DESDE 2013
https://repository.uaeh.edu.mx/revistas/index.php/icbi/issue/archive
Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI
ISSN: 2007-6363

Publicación Semestral Pädi Vol. 14 No. Especial 3 (2026) 291-300

Optimización de una línea de producción de chocolate mediante su simulación como un sistema Flowshop
Optimization of a chocolate production line through its simulation as a Flowshop system

N. M. Soto-Hilario [a], J. C. Seck-Tuoh-Mora [a,*], N. J. Escamilla-Serna [a], N. S. Zúñiga-Peña [a], M González-Hernández [a]

[a] *Área Académica de Ingeniería y Arquitectura, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.*

Resumen

Dentro de las empresas manufactureras de cualquier sector, es común que existan fallas que limiten la capacidad operativa de las líneas de producción dentro y fuera de la planta, provocando tiempos muertos y cuellos de botella en la línea. Sin embargo, hoy en día, gracias a la ingeniería, existen diversos métodos y técnicas fáciles de aplicar para minimizar el impacto que estas pueden tener. El objetivo de este artículo es optimizar el makespan de una línea de producción de chocolate mediante su simulación como un sistema Flowshop y aplicar un algoritmo genético para encontrar una solución bajo el análisis de varios posibles escenarios de preparación y falla de máquinas.

Palabras Clave: Línea de producción, Flowshop, Makespan, Algoritmos genéticos, Simulación

Abstract

In manufacturing companies across sectors, failures often limit the operational capacity of production lines inside and outside the plant, causing downtime and bottlenecks. However, engineering now offers various easy-to-apply methods and techniques to minimize the impact of these failures. This article aims to optimize the makespan of a chocolate production line by simulating it as a Flowshop system and applying a genetic algorithm to find a solution that considers multiple possible scenarios of machine setup and failure.

Keywords: Production Line, Flowshop, Makespan, Genetic algorithms, Simulation

1. Introducción

La industria del chocolate es un motor económico complejo que integra procesos industriales en un mercado de consumo global en constante expansión. Por ello, enfrenta problemáticas relacionadas con la calidad, la eficiencia y la optimización de sus procesos productivos.

Los científicos concuerdan en que los pueblos nativos de América del Sur fueron inicialmente atraídos por la dulzura de la pulpa del cacao, pero nadie sabe con exactitud qué condujo al descubrimiento del chocolate a partir de las semillas crudas, amargas e incomestibles. Se dice que el azúcar fue incorporado a la producción del chocolate cuando los españoles iniciaron las importaciones de caña de azúcar proveniente de las Islas Canarias y la plantaron en México (Sevilla, 2007).

La elaboración de chocolate a nivel industrial requiere una gran cantidad de controles en cada una de sus operaciones para el desarrollo correcto del producto final; además, se debe contar con formulaciones que permitan la estabilidad de la mezcla y un sabor placentero al paladar. Es por estas razones, que se hace necesaria una constante evaluación del proceso y de las formulaciones utilizadas para el mismo (Toledo, 2011). Dentro de muchas plantas en las líneas de producción de chocolate se identifican problemas como; tiempos muertos, desperdicios o cuellos de botella. Todas estas situaciones afectan la productividad y los costos operativos de las empresas. Por lo tanto, es necesario implementar estrategias de mejora mediante un análisis sistemático del proceso.

La ingeniería ofrece un gran número de metodologías y técnicas orientadas a alcanzar una excelencia operativa que permita cumplir los objetivos establecidos. Una de las

*Autor para la correspondencia: jseck@uaeh.edu.mx
Correo electrónico: so379652@uaeh.edu.mx (Naydelin Micheel Soto-Hilario), jseck@uaeh.edu.mx (Juan Carlos Seck-Tuoh-Mora), nayeli_escamilla@uaeh.edu.mx (Nayeli Jazmín Escamilla-Serna), nadia_zuniga@uaeh.edu.mx (Nadia Samantha Zúñiga-Peña), mghdez@uaeh.edu.mx (Manuel González-Hernández)

Historial del manuscrito: recibido el 03/06/2026, última versión-revisada recibida el 23/08/2026, aceptado el 18/09/2026, publicado el 06/11/2026. **DOI:** https://doi.org/10.29057/icbi.v14iEspecial3.18053

herramientas más utilizadas para abordar este tipo de problemas es la simulación, que consiste en representar un problema real mediante un modelo matemático o computacional que nos permite replicar su comportamiento lo más cerca posible de la realidad en un entorno controlado. En (Robles, 2025) se explica que no es una tecnología, sino una técnica que permite sustituir o ampliar las experiencias reales mediante experiencias guiadas que replican aspectos sustanciales del mundo real de forma interactiva.

El desarrollo de algoritmos de programación para problemas de secuenciación de tipo Flowshop ha sido de gran importancia en el ámbito empresarial, especialmente para la evolución de la industria 4.0. Los problemas de planificación involucran un conjunto de trabajos, cada uno de los cuales requiere una o varias operaciones para completarse con éxito (Mario and Setiawan, 2026), (Cubukcuoglu et al., 2025), (Ma et al., 2025). La metodología Flowshop (taller de flujo) es un modelo de organización y programación de la producción donde todas las tareas pasan en todas las maquinas, es decir, es un sistema de flujo en línea donde cada producto debe pasar por una serie de estaciones de trabajo siguiendo exactamente el mismo orden, y pretende optimizar el tiempo total de producción mediante indicadores matemáticos; makespan: tiempo total transcurrido desde que el primer lote entra a la primer maquina hasta que el ultimo sale de la última máquina, y balanceo de líneas: el tiempo de ciclo de cada estación debe ser similar para que ninguna maquina esté parada en lo que otra está saturada.La complejidad del modelo varía según sus características. Cuando la instancia del problema es determinística, los problemas de programación de trabajos son modelos de optimización combinatoria, difíciles de resolver. Por otra parte, se habla de un modelo estocástico cuando existe incertidumbre con los datos y estos presentan distribuciones probabilísticas (Pinzón and Parra, 2020).

