales los trabajos son ordenados de manera aleatoria. Posteriormente, se seleccionan los padres mediante un operador de Selección por Torneo. Luego se aplica el operador de cruce el cual, con cierta probabilidad, se encarga de generar dos soluciones nuevas a partir de los padres seleccionados, seguidamente se aplica el proceso de mutación con una probabilidad. Finalmente, el remplazo de la población se da mediante la incorporación de los descendientes en el lugar de los padres originales. Este proceso se repite hasta alcanzar el número de generaciones establecido, obteniendo como resultado la mejor solución posible, es decir, aquella con menor consumo de energía.

A continuación, se presenta el pseudocódigo del Algoritmo Genético implementado en el problema.

Figura 11

Pseudocódigo Algoritmo Genético creación propia.

```

1:   Entrada: Instancia del problema
2:   Definición de parámetros // Inicia el GA
3:   Generar población inicial
4:   Evaluar aptitud de la población
5:   While el número de generaciones no sea alcanzado
6:       Seleccionar los padres mediante la Selección por Torneo
7:       Generar dos individuos usando el operador de Cruzamiento con probabilidad  $P_c$ 
8:       Aplicar el operador de Mutación sobre los descendientes con Probabilidad  $P_m$ 
9:       Introducir los descendientes a la población mediante el operado de Remplazo
10:  End while
11:  Salida: Mejor solución  $S$  encontrada
12:  // Finaliza GA

```

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

8.4.1. Selección por Torneo

Este operador se encarga de escoger quienes serán los individuos que participarán en el proceso de cruzamiento, esto se lleva a cabo seleccionando un listado de $K=4$ individuos aleatoriamente, permitiendo que individuos de baja calidad tengan oportunidad de ser seleccionados. Posteriormente, se evalúa la aptitud de los K seleccionados y se escogen los dos mejores.

Figura 12

Operador de Selección por Torneo creación propia.

- 1: Entrada: Población de soluciones
- 2: Seleccionar aleatoriamente K individuos
- 3: Evaluar la aptitud de cada individuo seleccionado
- 4: Escoger a los dos mejores individuos.
- 5: Salida: Dos individuos seleccionados como padres

8.4.2. Operador de Cruzamiento

El operador de cruzamiento se aplica si se cumple cierta probabilidad P_c , dicho operador trabaja separando a los progenitores en un punto de la cadena y uniendo información de ambos progenitores entre sí de manera aleatoria. De esta forma se generan dos descendientes con información de ambos progenitores. Este procedimiento, por lo general ocasiona que se presenten trabajos duplicados y se eliminen otros, por lo que se requiere que los descendientes sean reparados para evitar la duplicidad de trabajos.

Figura 13

Operador de Cruzamiento creación propia.

- 1: Entrada: Progenitores
- 2: **If** Se cumple la probabilidad P_c
- 3: Realizar cruce de 1 punto
- 4: Reparar descendientes
- 5: **End if**
- 6: Salida: Descendientes

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

8.4.3. Operador de Mutación

El operador de mutación se aplica si se cumple con cierta probabilidad P_m , dicho operador se encarga de intercambiar las posiciones de dos trabajos dentro de cada individuo generado como descendiente.

Figura 14

Operador de Mutación creación propia.

```

1:   Entrada: Descendientes
2:   If Se cumple la probabilidad  $P_m$ 
3:     Aplicar operador de mutación
4:   End if
5:   Salida: Descendientes mutados

```

9. Diseño de Experimentos

Al desarrollar la metaheurística que se basa en el algoritmo GA es necesario comprobar su funcionalidad y consistencia a partir de experimentos numéricos; un diseño de experimentos consiste en un cambio en las condiciones de operación de un sistema con el objetivo de medir el efecto del cambio sobre una o varias propiedades del producto, resultado o variable respuesta (Gutiérrez Pulido & De la Vara Salazar, 2008).

El algoritmo Genético propuesto cuenta con cuatro parámetros que controlan su desempeño, los cuales son: el tamaño de la población, cantidad de generaciones, probabilidad de cruce y probabilidad de mutación, el algoritmo cuenta con un parámetro fijo el cual corresponde al tamaño de la lista del torneo (K) con un valor de 4. Con el objetivo de determinar los parámetros adecuados se planteó un diseño factorial del tipo 2^k con 5 réplicas. Los detalles relacionados al diseño de cada instancia están documentados en el apéndice E.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Los factores y niveles considerados se presentan en la **Tabla 8**.

Tabla 8

Factores y niveles del diseño experimental

Factores	Nivel bajo (-)	Nivel alto (+)
Tamaño de Población	10	100
Cantidad de generaciones	100	500
Probabilidad de cruce	0,7	0,9
Probabilidad de mutación	0,02	0,1

A continuación, se presenta el Análisis de varianza de cada una de las instancias a ser evaluadas.

9.1 Análisis de Varianza Para la Instancia 20*5

Tabla 9

*Análisis de varianza para la instancia 20*5*

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Modelo	15	11797031	786469	4,51	0,000
Lineal	4	8589665	2147416	12,32	0,000
P. mutación	1	673	673	0,00	0,951
P Cruce	1	519064	519064	2,98	0,089
Generaciones	1	170940	170940	0,98	0,326
Población	1	7898988	7898988	45,31	0,000
Interacciones de 2 términos	6	1915055	319176	1,83	0,107
P. mutación*P Cruce	1	551120	551120	3,16	0,080
P. mutación*Generaciones	1	722380	722380	4,14	0,046
P. mutación*Población	1	514884	514884	2,95	0,091
P Cruce*Generaciones	1	20034	20034	0,11	0,736
P Cruce*Población	1	104980	104980	0,60	0,441
Generaciones*Población	1	1656	1656	0,01	0,923
Interacciones de 3 términos	4	1082186	270546	1,55	0,198
P. mutación*P Cruce*Generaciones	1	440748	440748	2,53	0,117
P. mutación*P Cruce*Población	1	609354	609354	3,50	0,066
P. mutación*Generaciones*Población	1	562	562	0,00	0,955
P Cruce*Generaciones*Población	1	31522	31522	0,18	0,672
Interacciones de 4 términos	1	210125	210125	1,21	0,276
Error	64	11157174	174331		
Total	79	22954204			

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 15

*Diagrama de Pareto de efectos estandarizados de la instancia 20*5*





Figura 16


*Diagrama de efectos principales para la instancia 20*5*



SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 17

Gráfica de interacciones para la instancia 20*5



El análisis de varianza y el diagrama de Pareto de la Figura 15 permiten identificar los factores con efectos significativos sobre la aptitud de la solución, en este caso, corresponde al tamaño de población con valor de 100. A partir del gráfico de interacciones se encuentra que la interacción entre la probabilidad de mutación y el número de generaciones es de tipo significativo, siendo 0,1 y 500 sus valores correspondientes. Finalmente, el valor de la probabilidad de cruce se deja en su valor mínimo para reducir el tiempo de procesamiento del algoritmo.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

9.2. Análisis de Varianza para la Instancia 20*10

Tabla 10

*Análisis de varianza para la instancia 20*10.*

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Modelo	15	166024987	11068332	5,25	0,000
Lineal	4	137175203	34293801	16,25	0,000
P. mutación	1	1959693	1959693	0,93	0,339
P Cruce	1	1361637	1361637	0,65	0,425
Generaciones	1	1892048	1892048	0,90	0,347
Población	1	131961825	131961825	62,54	0,000
Interacciones de 2 términos	6	15326148	2554358	1,21	0,313
P. mutación*P Cruce	1	905464	905464	0,43	0,515
P. mutación*Generaciones	1	531217	531217	0,25	0,618
P. mutación*Población	1	2963345	2963345	1,40	0,240
P Cruce*Generaciones	1	12878	12878	0,01	0,938
P Cruce*Población	1	18150	18150	0,01	0,926
Generaciones*Población	1	10895094	10895094	5,16	0,026
Interacciones de 3 términos	4	8709378	2177345	1,03	0,398
P. mutación*P Cruce*Generaciones	1	5040582	5040582	2,39	0,127
P. mutación*P Cruce*Población	1	174752	174752	0,08	0,774
P. mutación*Generaciones*Población	1	2869410	2869410	1,36	0,248
P Cruce*Generaciones*Población	1	624635	624635	0,30	0,588
Interacciones de 4 términos	1	4814258	4814258	2,28	0,136
P. mutación*P Cruce * Generaciones *Población	1	4814258	4814258	2,28	0,136
Error	64	135040924	2110014		
Total	79	301065911			

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 18

Diagrama de Pareto de efectos estandarizados de la instancia 20*10



**Figura 19**


Diagrama de efectos principales para la instancia 20*10



SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 20

Gráfica de interacciones para la instancia 20*10



El análisis de varianza y el diagrama de Pareto de la Figura 18 permiten identificar los factores con efectos significativos sobre la aptitud de la solución, en este caso, corresponde al tamaño de población con valor de 100. A partir del gráfico de interacciones se encuentra que la interacción entre la población y el número de generaciones es de tipo significativo, siendo el valor de 100 el que alcanza el objetivo de minimización. Finalmente, el valor de la probabilidad de cruce y la probabilidad de mutación se fijan en su valor mínimo para reducir el tiempo de procesamiento del algoritmo.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

9.3 Análisis de Varianza para la Instancia 20*20

Tabla 11

*Análisis de varianza para la instancia 20*20*

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Modelo	15	619272047	41284803	6,00	0,000
Lineal	4	504548312	126137078	18,34	0,000
P. mutación	1	61605	61605	0,01	0,925
P Cruce	1	204626	204626	0,03	0,864
Generaciones	1	1187306	1187306	0,17	0,679
Población	1	503094774	503094774	73,14	0,000
Interacciones de 2 términos	6	84892223	14148704	2,06	0,071
P. mutación*P Cruce	1	7911562	7911562	1,15	0,288
P. mutación*Generaciones	1	16742670	16742670	2,43	0,124
P. mutación*Población	1	6428646	6428646	0,93	0,337
P Cruce*Generaciones	1	1888666	1888666	0,27	0,602
P Cruce*Población	1	17672000	17672000	2,57	0,114
Generaciones*Población	1	34248679	34248679	4,98	0,029
Interacciones de 3 términos	4	26983651	6745913	0,98	0,424
P. mutación*P Cruce*Generaciones	1	3829875	3829875	0,56	0,458
P. mutación*P Cruce*Población	1	14054938	14054938	2,04	0,158
P. mutación*Generaciones*Población	1	6635520	6635520	0,96	0,330
P Cruce*Generaciones*Población	1	2463318	2463318	0,36	0,552
Interacciones de 4 términos	1	2847860	2847860	0,41	0,522
P. mutación*P Cruce*Generaciones*Población	1	2847860	2847860	0,41	0,522
Error	64	440239305	6878739		
Total	79	1059511352			

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 21

*Diagrama de Pareto de efectos estandarizados de la instancia 20*20*





Figura 22

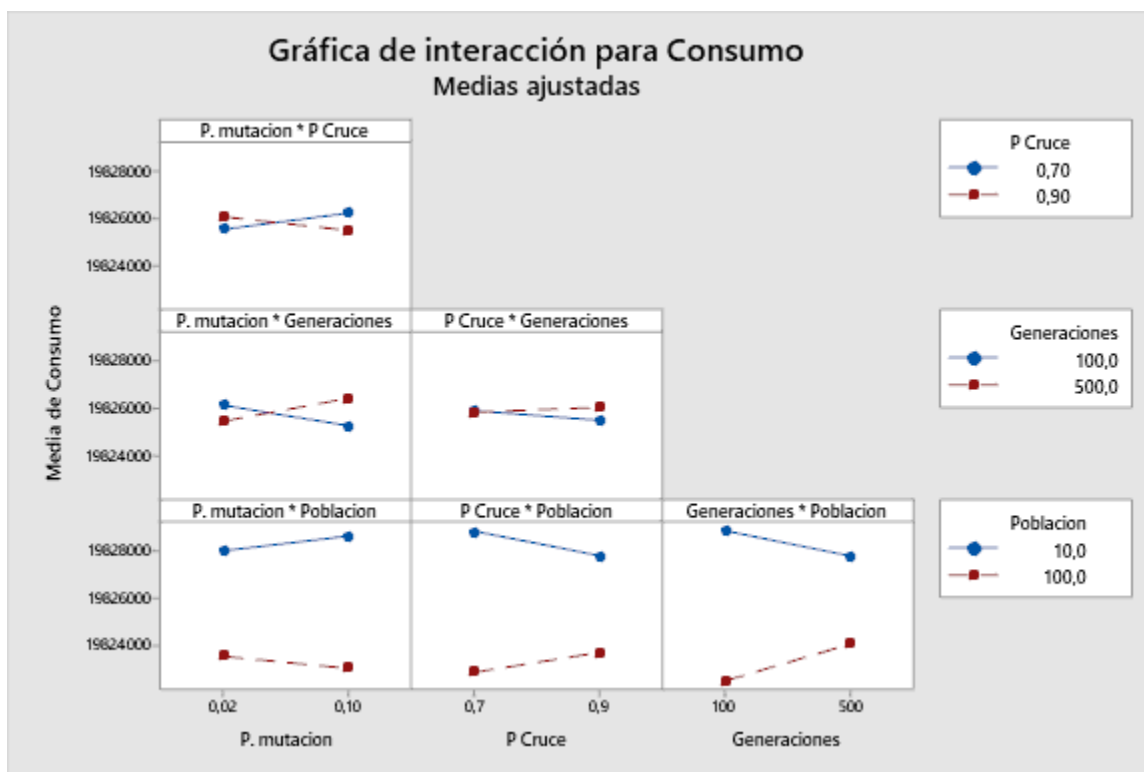
*Diagrama de efectos principales para la instancia 20*20*



SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 23

Gráfica de interacciones para la instancia 20*20



El análisis de varianza y el diagrama de Pareto de la Figura 21 permiten identificar los factores con efectos significativos sobre la aptitud de la solución, en esta instancia, corresponde al tamaño de población con valor de 100. A partir del gráfico de interacciones se encuentra que la interacción entre la población y el número de generaciones es de tipo significativo, siendo el valor de 100 el que alcanza el objetivo de minimización. Finalmente, el valor de la probabilidad de cruce y la probabilidad de mutación se fijan en su valor mínimo para reducir el tiempo de procesamiento del algoritmo.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

9.4. Análisis de Varianza para la Instancia 50*5

Tabla 12

*Análisis de varianza para la instancia 50*5*

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Modelo	15	99284385	6618959	7,77	0,000
Lineal	4	93121379	23280345	27,35	0,000
P. mutación	1	793812	793812	0,93	0,338
P Cruce	1	725234	725234	0,85	0,359
Generaciones	1	3874200	3874200	4,55	0,037
Población	1	87728133	87728133	103,05	0,000
Interacciones de 2 términos	6	3029821	504970	0,59	0,735
P. mutación*P Cruce	1	1025819	1025819	1,20	0,276
P. mutación*Generaciones	1	89579	89579	0,11	0,747
P. mutación*Población	1	22078	22078	0,03	0,873
P Cruce*Generaciones	1	744015	744015	0,87	0,353
P Cruce*Población	1	1125040	1125040	1,32	0,255
Generaciones*Población	1	23290	23290	0,03	0,869
Interacciones de 3 términos	4	3110774	777694	0,91	0,462
P. mutación*P Cruce*Generaciones	1	110484	110484	0,13	0,720
P. mutación*P Cruce*Población	1	983683	983683	1,16	0,286
P. mutación*Generaciones*Población	1	593229	593229	0,70	0,407
P Cruce*Generaciones*Población	1	1423378	1423378	1,67	0,201
Interacciones de 4 términos	1	22412	22412	0,03	0,872
P. mutación*P Cruce*Generaciones*Población	1	22412	22412	0,03	0,872
Error	64	54485618	851338		
Total	79	153770003			

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 24

Diagrama de Pareto de efectos estandarizados de la instancia 50*5



**Figura 25**


Diagrama de efectos principales para la instancia 50*5



SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 26

Gráfica de interacciones para la instancia 50*5



El análisis de varianza y el diagrama de Pareto de la Figura 24 permiten identificar los factores con efectos significativos sobre la aptitud de la solución, en esta instancia, corresponden al tamaño de población con valor de 100 y el número de generaciones con valor de 100. Además, no se encuentra ninguna interacción de tipo significativo. Finalmente, el valor de la probabilidad de cruce y la probabilidad de mutación se fijan en su valor mínimo para reducir el tiempo de procesamiento del algoritmo.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