La organización analizada en este estudio corresponde a una empresa chocolatera real, por lo que, por motivos de confidencialidad, no se proporcionará información adicional sobre ella. Los datos presentados y tiempos de procesos para este análisis se obtuvieron durante la realización de prácticas profesionales, por lo tanto, son parámetros representativos del funcionamiento real de la empresa y sirven para motivos académicos de análisis. Durante un mes se observó el proceso de la línea y se identificó un flujo lineal de la misma, sin embargo, al ser una de las líneas más antiguas dentro de la planta por la alta demanda del chocolate en sus diferentes presentaciones, a lo largo del turno surgen fallas técnicas dado que las maquinas son bastante antiguas, fallas de mantenimiento porque las maquinas son extranjeras y esta área no cuenta con el personal altamente capacitado para resolverlas, y fallas operativas por la constante rotación de personal y la falta de capacitación. La presencia de constantes interrupciones provoca una disminución de la eficiencia de la línea, reflejada en costos adicionales asociados al retrabajo, al desperdicio de insumos, de material y del producto mismo, lo cual se observa con mayor frecuencia en la línea. Los días en que no se alcanza a satisfacer la demanda acarrean desabasto o sobreinventario y un doble trabajo administrativo.

El presente trabajo tiene como objetivo analizar y mejorar la línea de producción de chocolate mediante la simulación de sistemas de tipo Flowshop con el fin de optimizar el flujo de producción, reducir tiempos y aumentar la eficiencia del sistema.

La originalidad de este estudio reside en la propuesta de una estrategia práctica y de bajo costo para la planificación de la producción, lo que demuestra que, incluso en sistemas productivos obsoletos, es factible optimizar el rendimiento operativo mediante decisiones estratégicas en la planificación, maximizando la utilización de los recursos disponibles sin requerir inversiones en infraestructura. La contribución de esta investigación consiste en presentar una alternativa distinta a los enfoques tradicionales que demandan inversión en la modernización de la maquinaria, ante los cuales no todas las empresas medianas o pequeñas disponen de los recursos necesarios. Asimismo, los resultados obtenidos proporcionarán un criterio práctico para la toma de decisiones en la programación diaria. Con la divulgación de este trabajo, las pequeñas y medianas empresas, junto con los profesionales relacionados, podrán conocer alternativas de simulación y optimización para este tipo de problemáticas.

2. Descripción del Sistema de Producción

Un sistema de producción utiliza recursos operacionales para transformar insumos, especificados como materia prima, clientes o algún producto proveniente de otro sistema, en un resultado deseado (Vargas et al., 2016). El sistema analizado corresponde a una configuración de producción de flujo lineal. El flujo lineal se produce cuando las trayectorias del flujo (estaciones de trabajo) son paralelas y el fluido (producto) fluye en una sola dirección. Este tipo de proceso desarrolla la producción de manera secuencial, continua y controlada (Sitahong, 2025).

El sistema a analizar en este trabajo corresponde a una configuración de producción lineal; cuenta con 7 puestos de trabajo y 11 personas operando durante el turno. Sin embargo, cuando las fallas demoran en ser atendidas por el área de mantenimiento, se requiere más personal. El sistema opera bajo dos turnos de 8 horas. El plano en la Figura 1 ofrece una visualización detallada de la línea de producción.

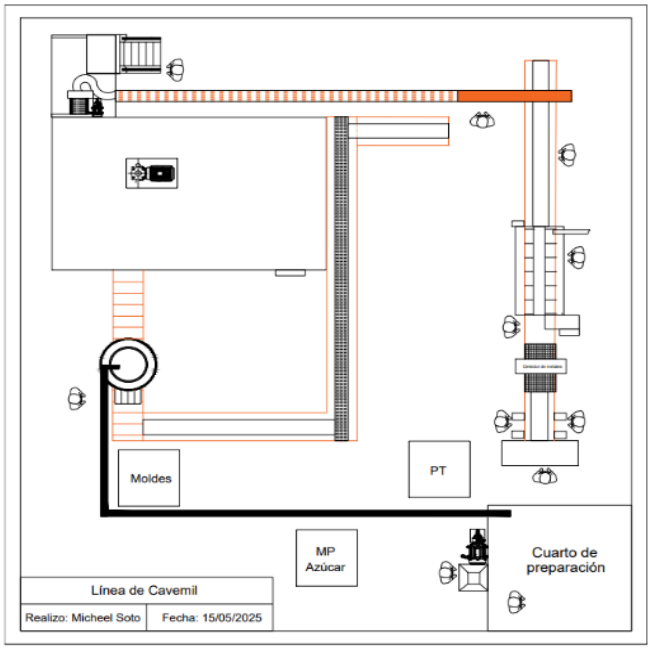


Figura 1. Plano de la línea de chocolate

La empresa ofrece tres presentaciones de chocolate de mesa; Tablilla Precissimo, Chococoa Doble 180 g y Chococoa Tapatío 540 g. La línea de chocolate es de las más antiguas de la empresa y una de las de mayor demanda, por lo que se considera importante una propuesta de mejora.

2.1. Entradas y preparación

El sistema inicia en el cuarto de preparación, donde, una vez solicitada nuestra materia prima, la mezcla de todos los ingredientes tarda 15 min en estar lista. Posteriormente, se desplaza a la máquina inyectora, que inicia el proceso. Cada una de las estaciones de la línea se encuentra conectada por medio de bandas eléctricas, y algunas de ellas cuentan con un paro de emergencia para cualquier accidente o falla que se presente durante el turno. Una vez que salen los moldes, ingresan a la cámara de refrigeración para luego ser desmoldados y colocados en la siguiente estación: la envolvedora. En estas primeras estaciones se registra un alto porcentaje de desperdicio, dado que, en primer lugar, la inyectora, al ser muy vieja, requiere ajustes y, a veces, toma más tiempo de lo normal, hasta el punto de detener la línea. Segundo, las bandas transportadoras tampoco se encuentran en perfectas condiciones y, si los moldes no se encuentran colocados de la manera correcta, se crean cuellos de botella en la banda antes de pasar por la inyectora, antes, durante o después de la cámara de refrigeración y, finalmente, al momento de desmoldar, ya que, si el trabajador tiene un exceso de fuerza, los moldes pueden caer de la banda o romperse. Esto último puede ocurrir cuando la persona a cargo de dicha actividad no cuenta con la experiencia necesaria o es nueva, ya que la planta tiene una alta rotación de personal.

2.2. Proceso de empaque

El proceso de empaque inicia con la envolvedora. Aquí las piezas son colocadas manualmente en la mesa de la máquina, las cuales irán avanzando conforme al ritmo de esta. En esta estación es donde existe cambio de maquina y película de sellado de acuerdo al lote del producto que se esté trabajando, si existió cambio de personal durante el turno y no se tuvo la capacitación correcta el tiempo de preparación de la maquina puede demorar más de 20 min generando un cuello de botella ya que si no se hizo la correcta calibración de temperaturas habrá mal sellado y provocara paros constantemente a lo largo del turno y mucho retrabajo. Una vez que esta estación se encuentre trabajando correctamente, las piezas salientes pasarán por el detector de metales y seguirán por la banda de empaque final, el cual se realiza de manera manual y para la cual se debe seguir la velocidad de la máquina envolvedora para que no se acumule el producto y no se tenga que parar nuevamente.

En la Figura 2 se observa un diagrama del proceso en el que se identifican cada una de las estaciones de trabajo y su relación entre sí. Las estaciones en color azul son aquellas en las que se ocupa a un operador de máquina. Este fue previamente capacitado para estar en ese puesto y no existirá cambio de personal a menos que sea sustituido por otro operador previamente capacitado. Como dato interesante, el personal seleccionado para operador de máquina recibe un bono extra por cada máquina que sepa operar, siempre y cuando haya cumplido con la acreditación de los cursos requeridos. Las estaciones en color verde son estaciones que llegan a ser ocupadas por auxiliares de producción general, en estas estaciones se llega a ocupar más de una persona.

Tabla 1. Tiempos de procesamiento

Producto	Maquina 1 (Cuarto de preparación) (min)	Maquina 2 (Inyectora) (min)	Maquina 3 (Cámara de refrigeración) (min)	Maquina 4 (Desmolde) (min)	Maquina 5** (Coloca) (min)	Maquina 6** (Envolvedora) (min)	Maquina 7** (Empaque) (min)
Producto 1 (Chococoa doble)	10	2+-1	1	2+-1	3+-1	0.5	2+-1
Producto 2 (Chococoa)	10	2+-1	1	2+-1	2+-1	0.5	2+-1
Producto 3 (Tablilla precisisimo)	10	2+-1	1	3+-1	1	0.5	2+-1

Las flechas en azul muestran el flujo continuo del producto y la relación entre las estaciones. Las flechas en color verde muestran la dirección de los moldes; una vez que estos están

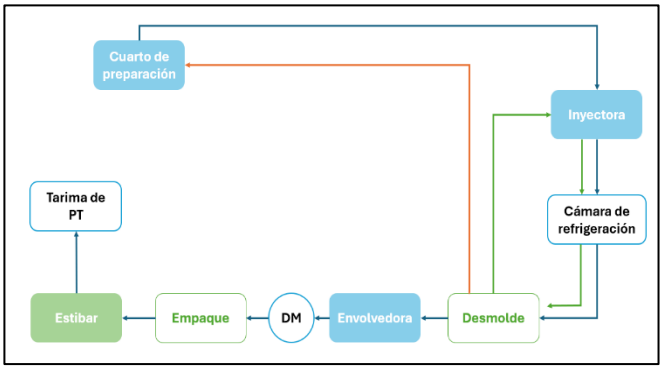


Figura 2. Diagrama del Proceso

desocupados, se colocan en otra banda transportadora que los llevará a la máquina inyectora y nuevamente entran a la cámara de refrigeración y así sucesivamente. Cuando hay un cambio de orden, se detiene la línea para cambiar los moldes. Finalmente, la flecha en color anaranjado indica que el producto que no cumple con los criterios de calidad en la estación de desmolde es reutilizado y se transporta en cajas anaranjadas al área de preparación para ser vertido en la mezcla, siempre y cuando no esté contaminado.

Dado que el proceso es el mismo para los tres productos y solo existe variación de tiempos en el cambio de etiquetas y moldes cuando se tiene que sacar más de una orden diferente, se identificó un ritmo de producción de 24 piezas (moldes de 6 piezas) por minuto, equivalente a 144 piezas de chocolate por minuto en un flujo constante sin fallas y paros prolongados.

Tabla 4. Clasificación de fallas

Tipo de falla	Probabilidad de ocurrencia	Máquina 3 (Cámara de refrigeración)
Maquinaria	65%	Maquinas desgastadas, rotura de bandas, desalineación de cadenas.
Operación	25%	Configuración incorrecta, temperaturas inestables, baja capacidad operativa.
Calidad	10%	El producto está fuera de los parámetros de calidad.

2.3. Datos del sistema a analizar

Los tiempos de procesamiento en minutos de cada producto en cada máquina se presentan en la Tabla 1. Los tiempos de procesamiento en minutos de cada producto en cada máquina son similares entre sí; la única variación observada se da en las máquinas 4 y 5. Para el producto 3, la fuerza y la velocidad del desmolde deben regularse mejor, ya que, de no ser así, el producto se quebrará con facilidad; por ello, demora más tiempo que los demás productos.

Cada producto tiene un tiempo de preparación al inicio de la jornada y al pasar de una máquina a la siguiente, que se muestra en la Tabla 2. Los tiempos de variación entre cada producto se presentan cuando hay un cambio de orden; por ende, se debe realizar el cambio de etiqueta en la envolvedora y el de mesa para el empaque del producto.

Tabla 2. Tiempos de preparación

De/A	Producto 1	Producto 2	Producto 3
Estado inicial	15 min	15 min	15 min
Producto 1	-	20 min	30 min
Producto 2	20 min	-	35 min
Producto 3	30 min	30 min	-

La probabilidad de falla en cada máquina por turno durante el proceso de elaboración de cada producto se resume en la Tabla 3, en la cual se observa que la falla con mayor porcentaje ocurre en la cámara de refrigeración, debido al ajuste constante de las bandas transportadoras dentro de ella y al cuello de botella que se genera cuando los moldes chocan al salir de la cámara.