9.5. Análisis de Varianza para la Instancia 50*10

Tabla 13

*Análisis de varianza para la instancia 50*10*

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Modelo	15	403475952	26898397	6,19	0,000
Lineal	4	365349601	91337400	21,03	0,000
P. mutación	1	208	208	0,00	0,995
P Cruce	1	1465841	1465841	0,34	0,563
Generaciones	1	339171	339171	0,08	0,781
Población	1	363544382	363544382	83,69	0,000
Interacciones de 2 términos	6	23737194	3956199	0,91	0,493
P. mutación*P Cruce	1	2551480	2551480	0,59	0,446
P. mutación*Generaciones	1	10513225	10513225	2,42	0,125
P. mutación*Población	1	6670703	6670703	1,54	0,220
P Cruce*Generaciones	1	888101	888101	0,20	0,653
P Cruce*Población	1	169556	169556	0,04	0,844
Generaciones*Población	1	2944130	2944130	0,68	0,413
Interacciones de 3 términos	4	13118321	3279580	0,75	0,558
P. mutación*P Cruce*Generaciones	1	3744153	3744153	0,86	0,357
P. mutación*P Cruce*Población	1	6296103	6296103	1,45	0,233
P. mutación*Generaciones*Población	1	351523	351523	0,08	0,777
P Cruce*Generaciones*Población	1	2726542	2726542	0,63	0,431
Interacciones de 4 términos	1	1270836	1270836	0,29	0,590
P. mutación*P Cruce*Generaciones*Población	1	1270836	1270836	0,29	0,590
Error	64	278016475	4344007		
Total	79	681492427			

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 27

Diagrama de Pareto de efectos estandarizados de la instancia 50*10





Figura 28

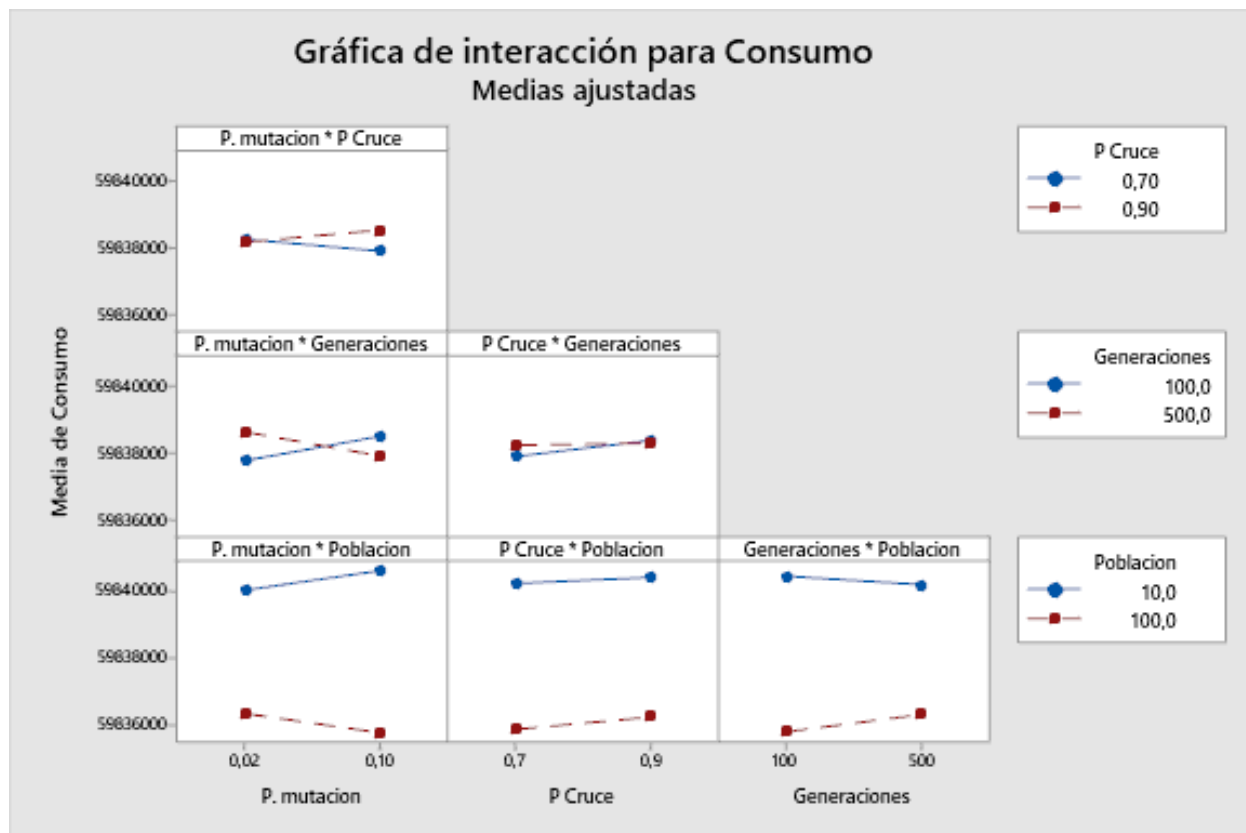
Diagrama de efectos principales para la instancia 50*10



SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 29

Gráfica de interacciones para la instancia 50*10



El análisis de varianza y el diagrama de Pareto de la Figura 27 permiten identificar los factores con efectos significativos sobre la aptitud de la solución, en esta instancia, corresponde al tamaño de población con valor de 100. Los demás efectos y sus interacciones no son significativos, por lo que el valor de la probabilidad de cruce y la probabilidad de mutación y número de generaciones se fijan en su valor mínimo para reducir el tiempo de procesamiento del algoritmo.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

9.6 Análisis de Varianza para la Instancia 50*20

Tabla 14

*Análisis de varianza para la instancia 50*20*

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Modelo	15	1369284516	91285634	4,29	0,000
Lineal	4	1251453664	312863416	14,71	0,000
P. mutación	1	37066838	37066838	1,74	0,191
P Cruce	1	2965655	2965655	0,14	0,710
Generaciones	1	26999070	26999070	1,27	0,264
Población	1	1184422101	1184422101	55,70	0,000
Interacciones de 2 términos	6	33678466	5613078	0,26	0,952
P. mutación*P Cruce	1	16014236	16014236	0,75	0,389
P. mutación*Generaciones	1	5015512	5015512	0,24	0,629
P. mutación*Población	1	14988	14988	0,00	0,979
P Cruce*Generaciones	1	9582125	9582125	0,45	0,504
P Cruce*Población	1	2804631	2804631	0,13	0,718
Generaciones*Población	1	246975	246975	0,01	0,915
Interacciones de 3 términos	4	81761179	20440295	0,96	0,435
P. mutación*P Cruce*Generaciones	1	12438588	12438588	0,58	0,447
P. mutación*P Cruce*Población	1	34346895	34346895	1,62	0,208
P. mutación*Generaciones*Población	1	6780884	6780884	0,32	0,574
P Cruce*Generaciones*Población	1	28194813	28194813	1,33	0,254
Interacciones de 4 términos	1	2391207	2391207	0,11	0,738
P. mutación*P Cruce*Generaciones*Población	1	2391207	2391207	0,11	0,738
Error	64	1360980106	21265314		
Total	79	2730264622			

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 30

Diagrama de Pareto de efectos estandarizados de la instancia 50*20


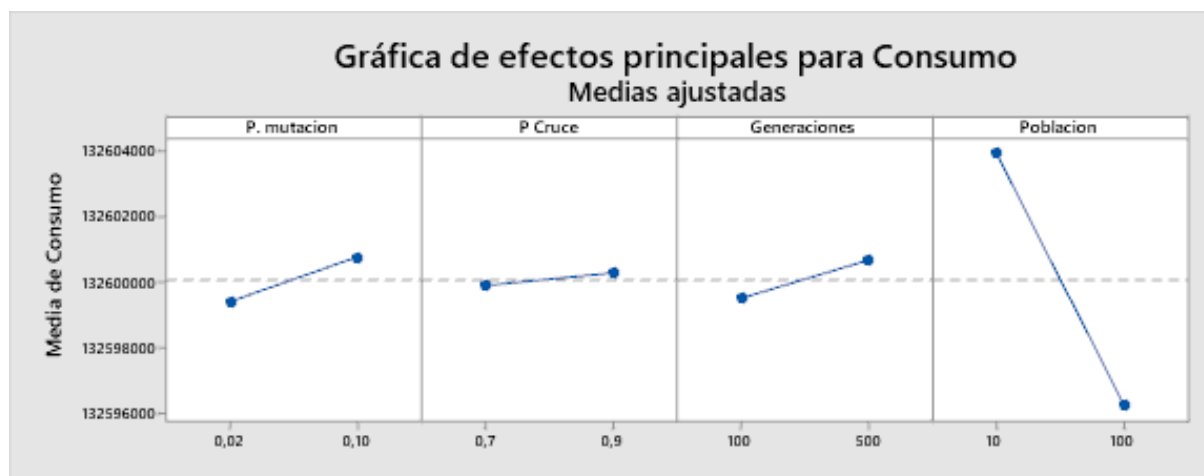
**Figura 31**


Diagrama de efectos principales para la instancia 50*20



SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 32

Gráfica de interacciones para la instancia 50*20



El análisis de varianza y el diagrama de Pareto de la Figura 30 permiten identificar los factores con efectos significativos sobre la aptitud de la solución, en esta instancia, corresponde al tamaño de población con valor de 100. Los demás efectos y sus interacciones no son significativos, por lo que el valor de la probabilidad de cruce y la probabilidad de mutación y número de generaciones se fijan en su valor mínimo para reducir el tiempo de procesamiento del algoritmo.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

9.7 Análisis de Varianza para la Instancia 100*5

Tabla 15

*Análisis de varianza para la instancia 100*5*

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Modelo	15	138496725	9233115	11,14	0,000
Lineal	4	121035279	30258820	36,51	0,000
P. mutación	1	2215117	2215117	2,67	0,107
P Cruce	1	707256	707256	0,85	0,359
Generaciones	1	14906	14906	0,02	0,894
Población	1	118098000	118098000	142,48	0,000
Interacciones de 2 términos	6	14133628	2355605	2,84	0,016
P. mutación*P Cruce	1	7284245	7284245	8,79	0,004
P. mutación*Generaciones	1	185281	185281	0,22	0,638
P. mutación*Población	1	2385332	2385332	2,88	0,095
P Cruce*Generaciones	1	1182925	1182925	1,43	0,237
P Cruce*Población	1	364500	364500	0,44	0,510
Generaciones*Población	1	2731344	2731344	3,30	0,074
Interacciones de 3 términos	4	3267098	816775	0,99	0,422
P. mutación*P Cruce*Generaciones	1	2956036	2956036	3,57	0,063
P. mutación*P Cruce*Población	1	293062	293062	0,35	0,554
P. mutación*Generaciones*Población	1	17880	17880	0,02	0,884
P Cruce*Generaciones*Población	1	120	120	0,00	0,990
Interacciones de 4 términos	1	60720	60720	0,07	0,788
P. mutación*P Cruce*Generaciones*Población	1	60720	60720	0,07	0,788
Error	64	53047721	828871		
Total	79	191544446			

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 33

*Diagrama de Pareto de efectos estandarizados de la instancia 100*5*





Figura 34

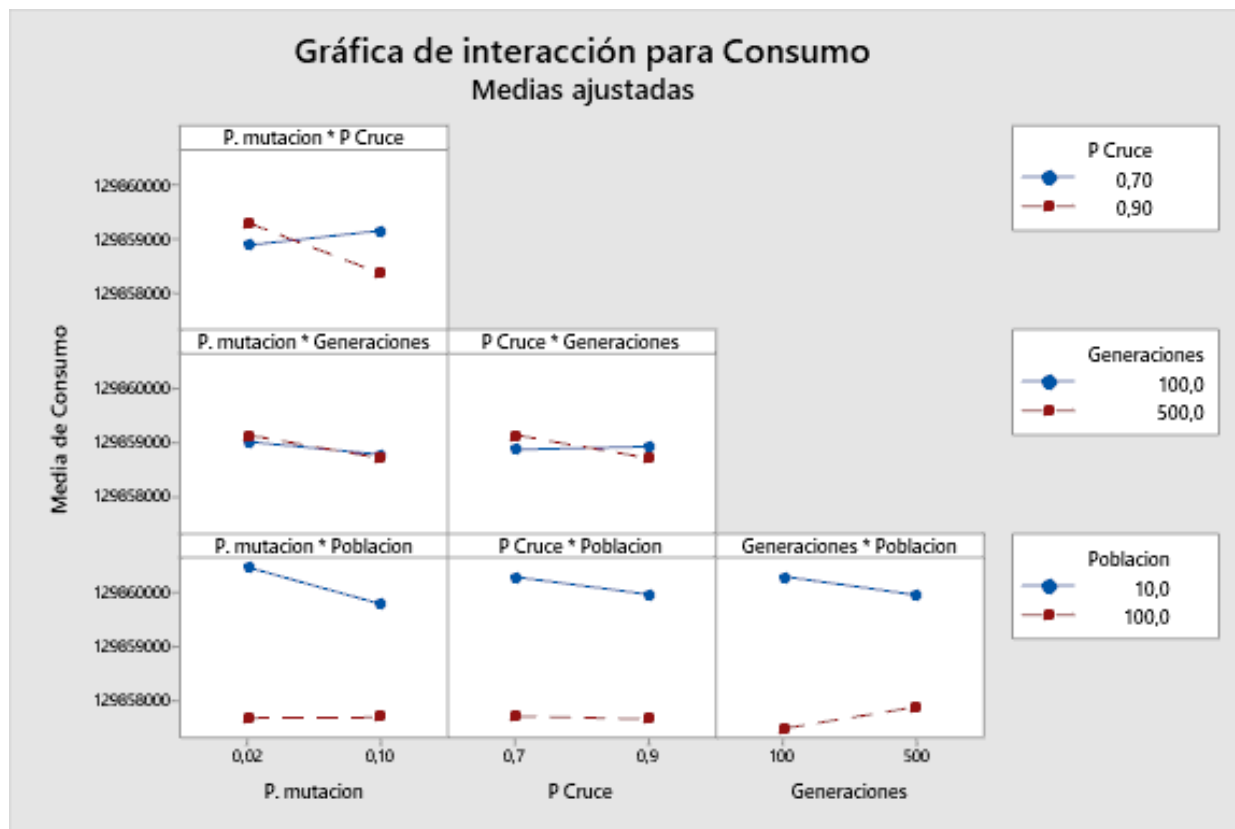
*Diagrama de efectos principales para la instancia 100*5*



SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 35

Gráfica de interacciones para la instancia 100*5



El análisis de varianza y el diagrama de Pareto de Figura 33 permiten identificar los factores con efectos significativos sobre la aptitud de la solución, en esta instancia, corresponde al tamaño de población con valor de 100. A partir del gráfico de interacciones se encuentra que la interacción entre la probabilidad de mutación y probabilidad de cruce es de tipo significativo, teniendo el valor de 0,1 y 0,9 respectivamente. Finalmente, el valor de cantidad de generaciones se fija en su valor mínimo para reducir el tiempo de procesamiento del algoritmo.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

9.8 Análisis de Varianza para la Instancia 100*10

Tabla 16

Análisis de varianza para la instancia 100*10

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Modelo	15	676864707	45124314	6,44	0,000
Lineal	4	574587820	143646955	20,49	0,000
P. mutación	1	612325	612325	0,09	0,769
P Cruce	1	2405752	2405752	0,34	0,560
Generaciones	1	12506502	12506502	1,78	0,186
Población	1	559063241	559063241	79,74	0,000
Interacciones de 2 términos	6	63439391	10573232	1,51	0,190
P. mutación*P Cruce	1	5356643	5356643	0,76	0,385
P. mutación*Generaciones	1	2672171	2672171	0,38	0,539
P. mutación*Población	1	27955484	27955484	3,99	0,050
P Cruce*Generaciones	1	20756013	20756013	2,96	0,090
P Cruce*Población	1	5568818	5568818	0,79	0,376
Generaciones*Población	1	1130264	1130264	0,16	0,689
Interacciones de 3 términos	4	38647859	9661965	1,38	0,251
P. mutación*P Cruce*Generaciones	1	2357441	2357441	0,34	0,564
P. mutación*P Cruce*Población	1	5682313	5682313	0,81	0,371
P. mutación*Generaciones*Población	1	907167	907167	0,13	0,720
P Cruce*Generaciones*Población	1	29700938	29700938	4,24	0,044
Interacciones de 4 términos	1	189638	189638	0,03	0,870
P. mutación*P Cruce*Generaciones*Población	1	189638	189638	0,03	0,870
Error	64	448723569	7011306		
Total	79	1125588276			