Para simplificar el análisis, pero sin perder la aproximación realista del caso, se generalizaron los tipos y las probabilidades de falla para todas las máquinas, como se muestra en la Tabla 4. Debido a que la línea de chocolate es una de las más antiguas de la empresa, las máquinas ya no están en perfecto estado y, al no existir un plan de mantenimiento, la probabilidad de fallas aumenta.

Del mismo modo, cada vez que ocurre una falla, dependiendo de su tipo y de la máquina, se tiene un tiempo aleatorio de reparación o recompostura de la orden, cuyos límites inferior y superior se describen en la Tabla 5. En algunas máquinas el tiempo es mayor, ya que requiere la asistencia del área de mantenimiento, la cual puede encontrarse atendiendo fallas en otra línea o porque no se cuenta con todas las herramientas y se debe resolver con lo que se tiene en el momento.

Tabla 5. Tiempos de reparación

Máquina	Maquinaria (min)	Operación (min)	Calidad (min)
M_1	30-35	15-20	5-10
M_2	30-45	10.-20	5-12
M_3	10-15	2-5	5-7
M_4	2-10	2-5	3-5
M_5	30-50	5-10	2-5
M_6	30-50	5-15	10-15
M_7	5-10	3-5	5-15

Como ejemplo, pondremos el posible procesamiento del pedido (1, 2, 3), que consiste en emitir una orden de tipo 1, seguida de una de tipo 2 y, al final, otra de tipo 3.

Tabla 3. Probabilidad de falla entre cada máquina

Producto	Máquina 1 (Cuarto de preparación)	Máquina 2 (Inyectora)	Máquina 3 (Cámara de refrigeración)	Máquina 4 (Desmolde)	Máquina 5 (Coloca)	Máquina 6 (Envolvedora)	Máquina 7 (Empaque)
Producto 1	2%	4%	10%	7%	2%	6%	2%
Producto 2	2%	4%	10%	7%	3%	6%	2%
Producto 3	2%	3%	12%	8%	2%	7%	3%

El tiempo total que transcurre desde el inicio del primer trabajo en la primera máquina hasta la terminación del último trabajo en la última máquina se denomina makespan (Hojjati and Sahraeyan, 2009). Denotado como C_{max}, es el criterio de tiempo total de procesamiento de las solicitudes. En un sistema Flowshop, el objetivo es minimizar el tiempo total para maximizar la eficiencia del sistema. Minimizar el makespan equivale a maximizar la utilización de las máquinas, ya que se busca reducir los tiempos de aislamiento y de ocio (Zahmatkesh et al., 2026). Calculando el makespan con los supuestos anteriores, obtenemos los siguientes diagramas de Gantt por máquina:

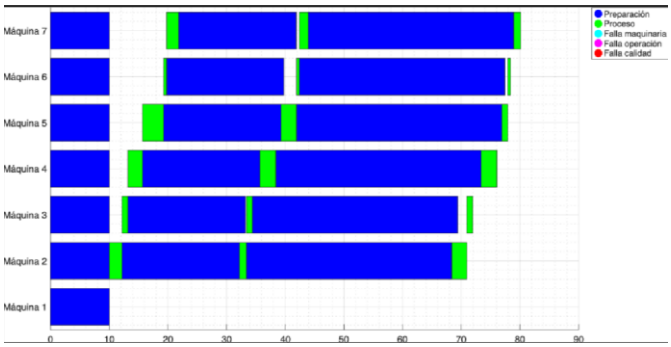


Figura 3. Ejemplo sin falla

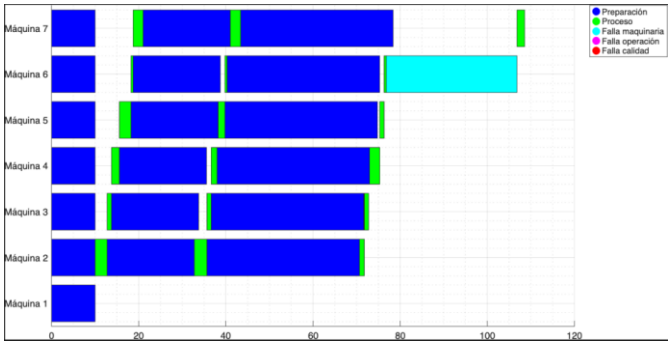


Figura 4. Ejemplo con falla

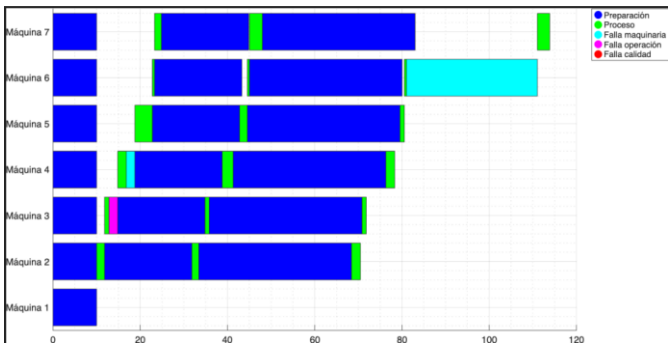


Figura 5. Ejemplo dos con falla

El makespan en cada ejemplo del mismo pedido puede variar, dadas las probabilidades de los tiempos de procesamiento en cada máquina y de los tiempos de falla. Como se observa primero en la Figura 3, el tiempo no supera los 90 min cuando todo se encuentra en orden; sin embargo, con una mínima probabilidad de falla, el tiempo de proceso aumenta considerablemente, como se observa en las Figuras 4 y 5. Algunas veces las fallas se encuentran al inicio del proceso y otras a mitad de él. Es por ello que los tiempos de reparación son diferentes: cuando demoran pocos minutos, es porque el operador detecta la falla antes de que suceda y, si es mínima, él mismo la atiende. Cuando demoran bastante tiempo, es porque no se detectó a tiempo o hubo una falla imprevista que requiere más tiempo, hasta que llega el personal de mantenimiento, revisa la máquina, identifica el problema y analiza las opciones de reparación. En esta situación de falla prolongada, el personal de la línea tiene la indicación de avanzar con el retrabajo, ya sea acomodando el producto que salió mal etiquetado, limpiando su lugar de trabajo o ayudando en el empaque de producto terminado, de tal manera que el tiempo en que se esté en paro se aproveche de la mejor manera.