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 36

Diagrama de Pareto de efectos estandarizados de la instancia 100*10



**Figura 37**


Diagrama de efectos principales para la instancia 100*10



SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 38

Gráfica de interacciones para la instancia 100*10



El análisis de varianza y el diagrama de Pareto de la Figura 36 permiten identificar los factores con efectos significativos sobre la aptitud de la solución, en esta instancia, corresponde al tamaño de población con valor de 100. A partir del gráfico de interacciones se encuentra que la interacción entre la probabilidad de cruce y número de generaciones es de tipo significativo, teniendo el valor de 0,9 y 100 respectivamente. Finalmente, el valor de la probabilidad de mutación se fija en su valor mínimo para reducir el tiempo de procesamiento del algoritmo.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

9.. Análisis de Varianza para la Instancia 100*20

Tabla 17

*Análisis de varianza para la instancia 100*20*

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Modelo	15	2687641128	179176075	8,05	0,000
Lineal	4	2515985186	628996296	28,25	0,000
P. mutación	1	242881	242881	0,01	0,917
P Cruce	1	7446881	7446881	0,33	0,565
Generaciones	1	24431551	24431551	1,10	0,299
Población	1	2483863873	2483863873	111,57	0,000
Interacciones de 2 términos	6	139608832	23268139	1,05	0,405
P. mutación*P Cruce	1	45369756	45369756	2,04	0,158
P. mutación*Generaciones	1	82385523	82385523	3,70	0,059
P. mutación*Población	1	1361	1361	0,00	0,994
P Cruce*Generaciones	1	378125	378125	0,02	0,897
P Cruce*Población	1	6237328	6237328	0,28	0,598
Generaciones*Población	1	5236738	5236738	0,24	0,629
Interacciones de 3 términos	4	31471149	7867787	0,35	0,841
P. mutación*P Cruce*Generaciones	1	9178770	9178770	0,41	0,523
P. mutación*P Cruce*Población	1	6125	6125	0,00	0,987
P. mutación*Generaciones*Población	1	6894902	6894902	0,31	0,580
P Cruce*Generaciones*Población	1	15391351	15391351	0,69	0,409
Interacciones de 4 términos	1	575962	575962	0,03	0,873
P. mutación*P Cruce*Generaciones*Población	1	575962	575962	0,03	0,873
Error	64	1424821958	22262843		
Total	79	4112463086			

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 39

Diagrama de Pareto de efectos estandarizados de la instancia 100*20



**Figura 40**


Diagrama de Pareto de efectos estandarizados de la instancia 100*20



SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 41

Gráfica de interacciones para la instancia 100*20



El análisis de varianza y el diagrama de Pareto de la Figura 39 permiten identificar los factores con efectos significativos sobre la aptitud de la solución, en esta instancia, corresponde al tamaño de población con valor de 100. Los demás efectos y sus interacciones no son significativos, por lo que el valor de la probabilidad de cruce y la probabilidad de mutación y número de generaciones se fijan en su valor mínimo para reducir el tiempo de procesamiento del algoritmo.

A continuación, se resumen los valores fijados para cada una de las instancias según los resultados del diseño de experimentos.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla 18*Definición de parámetros para las instancias del PSFP*

Instancia	Población	Generaciones	Cruce	Mutación
Instancia 20-5	100	500	0,7	0,1
Instancia 20-10	100	100	0,7	0,02
Instancia 20-20	100	100	0,7	0,02
Instancia 50-5	100	100	0,7	0,02
Instancia 50-10	100	100	0,7	0,02
Instancia 50-20	100	100	0,7	0,02
Instancia 100-5	100	100	0,9	0,1
Instancia 100-10	100	100	0,9	0,02
Instancia 100-20	100	100	0,7	0,02

10. Resultados Computacionales

En esta capítulo se evalúan los resultados para el TEC que se obtuvieron mediante los métodos propuestos, el método aproximado de solución propuesto que corresponde a la metaheurísticas Algoritmo Genético y la ejecución del modelo matemático como modelo de programación lineal usando la herramienta GAMS. En este capítulo se comparan los resultados obtenidos para una instancia de prueba, la cual es de tamaño 10*5, es decir 10 trabajos y 5 máquinas, esto debido a que el tiempo de ejecución del modelo de programación lineal para instancias de mayor tamaño no generan soluciones en tiempos computacionales razonables.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Adicionalmente se presentan los resultados para cada tamaño de problema considerado se evalúan 5 instancias, tal como se consignan en el Apéndice E.

Para instancias del problema de tamaño mediano y grande solo se evaluaron los resultados de Makespan obtenidos por medio del algoritmo GA a partir de un benchmarking con otras heurísticas que utilizaron las mismas instancias, El método exacto por GAMS, por el contrario, no se considera pertinente para este tipo de instancias debido al tiempo de ejecución elevado lo cual indica tiempos computacionales no pertinentes.

La ejecución de los resultados se desarrolló usando un computador con procesador Intel® Core™ i5-5200U CPU @ de 2,20 GHz, memoria RAM instalada de 8.00 GB y un sistema operativo Microsoft Windows 10 (Build 19041.685) de 64 bits. El software empleado fue Matlab en su versión: 9.8.0.1417392 (R2020a) Update 4.

10.1 Resolución Instancias Pequeñas

En las tablas a continuación se presentan los resultados de las mejores soluciones obtenida por el algoritmo Genético y el tiempo computacional de cada instancia del tipo pequeño, además como información adicional también se presenta los tiempos Makespan de cada problema tratado.

Tabla 19

*Resultados obtenidos por el algoritmo Genético para la instancia 20*5*

Instancia 20*5	TEC	Makespan	CPU time (s)
1	4932033	1474	6,4517414
2	5197524	1496	8,2500541
3	4252789	1373	7,0726597
4	5563249	1535	5,9010488
5	4784122	1428	7,4879711

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla 20

*Resultados obtenidos por el algoritmo Genético para la instancia 20*5*

Instancia 20*10	TEC	Makespan	CPU time (s)
1	10802787	1958	5,181198
2	10100294	1934	3,4207852
3	10204752	1748	3,4596329
4	9157870	1674	3,425967
5	9229041	1655	3,5847141

Tabla 21

*Resultados obtenidos por el algoritmo Genético para la instancia 20*20*

Instancia 20*20	TEC	Makespan	CPU time (s)
1	19822865	2676	6,8280785
2	19003186	2463	4,6080987
3	20601718	2647	5,119172
4	19647131	2654	5,0152864
5	20833375	2603	6,2021256

Con el objetivo de determinar qué tan eficiente es el algoritmo propuesto y validar sus resultados, se propuso programar el mismo modelo matemático como un problema de programación lineal en el software GAMS (ver anexo B) esto se realizó para una instancia de prueba 10*5. El modelo fue programado y ejecutado en la versión GAMS Release 33.2.0 (December 01, 2020) el cual nos permitió validar que el modelo propuesto se ajustara a las características del problema. El modelo matemático de programación lineal se presentan en el apéndice B (documento de formato GMS).

A continuación, se presenta como se obtuvieron las respuestas en GAMS además en la Tabla 22 se resumen los resultados obtenidos por el método exacto y el algoritmo genético en términos de TEC y tiempo computacional.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla 22

*Resultados obtenidos mediante el modelo PL y el algoritmo Genético para la instancia 10*5*

Método de solución	TEC	CPU Time (s)
Programación matemática	1.321.329,41	1,68
Algoritmo Genético	1.321.834	1,54

A partir de los resultados obtenidos por la instancia de prueba 10*5, se observa la diferencia porcentual del TEC de aproximadamente el 0,04% lo cual indica que el método propuesto es capaz de ofrecer soluciones muy cercanas a la óptima. Por otro lado, respecto al tiempo computacional, las diferencias corresponden a que, siendo una instancia de tamaño pequeño, el problema no es lo suficientemente robusto para exigir la capacidad de procesamiento del equipo utilizado.

Además, El rendimiento del algoritmo se puede medir mediante el índice de consumo de energía (ECR Figura 42) según la experimentación de los autores Utama, D., Setiya, d.(2019). El ECR se define como el Consumo de Energía (EC) del algoritmo propuesto GA dividido por EC de diferentes métodos de solución. El GA tendrá un rendimiento más alto que otros algoritmos si $ECR < 1$, pero tiene el mismo rendimiento si produce un valor $ECR = 1$. Además, otro algoritmo tiene un rendimiento más alto si $ECR > 1$.