Por lo tanto, al considerar la planificación en el contexto de la optimización, se puede determinar de manera eficiente el orden que mejor ejecuta las tareas en una línea de producción, considerando criterios como el tiempo, los costos y los recursos limitados para la reducción de pedidos atrasados y la minimización del tiempo total de procesamiento ante una falla imprevista (Souza, 2023).

3. Modelo formal para la programación de operaciones en la producción de órdenes de chocolate

El problema consiste en la preparación de n tipos de productos de chocolate, cada producto tiene k_i órdenes para $1 \leq i \leq n$. La producción se lleva a cabo en un sistema lineal de m máquinas. Para cada tipo de producto y cada máquina se tienen un tiempo de preparación s_{ij} que depende del tipo de producto anterior, un tiempo de procesamiento p_{ij} y varios tipos de fallas posibles.

Las fallas se clasifican en tres tipos: por falla de la máquina (f) con probabilidad pf, por falla en la calidad del producto (c) con probabilidad pc, y por falla en la operación (o) con probabilidad po. Para cada tipo de falla, se tiene un tiempo de reparación o reposición del producto rf, rc y ro, respectivamente.

Para tener una representación más realista de todo el proceso de producción, todos los tiempos (preparación, procesamiento y los diferentes tipos de fallas, así como los tiempos de reparación o reposición del producto) se modelan como variables aleatorias uniformes.

Este sistema se clasifica como un problema tipo Flowshop, en el que cada orden debe procesarse secuencialmente.
Las restricciones del problema son:

- Cada orden debe procesarse secuencialmente en todas las máquinas.
- Cada orden debe seguir la misma secuencia de máquinas.
- Cada máquina procesa a lo más un trabajo a la vez.

El objetivo del problema es minimizar el makespan, es decir, el tiempo total de finalización de la última orden programada en la última máquina.

4. Modelo computacional para la optimización de operaciones

Muchos algoritmos metaheurísticos basados en poblaciones, como el algoritmo genético (AG), la optimización por colonia de hormigas (ACO) y el algoritmo de optimización por enjambre de partículas (PSO), se han desarrollado y aplicado en las últimas décadas. Estos algoritmos generan diversas soluciones para ayudar a resolver problemas de tipo Flowshop con tiempos de preparación y fallas mediante la simulación del proceso evolutivo entre generaciones (Ouled et al., 2026). Las metaheurísticas exploran progresivamente las regiones más prometedoras del espacio de búsqueda para encontrar soluciones de alta calidad mediante reglas heurísticas bien diseñadas; estos algoritmos son muy eficaces para resolver problemas de programación (Ding and Gu, 2020). Parte de la investigación reciente se ha enfocado en abordar problemas de minimización de fallas y de mantenimiento preventivo, con el fin de optimizar el funcionamiento y el rendimiento de los procesos productivos (Marichelvam and Geetha, 2026), (Sun et al., 2025). Esto muestra que los algoritmos evolutivos y las metahuerísticas ofrecen un conjunto de herramientas idóneas para afrontar problemáticas similares a la que se analiza en este trabajo.

Una situación común de pedido en la empresa que se está tomando como referencia, es la producción de 10 órdenes para cada tipo de pedido durante una jornada de 8 horas. El objetivo es encontrar la mejor programación de las 30 órdenes que minimice el tiempo de procesamiento (o makespan), cumpliendo con las restricciones y los tiempos probabilísticos de procesamiento, preparación y fallas descritos en la sección anterior.

Debido a las propiedades del problema, para encontrar una solución cercana a la óptima se modelará el cálculo del makespan mediante un programa computacional y se aplicará un algoritmo genético para obtener una solución.

4.1. Codificación y decodificación

Cada solución se representará como una combinación de las 30 órdenes, en la que cada tipo de pedido se repite 10 veces, como se muestra en la Figura 6. Para obtener el makespan de cada solución, la combinación se leerá de izquierda a derecha para determinar el tipo de pedido a producir: primero se tomará en cuenta el tiempo de preparación, luego se recorrerá cada máquina considerando el tiempo probabilístico de procesamiento y la probabilidad de falla, y, en caso de que se produzca una posible falla, se agregará el tiempo de reparación o recompostura de la orden, de acuerdo con los parámetros establecidos en las Tablas 3-5.

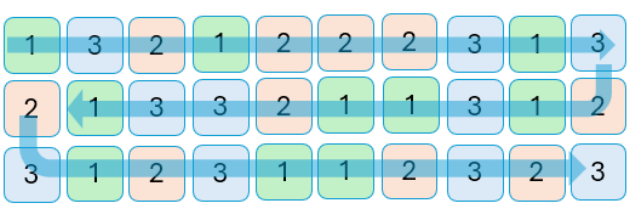


Figura 6. Ejemplo de codificación

4.2. Función objetivo probabilística

Dado que el cálculo del makespan es probabilístico, no es posible obtener un único valor de este para una misma combinación de órdenes. Para esto se utilizará una aproximación del valor promedio del makespan por el método de Monte Carlo. En estudios de optimización mediante algoritmos genéticos y el método de Monte Carlo aplicados a sistemas probabilísticos, es habitual emplear entre 20 y 50 réplicas por solución evaluada, siendo 30 un valor estándar que equilibra la precisión estadística y el costo computacional (Fu, 2015), (Al-Fandi et al., 2026). En este trabajo se tomaron 30 muestras del cómputo de este valor para cada solución analizada basándose en el Teorema del Límite Central, que establece que, para tamaños de muestra n ≥ 30, la media muestral presenta una distribución aproximadamente normal, lo que permite obtener una aproximación válida del desempeño esperado de cada solución con un costo computacional manejable (Montgomery and Runger, 2019), Law, 2015). Esto también demuestra la necesidad de utilizar un programa informático, debido a la gran cantidad de operaciones numéricas requeridas en este procedimiento.

4.3. Forma general de un algoritmo genético

Un algoritmo genético es una técnica de resolución de problemas inspirada en la evolución biológica (Goldberg, 2013). Es un intento de abstraer las características esenciales del proceso evolutivo tal como se observa en la naturaleza, con vistas a aplicarlo a sistemas de cómputo (Holland, 1992). Actualmente se utilizan como métodos de búsqueda de soluciones cercanas a la óptima que simulan la evolución natural y han sido usados con éxito en la solución de problemas de optimización combinatoria, de optimización de funciones reales y como mecanismos de aprendizaje de máquina (Kuri and Galaviz, 2002).

El uso de un AG permite una mejor aproximación a la optimización global en menos tiempo. Cuando se usa en problemas de optimización, el AG resulta menos afectado por mínimos locales que las técnicas tradicionales. Tienen como ventaja la capacidad de manipular múltiples parámetros simultáneamente y no requieren conocimientos específicos del problema para resolverlo (Arranz and Parra, 2007).

El algoritmo genético presentado en este trabajo tiene la siguiente estructura.

- Se genera una población aleatoria con $\boldsymbol{p_n}$ soluciones iniciales.
- Se obtiene el makespan promedio de cada solución a partir de una muestra de 30 observaciones de costo promedio por individuo.
- Se toman $\boldsymbol{p_e}$ soluciones elitistas que se guardan en la nueva población.
- Se aplica un método de selección por torneo para seleccionar las restantes $\boldsymbol{p_t = p_n - p_e}$ soluciones de la nueva población.

- Para cada individuo de la nueva población, se selecciona aleatoriamente otra solución del mismo conjunto y se obtienen dos nuevas soluciones mediante un cruce en dos posiciones aleatorias.

- Cada individuo se muta con probabilidad $\boldsymbol{p_m}$ intercambiando la posición de dos de sus elementos.

- Estas nuevas soluciones se reparan si tienen un número de órdenes diferente al requerido para cada tipo de pedido.

- Este proceso se repite durante n iteraciones, al final, se selecciona el individuo con el menor makespan promedio como mejor solución.

La Figura 7 muestra la estructura general del algoritmo genético propuesto. Como se puede observar, cada solución se repara si no tiene el número correcto de órdenes por pedido tras el proceso de cruce y mutación.

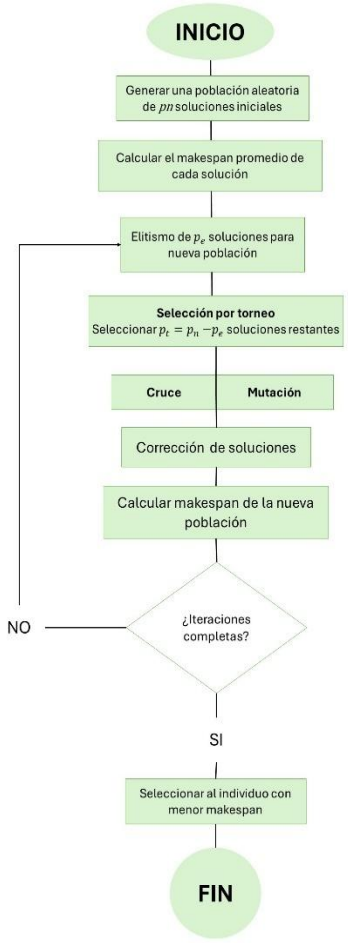


Figura 7. Diagrama de flujo del AG

4.4. Selección

La selección del algoritmo se realiza mediante el método de torneo por pares. Se toman la lista de soluciones y otra lista que es una permutación de los individuos, y se emparejan, una a una, cada pareja de individuos. Para cada una, se toman sus makespan y la solución de menor costo promedio gana el enfrentamiento. De esta manera, se guarda una nueva población que incluya a los ganadores de cada encuentro. Esto asegura que las mejores soluciones se conserven en la siguiente generación y que las menos buenas también puedan heredar su información.

4.5. Cruce

En el algoritmo genético, el cruce tiene como objetivo que los descendientes mejoren la aptitud de sus padres. Para aplicarlo, previamente se deben seleccionar dos individuos de la población. Una vez seleccionados los individuos, se combinan nuevamente para producir la descendencia que se insertará en la siguiente generación; la combinación se hace seleccionando dos posiciones aleatorias en los padres, e intercambiando las subsecuencias entre padres para obtener dos nuevos descendientes (Pose, 2000). El cruce se encarga de afinar y refinar las buenas soluciones de producción con las que ya se cuenta, es decir, de explotarlas al máximo.

El cruce de dos puntos en AG consiste en seleccionar dos puntos dentro del cromosoma e intercambiar el segmento intermedio entre ambos individuos padres. La Figura 8 muestra un ejemplo sencillo de cruce para 5 pedidos. En este caso, el punto de corte se establece después del segundo gen. Para crear a los hijos, se combinan la primera y la última parte del padre uno con el corte de la madre y viceversa para el segundo hijo.

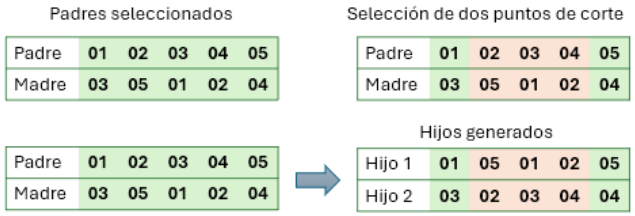


Figura 8. Ejemplo de cruce en dos puntos.

En una línea de operación, el cruce de dos puntos permite generar nuevas secuencias de órdenes de fabricación que pueden reducir el tiempo total de producción (makespan).