Figura 42

Ecuación ECR

$$ECR = \frac{EC \text{ Algoritmo propuesto}}{EC \text{ Metodo Exacto}}$$

Tabla 23

Comparación del algoritmo para el consumo de energía ECR.

Instancias Pequeñas	GA-TEC	GAMS-TEC	ECR
10*5	1,321.834	1.321.329,41	1.0004

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

A partir de los resultados de la tabla 20, se concluye el GA tiene un performance muy similar al modelo de programación lineal con soluciones optimas ya el valor obtenido para ECR es significativamente cercano a 1 indicando que tienen un mismo rendimiento, en el contexto industrial la cantidad de trabajos y maquinas son de mayor tamaño por ende variaciones en consumo de energía aunque sea poca puede representar sobrecostos o sobre consumos validando el enfoque genético para la solución de este tipo de problemas es pertinentes ya que obtiene respuestas muy cercanas a la óptima.

10.2 Resolución Instancias Medianas

En las tablas a continuación se presentan los resultados de las mejores soluciones obtenida por el algoritmo Genético y el tiempo computacional de cada instancia del tipo mediano, además como información adicional también se presenta los tiempos Makespan de cada problema tratado.

Tabla 24

*Resultados obtenidos por el algoritmo Genético para la instancia 50*5*

Instancia 50*5	TEC	Makespan	CPU time (s)
1	30785354	2982	4,2742771
2	34058906	3222	3,5789968
3	30036302	2925	4,8873269
4	32674881	3158	3,9343783
5	31916315	3059	4,36835

Tabla 25

*Resultados obtenidos por el algoritmo Genético para la instancia 50*10*

Instancia 50*10	TEC	Makespan	CPU time (s)
1	59836742	3674	6,2358329
2	60951859	3515	4,6770298
3	63151533	3457	3,9788418
4	64802064	3640	4,4205032
5	63668758	3694	4,8930186

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla 26*Resultados obtenidos por el algoritmo Genético para la instancia 50*20*

Instancia 50*20	TEC	Makespan	CPU time (s)
1	132591733	4642	7,5733781
2	123751410	4652	7,0993714
3	122996129	4358	5,8009729
4	126448935	4610	6,264961
5	126492446	4623	6,9201351

Como se mencionó anteriormente el modelo matemático como un problema de programación lineal tiene limitantes ya que al ejecutar instancias de tamaño mediano y grande los tiempos computaciones crecen de una forma exponencial.

10.3 Resolución Instancias Grandes

En las tablas a continuación se presentan los resultados de las mejores soluciones obtenida por el algoritmo Genético y el tiempo computacional de cada instancia del tipo grande, además como información adicional también se presenta los tiempos Makespan de cada problema tratado.

Tabla 27*Resultados obtenidos por el algoritmo Genético para la instancia 100*5*

Instancia 100*5	TEC	Makespan	CPU time (s)
1	129856320	5796	4,4868144
2	127793573	5760	3,6521315
3	124486465	5537	4,210466
4	118377603	5518	3,6992058
5	128798973	5785	3,5045884

Tabla 28*Resultados obtenidos por el algoritmo Genético para la instancia 100*10*

Instancia 100*10	TEC	Makespan	CPU time (s)
1	247603082	6322	5,0185479
2	257082430	6752	6,6925957
3	249125863	6281	6,0313468
4	247224720	6451	4,5124421
5	264940521	6769	4,3145339

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla 29

*Resultados obtenidos por el algoritmo Genético para la instancia 100*20*

Instancia 100*20	TEC	Makespan	CPU time (s)
1	490790463	7642	8,2885175
2	500733926	7531	7,5989723
3	488937939	7725	8,4775935
4	502111932	7741	6,0985716
5	501884082	7480	6,6423168

10.4 Validación de Resultados para Instancias Medianas y Grandes.

Como se mencionó anteriormente el modelo matemático como un problema de programación lineal tiene limitantes ya que al ejecutar instancias de tamaño mediano y grande los tiempos computacionales crecen exponencialmente, además por la complejidad del modelo es difícil encontrar una respuesta en corto tiempo.

Con el fin de analizar la capacidad y buenos resultados de las instancias medianas y grandes para el GA evaluando el Makespan en este caso, fueron tomados de la literatura los resultados obtenidos a través de otra tipo de heurísticas como redes neuronales artificiales evaluadas por los autores Gupta, J. N. D., Majumder, A., & Laha, D. (2019) que utilizaron las mismas instancias tomadas para esta investigación E. Taillard, "Benchmarks for basic scheduling problems", las cuales obtuvieron los siguientes resultados:

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Figura 43

Valores de Makespan producidos por diferentes algoritmos

Table 8. Makespan values produced by different algorithms for Tailard's Benchmark Problem Instances.

Instance	Size ($n \times m$)	CBP	GDAL	UQ-N	L-M	CDS	NEH	NEH-D	NEHLJPI
TA-1	20 × 5	1448	1322	1301	1297	1390	1286	1297	1297
TA-2	20 × 5	1459	1399	1368	1366	1424	1365	1383	1383
TA-3	20 × 5	1209	1196	1158	1104	1249	1159	1132	1111
TA-4	20 × 5	1486	1370	1343	1275	1418	1325	1306	1305
TA-5	20 × 5	1300	1298	1276	1248	1323	1305	1283	1283
TA-6	20 × 5	1444	1307	1276	1210	1312	1228	1264	1210
TA-7	20 × 5	1469	1351	1277	1259	1393	1278	1251	1251
TA-8	20 × 5	1428	1269	1236	1218	1341	1223	1221	1216
TA-9	20 × 5	1385	1341	1287	1271	1360	1291	1289	1267
TA-10	20 × 5	1321	1255	1174	1123	1164	1151	1131	1156
TA-11	50 × 5	2965	2744	2735	2735	2816	2733	2724	2732
TA-12	50 × 5	2987	2965	2884	2840	3032	2843	2882	2882
TA-13	50 × 5	2829	2686	2653	2641	2703	2640	2654	2654
TA-14	50 × 5	2888	2859	2814	2778	2884	2782	2768	2762
TA-15	50 × 5	3071	2922	2911	2871	3038	2868	2890	2868
TA-16	50 × 5	3107	2902	2887	2858	3031	2850	2846	2842
TA-17	50 × 5	3014	2924	2812	2746	2969	2758	2736	2734
TA-18	50 × 5	3058	2791	2725	2705	2835	2721	2704	2704
TA-19	50 × 5	2850	2716	2682	2614	2784	2576	2571	2565
TA-20	50 × 5	3188	2843	2809	2785	2942	2790	2790	2796
TA-21	100 × 5	5724	5546	5527	5493	5592	5519	5514	5493
TA-22	100 × 5	5535	5372	5316	5290	5563	5348	5297	5318
TA-23	100 × 5	5656	5359	5244	5219	5493	5219	5215	5200
TA-24	100 × 5	5158	5061	5044	5035	5273	5023	5027	5023
TA-25	100 × 5	5478	5352	5312	5265	5461	5266	5255	5267
TA-26	100 × 5	5221	5215	5146	5146	5259	5139	5139	5139
TA-27	100 × 5	5425	5376	5261	5246	5557	5259	5283	5259
TA-28	100 × 5	5323	5228	5144	5119	5387	5120	5110	5106
TA-29	100 × 5	5926	5632	5536	5487	5758	5489	5470	5489
TA-30	100 × 5	5758	5363	5342	5336	5723	5341	5346	5343
Average Makespan		3304	3165	3116	3086	3249	3097	3097	3089
# Best Makespan		0	0	0	11	0	6	6	15

Nota. Adaptada de Gupta, Majumder, & Laha, D. (2019)

Para evaluar el rendimiento del algoritmo se puede medir mediante un índice Makespan (MKR) de la misma manera como se evaluó el consumo de energía en el numeral 10.1. El MKR se define como el Makespan del algoritmo propuesto GA dividido por Makespan de diferentes métodos de solución. El GA tendrá un rendimiento más alto que otros algoritmos si $MKR < 1$, pero tiene el mismo rendimiento si produce un valor $MKR = 1$. Además, otro algoritmo tiene un rendimiento más alto si $MKR > 1$. Tomando la primera solución para cada tamaño de instancia y comparándolo con los resultados obtenidos en estas instancias.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Tabla 30