4.6. Corrección de soluciones

El cruce puede generar soluciones no factibles, en las que un pedido aparezca más o menos veces de lo que el proceso requiere. Para ello, cada nueva solución generada por un cruce se revisa y se registra cuántas veces aparece cada pedido. Se hacen dos listas: una con los pedidos cuyo número de órdenes es mayor que el deseado y otra con los pedidos cuyo número de órdenes es menor que el requerido. Se recorre la primera lista y, para cada pedido, se elimina una orden de la solución, intercambiándola con otra de la segunda lista seleccionada aleatoriamente. Este proceso se repite hasta que todos los pedidos tengan el número de órdenes deseado.

4.7. Mutación

El procedimiento habitual para mutar un cromosoma en un AG consiste en recorrer los genes del cromosoma uno por uno

y mutarlos con una probabilidad constante. El objetivo de la mutación es salir de una zona favorable pero no óptima, es decir, de un mínimo local (Di Rado and Podestá, 2014). Esta estrategia tiene la desventaja de que el aumento del número esperado de mutaciones puede mejorar la exploración del espacio, pero, a la vez, puede dificultar la explotación de vecindades pequeñas una vez que se encuentra una nueva zona favorable (Guzmán-Marín and Dumont-Viollaz, 2026). En este trabajo utilizaremos una variante de la mutación clásica, en la que se intercambian las posiciones de dos elementos seleccionados aleatoriamente en una solución con probabilidad. Este tipo de operación tiene la ventaja de conservar el número de órdenes por pedido y de no generar soluciones no factibles.

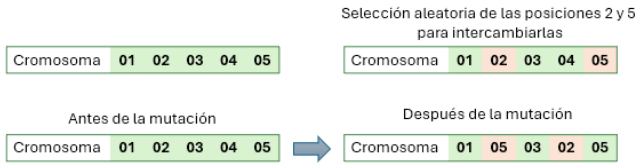


Figura 9. Ejemplo de mutación simple

Si nuestro cromosoma representara una orden de producción, como se observa en la Figura 9, y se intercambiaran dos órdenes aleatoriamente para generar una nueva secuencia, esta podría mejorar el desempeño de la línea productiva. La mutación sirve para evitar la pérdida de diversidad entre los individuos, que pueden haber convergido hacia valores comunes en toda la población. Es decir, la mutación del AG se encarga de la innovación, de modo que el algoritmo sea capaz de generar mejores soluciones cercanas a la óptima.

El criterio de paro más común de un AG consiste en repetir este proceso un número finito de iteraciones predefinidas; al final, se regresa el individuo con el mejor costo promedio.

5. Experimentación Computacional y Resultados

Una solución típica en la línea de producción de chocolate que se toma como caso de estudio consistía en una programación empírica, determinada principalmente por la experiencia del personal de supervisión y por la secuencia de llegada de las órdenes de producción. En la práctica, esto se traducía en secuencias del tipo agrupado, en las que se fabricaban todas las órdenes de un producto antes de cambiar al siguiente (por ejemplo, 1,1,1,…,1, 3,3,3,…,3, 2,2,2,…,2), con el objetivo de minimizar los tiempos de preparación asociados al cambio de moldes, etiquetas y configuraciones de la máquina envolvedora. Tomando una muestra de 30 cálculos de la función objetivo con esta solución, se obtuvo un makespan promedio de 229.63 minutos. Este valor se utilizará como referencia para compararlo con la solución calculada por el AG.

El algoritmo se implementó en Matlab 2025 en una MacBook Pro M2 con 16 GB de RAM. El AG se implementó con una población de 80 individuos, generados inicialmente de forma aleatoria, y se ejecutó durante 300 iteraciones. El algoritmo propuesto usa $\boldsymbol{p_e = 2}$ soluciones elitistas en cada iteración y una probabilidad $\boldsymbol{p_m = 0.4}$ de mutación. La ejecución del algoritmo tardó aproximadamente 80 segundos.

Los parámetros del AG se tomaron con valores similares a los utilizados en trabajos recientes que abordan sistemas de manufactura para problemáticas diversas, a fin de asegurar una ejecución con resultados aceptables en un tiempo de cómputo reducido (Schönheit and Lasch, 2026), (Wang et al., 2026), (Zheng et al., 2025).

El mejor resultado obtenido es: 1 1 1 2 2 2 2 2 2 2 2 2 2 1 1 1 1 1 1 3 3 3 3 3 3 3 3 3 3, con un makespan promedio de 199.45 minutos.

Para evaluar la eficiencia del AG propuesto, se analizó el comportamiento de la función objetivo a lo largo de las generaciones. En la Figura 10 se observa que el makespan promedio disminuye de manera pronunciada durante las primeras 40 iteraciones, lo que evidencia una rápida exploración del espacio de soluciones gracias a la diversidad de la población inicial. A partir de la iteración 50, la curva se estabiliza gracias al elitismo, que garantiza la preservación de las mejores soluciones encontradas. Finalmente, el algoritmo alcanza una fase de madurez cerca de la iteración 200, manteniendo constante el makespan óptimo promedio hasta completar las 300 iteraciones. Este makespan mejora en un 14% respecto de la solución típica de la empresa.

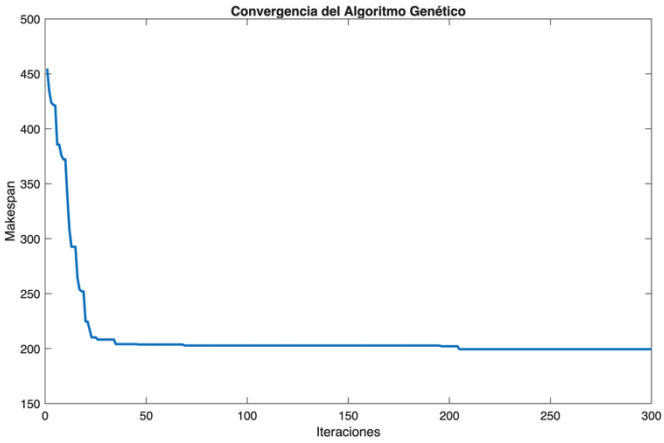


Figura 10. Curva de convergencia del algoritmo genético para la optimización del makespan a través de 300 iteraciones