Makespan obtenidos por otros algoritmos

AG	Size (n*m)	CBP	GDAL	UQ-N	L-M	CDS	NEH	NEH-D	NEHLJP1
1474	20*5	1448	1322	1301	1297	1390	1286	1297	1297
2982	50*5	2965	2744	2735	2735	2816	2733	2724	2732
5796	100*5	5724	5546	5527	5493	5592	5519	5514	5493

Tabla 31*Comparación Makespan instancias grandes.*

COMPARACIÓN	Size (n*m)	CBP	GDA L	UQ-N	L-M	CD S	NE H	NEH-D	NEHLJP 1
MKR	20*5	1.02	1.11	1.13	1.14	1.06	1.15	1.14	1.14
MKR	50*5	1.01	1.09	1.09	1.09	1.06	1.09	1.09	1.09
MKR	100*5	1.01	1.05	1.05	1.06	1.04	1.05	1.05	1.06

Tabla 32*Comparación makespan promedio de otras heurísticas con el AG*

AG	Size (n*m)	Promedio makespan heurísticas
1474	20*5	1329.8
2982	50*5	2773
5796	100*5	5551

A partir de la **Tabla 30** se puede definir que el GA desarrollado por esta investigación no obtiene un buen performance en comparación con las otras heurísticas, una de las razones es la complejidad de nuestro modelo matemático que no solo busca minimizar el Makespan sino el consumo de energía por su parte estas heurísticas solo buscaban minimizar el Makespan y no toman en cuenta este nuevo elemento, no obstante esta comparación permite validar que el algoritmo planteado en la investigación obtuvo soluciones congruentes e incluso valores de Makespan cercanos a los mejores valores de solución de estas heurísticas.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Cabe resaltar el consumo de energía para este tamaño de instancias no fue posible comparar ya que una de las limitantes de la investigación fue el acceso a datos de energía usados por otras investigaciones similares, aunque se estableció comunicación vial e-mail con los autores del artículo en el cual se basa el modelo matemático, la respuesta fue que su investigación e investigaciones similares manejan datos aleatorios siguiendo distribuciones uniformes, por ende al generar los datos de energía aleatoriamente para esta investigación se obtendrán resultados diferentes, especialmente ya que se tienen datos de procesamiento totalmente diferente que se obtuvieron de una diferente investigación lo que infiere significativamente en los resultados. Fue por ello que se decidió darle solución al modelo matemático como un problema de programación lineal para así validar el modelo y la calidad de las respuestas.

Al observar el comportamiento del AG comparado con el GAMS para instancias de tamaño pequeño y ver que el valor del TEC obtenido por ambos métodos fue semejante, se puede esperar que para las instancias medianas y grandes el comportamiento siga siendo similar y se acerquen al resultado óptimo.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

11. Conclusiones

Basados en el análisis bibliométrico realizado para la presente investigación, se encuentra relevante el problema Flow Shop acotado a las características propias de la presente investigación está vigente, además tiene alto potencial de investigación que permita ofrecer herramientas de decisión para las industrias manufactureras con este tipo de sistemas productivos.

El modelo matemático planteado contempla un objetivo importante basado en el consumo de energía TEC, el cual busca minimizar el consumo total de energía de las maquinas a través del tiempo, para esto se tiene en cuenta los tiempos de procesamiento, el consumo de energía con las maquinas en funcionamiento y el consumo de energía cuando las maquinas no están ejerciendo ninguna labor, de esta manera cuando se evalúan instancias pequeñas se obtienen resultados computacionales razonables y una buena calidad de respuestas.

Para las instancias de tamaño mediano y grande, no fue posible la comparación por métodos exactos debido a su tamaño, por ello se realizó a través del algoritmo genético y basados en comparaciones con otras investigaciones presentadas en la literatura (Gupta, Majumder, & Laha, D. (2019)), se pudo determinar que el GA desarrollado en la presente investigación para instancias pequeñas, provee soluciones cercanas a la solución óptima, por otro lado, para las instancias medianas y grandes, se pudo concluir que las soluciones dadas fueron muy similares a las mejores soluciones presentadas por otras heurísticas, que hicieron uso de las mismas instancias y estaban enfocadas en minimizar únicamente el Makespan y no tomaban en cuenta el elemento de consumo de energía como si se hizo en esta investigación.

Adicionalmente para optimizar la función objetivo, se planteó el desarrollo de un algoritmo GA, para el cual mediante el proceso de calibración se puede determinar el tamaño de la población

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

inicial corresponde al principal factor con mayor influencia en la variable respuesta *TEC* para todos los tamaños de instancias, por lo cual se opta por emplear el nivel alto de dicho factor con el propósito de determinar mejores soluciones. Otros factores analizados son la probabilidad de cruce y el número de generaciones para los cuales, aunque no representan efectos significativos, se tienen mejores resultados de *TEC* en los niveles bajos de estos.

A partir de la evolución del desempeño de la metaheurística calibrada da como resultado que el algoritmo GA ejecutado para instancias de tamaño pequeño genera buenas soluciones frente al modelo de programación lineal, con una desviación estándar de 0.04% lo cual evidencia la amplia competitividad que tiene la utilización de metaheurísticas como el Algoritmo Genético en la generación de respuestas competentes en la toma decisiones relacionadas a consumos de energía en un sistema productivo tipo “flow- shop”.

Dado a que los tiempos computacionales para instancias de mayores tamaños, es decir mayor número de trabajos y maquinas crecen exponencialmente en este tipo de sistemas Flow shop, la búsqueda de la solución óptima no resulta viable, por su parte el algoritmo genético permite encontrar una buena solución en poco tiempo. Siendo el Flow Shop un problema de programación de operaciones y tipo operativo, el proceso de toma de decisión en las organizaciones debe ser ágil.

12. Recomendaciones

Considerar instancias de otros tamaños (más pequeñas o más grandes) para poder observar el desempeño del modelo realizado o en su defecto un modelo actualizado con mejoras incluidas.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Siendo el problema analizado algo que afecta la realidad de las empresas actualmente, se recomienda a investigadores futuros contemplar nuevos parámetros o restricciones, que ayuden a estar más cerca de la realidad industrial.

Con el fin de comparar y validar los resultados obtenidos a través del Algoritmo Genético, se recomienda la utilización de otros modelos exactos y metaheurísticas, para así observar el desempeño del mismo.

Para investigaciones futuras se puede considerar incluir la velocidad a la que operan las maquinas, para así comparar el desempeño del algoritmo y que tanto se minimiza el consumo energético a distintas velocidades de funcionamiento.

Se recomienda para futuros investigadores, adquirir instancias reales, haciendo tomas de tiempos en industrias de su interés, con el fin de aproximar aún más la investigación a la realidad de las empresas y observar cómo funciona el algoritmo genético y las mejoras que se puedan presentar.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Referencias Bibliográficas

- Batista, María & Moreno-Pérez, José & Moreno-Vega, J.. (2009). Algoritmos Genéticos. Una visión práctica. *Números*, ISSN 0212-3096, N°. 71, 2009 (Ejemplar dedicado a: Darwin).
- Cheng, B. W., & Chang, C. L. (2007). A study on flowshop scheduling problem combining Taguchi experimental design and genetic algorithm. *Expert Systems with Applications*, 32(2), 415–421. <https://doi.org/10.1016/j.eswa.2005.12.002>
- Dai, M., Tang, D., Giret, A., Salido, M. A., & Li, W. D. (2013). Energy-efficient scheduling for a flexible Flow Shop using an improved genetic-simulated annealing algorithm. *Robotics and Computer-Integrated Manufacturing*, 29(5), 418–429. <https://doi.org/10.1016/j.rcim.2013.04.001>
- Ebrahimi, A., Jeon, H. W., Lee, S., & Wang, C. (2020). Minimizing total energy cost and tardiness penalty for a scheduling-layout problem in a flexible job shop system: A comparison of four metaheuristic algorithms. *Computers and Industrial Engineering*, 141(July 2019), 106295. <https://doi.org/10.1016/j.cie.2020.106295>
- Emmons, H., & Vairaktarakis, G. (2013). *Flow Shop Scheduling* (Vol. 182, Issue 1996). Springer US. <https://doi.org/10.1007/978-1-4614-5152-5>
- Fang, K., Uhan, N., Zhao, F., & Sutherland, J. W. (2011). A new approach to scheduling in manufacturing for power consumption and carbon footprint reduction. *Journal of Manufacturing Systems*, 30(4), 234–240. <https://doi.org/10.1016/j.jmsy.2011.08.004>

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Fogel, D. (2005). *Evolutionary Computation: Toward a New Philosophy of Machine Intelligence* (Third edit; W.-I. Press, Ed.). Retrieved from <https://www.wiley.com>

Fuster, J. E. (2016). *Eficiencia Energética y Robustez en Problemas de Scheduling*. 1–164.

Gielen, D., Bennaceur, K., Kerr, T., Tam, C., Tanaka, K., & Taylor, M. (2007). Cartilage committee seminar: Algorithms and flowcharts for the treatment of cartilage pathology. *ESSKA Instructional Course Lecture Book: Geneva 2012*, 9783642294, 215–234. https://doi.org/10.1007/978-3-642-29446-4_14

Gupta, J. N. D., Majumder, A., & Laha, D. (2019). Flowshop scheduling with artificial neural networks. *Journal of the Operational Research Society*, 1–19. doi:10.1080/01605682.2019.1621220

Gutiérrez Pulido, H., & De la Vara Salazar, R. (2008). *Analisis y diseño de experimentos*

Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. [https://books.google.com.co/books?hl=es&lr=&id=5EgGaBkwvWcC&oi=fnd&pg=PR7&dq=Holland+JH+\(1975\)+Adaptation+in+Natural+and+Artificial+Systems.+University+of+Michigan+Press,+Ann+Arbor.&ots=mIoo4YGosi&sig=n_YWdyDb0b8iuVy8lkaI2AH8_MA#v=onepage&q&f=false](https://books.google.com.co/books?hl=es&lr=&id=5EgGaBkwvWcC&oi=fnd&pg=PR7&dq=Holland+JH+(1975)+Adaptation+in+Natural+and+Artificial+Systems.+University+of+Michigan+Press,+Ann+Arbor.&ots=mIoo4YGosi&sig=n_YWdyDb0b8iuVy8lkaI2AH8_MA#v=onepage&q&f=false)

Kirkpatrick, S., Gelatt, C. D., and Vecchi, M. P., 1983, Optimization by simulated annealing, *Science*, **220**:671–680.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

- Krajewski, L., Ritzman, L., & Malhotra, M. (2009). Administración de Operaciones. In Administración de operaciones (Octava edi, Vol. 20). <https://doi.org/10.4067/S0718-07642009000500001>
- Lara Porras, A. (2001). *Diseño estadístico de experimentos, análisis de la varianza y temas relacionados*. Granada: Proyecto Sur.
- Li, J. qing, Sang, H. yan, Han, Y. yan, Wang, C. gang, & Gao, K. zhou. (2018). Efficient multi-objective optimization algorithm for hybrid Flow Shop scheduling problems with setup energy consumptions. *Journal of Cleaner Production*, 181, 584–598. <https://doi.org/10.1016/j.jclepro.2018.02.004>
- Liu, Z., Yan, J., Cheng, Q., Yang, C., Sun, S., & Xue, D. (2020). The mixed production mode considering continuous and intermittent processing for an energy-efficient hybrid Flow Shop scheduling. *Journal of Cleaner Production*, 246. <https://doi.org/10.1016/j.jclepro.2019.119071>
- López Vargas, J. C., & Arango Marín, J. A. (2015). Algoritmo genético para reducir el makespan en un Flow Shop híbrido flexible con máquinas paralelas no relacionadas y tiempos de alistamiento dependientes de la secuencia. *Entramado*, 11(1), 250–262. <https://doi.org/10.18041/entramado.2015v11n1.21103>
- Mansouri, S. A., & Aktas, E. (2016). Minimizing Energy consumption and makespan in a two-machine flowshop scheduling problem. *Journal of the Operational Research Society*, 67(11), 1382–1394. <https://doi.org/10.1057/jors.2016.4>

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

- Marinaki, M. (2008). Flow Shop Scheduling Problem. In *Encyclopedia of Optimization* (pp. 1060–1068). Springer US. https://doi.org/10.1007/978-0-387-74759-0_185
- Martí, R. (2001). Procedimientos Metaheurísticos en Optimización Combinatoria. *Departament d'Estadística i Investigació Operativa*, 1–60. <http://www.uv.es/rmarti/paper/docs/heur1.pdf>
- MathWorks. (n.d.). MathWorks, Inc.
- Michalewicz, Z. (2000). *Genetic Algorithms + Data Structures = Evolution Programs* by Z . Michalewicz Review by : D . M . Rocke Published by : American Statistical Association Stable URL : <http://www.jstor.org/stable/2669583> . Your use of the JSTOR archive indicates your acceptan. 95(449), 347–348.
- Ministerio de minas y energías. (2017). Energy Demand Situation in. *Ministerio De Minas Y Energia*.
- Minitab. (n.d.). Minitab © 2019 All rights Reserved.
- Mouzon, G., Yildirim, M. B., & Twomey, J. (2007). Operational methods for minimization of energy consumption of manufacturing equipment. *International Journal of Production Research*, 45(18–19), 4247–4271. <https://doi.org/10.1080/00207540701450013>
- Osman, I. H., & Kelly, J. P. (1996). *Meta-Heuristics: Theory, & Applications* (Issue 1). <https://doi.org/10.1007/978-1-4613-8>
- Öztop, H., Tasgetiren, M. F., Kandiller, L., Eliiyi, D. T., & Gao, L. (2020). Ensemble of metaheuristics for energy-efficient hybrid flowshops: Makespan versus total energy

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

- consumption. *Swarm and Evolutionary Computation*, 54(September 2019).
<https://doi.org/10.1016/j.swevo.2020.100660>
- Pach, C., Berger, T., Sallez, Y., Bonte, T., Adam, E., & Trentesaux, D. (2014). Reactive and energy-aware scheduling of flexible manufacturing systems using potential fields. *Computers in Industry*, 65(3), 434–448. <https://doi.org/10.1016/j.compind.2013.11.008>
- Pinedo, M. L. (2016). Scheduling. Theory, Algorithms, and Systems. In *Journal of clinical orthodontics : JCO* (fifth, Vol. 18, Issue 6). <https://doi.org/10.1007/978-3-319-26578-3>
- Rico Castillo, D. A., & Rodríguez López, H. G. (2019). *Solución al problema de “Flow-shop” permutado, minimizando los costos de inventario en proceso y penalización debido al retraso de lotes a través de un Algoritmo Genético.*
- Rodes, F. (2011). *ALGORITMOS PROYECTIVOS DE SEPARACION PARA PROBLEMAS DE PROGRAMACION LINEAL ENTERA.*
- Rodriguez Quiñones, T. A. (2014). *Solucion de problemas tipo Flow-Shop mediante algoritmos evolutivos.* 66. <http://www.bdigital.unal.edu.co/12916/>
- Ruiz, A. (2009). Herramientas Estadísticas - Comparación De Más De Dos Muestras : Anova (Parte I). *Universidad Pointificia de Comillas*, (Parte I), 1–22. Retrieved from <http://web.cortland.edu/matresearch/ANOVA-I.pdf>
- Ruíz, R., Maroto, C., Alcaraz., J. (2006). Two New Robust Genetic Algorithms for the Flowshop Scheduling Problem. *Omega*. Vol. 54, Issue 5, pp. 461-476.

SOLUCIÓN AL PROBLEMA PSFP SCHEDULING MEDIANTE UN GA

Utama, D., Setiya, d.(2019). A New Hybrid Metaheuristics Algorithm for Minimizing Energy Consumption in the Flow Shop Scheduling Problem. International Journal of Technology.

10(2),320

Vallejos Cifuentes, P. E. (2017). *Pablo Ernesto Vallejos Cifuentes*.

Wu, X., & Sun, Y. (2018). A green scheduling algorithm for flexible job shop with energy-saving measures. *Journal of Cleaner Production*, 172, 3249–3264.

<https://doi.org/10.1016/j.jclepro.2017.10.342>

Xian Liu, in *Methods and Applications of Longitudinal Data Analysis*, 2016

Zhang, M., Yan, J., Zhang, Y., & Yan, S. (2019). Optimization for energy-efficient flexible Flow Shop scheduling under time of use electricity tariffs. *Procedia CIRP*, 80, 251–256.

<https://doi.org/10.1016/j.procir.2019.01.062>.