En las Figuras 11, 12 y 13 se puede visualizar la distribución del programa de producción óptimo alcanzado por el AG. Se presentan tres diagramas de Gantt de la solución final calculada, secuenciada a través del sistema de producción, que muestran distintos escenarios de falla. Se detalla el flujo cronológico de los trabajos en cada una de las máquinas involucradas, lo que nos permite identificar los tiempos dedicados a las etapas de preparación y de procesamiento activo, así como a la gestión de los diferentes tipos de fallas clasificadas. En cada una de las figuras se observa cómo se equilibra la carga de trabajo entre las estaciones operativas, minimizando los tiempos muertos y optimizando el acoplamiento entre las operaciones sucesivas. Este balance permite mitigar el impacto de las interrupciones en la línea y estabilizar el makespan global en los niveles mínimos reportados en la experimentación computacional.

Es importante destacar que la implementación de esta estrategia de secuenciación optimizada no requiere inversión de capital en nueva maquinaria ni en infraestructura, lo que la hace particularmente atractiva para pequeñas y medianas empresas manufactureras con restricciones financieras. La

única necesidad es la adopción de una herramienta de soporte a la decisión basada en el algoritmo genético descrito, que puede integrarse en los sistemas de planificación de la producción existentes.

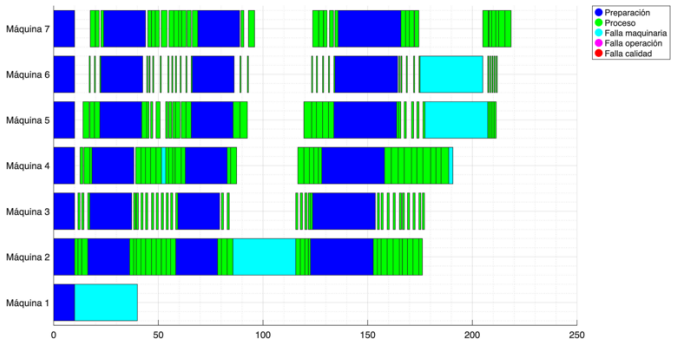


Figura 11. Diagrama de Gantt 1 de la mejor solución

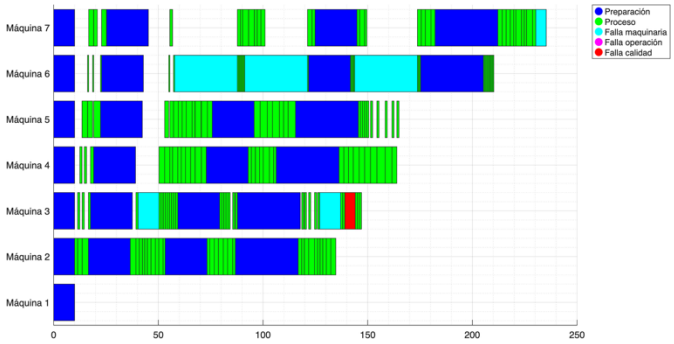


Figura 12. Diagrama de Gantt 2 de la mejor solución

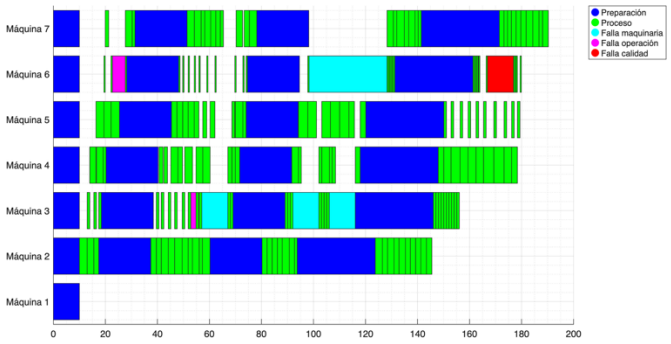


Figura 13. Diagrama de Gantt 3 de la mejor solución

6. Conclusiones

Este estudio se centró en optimizar el tiempo de producción de una línea mediante su simulación como un sistema Flowshop y se desarrolló un AG orientado a resolver la secuenciación de tareas en entornos de producción masiva. Los resultados del análisis ante posibles escenarios de falla no solo cumplieron con el objetivo de optimizar el makespan, sino que también lo estabilizaron en niveles competitivos mínimos, reduciendo significativamente los tiempos muertos en la línea, lo cual ayudará a una mejor organización de la ejecución de las tareas y reducirá el porcentaje de desperdicio a lo largo del turno. En el caso de estudio abordado, se obtuvo una reducción del 14% del makespan en comparación con una solución típica y empírica implementada por la empresa. La flexibilidad del enfoque implementado ofrece a la industria una herramienta computacional adicional viable para la toma de decisiones en tiempo real, lo que reduce el impacto económico de las interrupciones operativas.

El enfoque de optimización basado en algoritmos genéticos desarrollado en este estudio, si bien fue aplicado a un sistema de manufactura tipo flowshop con maquinaria en condiciones de obsolescencia, demuestra un alto potencial de transferencia a otros entornos industriales con restricciones similares. En particular, sectores como el de alimentos procesados, el textil, el metalmecánico o el de empacado de productos suelen operar líneas de producción secuenciales con equipos que no pueden reemplazarse por limitaciones presupuestales. En estos contextos, la posibilidad de reconfigurar la secuencia de trabajos, dosificar la carga o ajustar parámetros operativos mediante metaheurísticas, sin requerir inversión en nueva maquinaria, representa una alternativa viable y de bajo costo para mejorar indicadores como el makespan. Asimismo, la metodología puede extenderse a sistemas de servicios con flujo secuencial de tareas, como laboratorios de análisis clínicos o procesos administrativos con etapas definidas, siempre que exista variabilidad en los tiempos de proceso para gestionar la incertidumbre utilizando la simulación de Monte Carlo.

No obstante, deben reconocerse ciertas limitaciones del estudio. El modelo asume que las probabilidades de falla y los tiempos de reparación siguen distribuciones uniformes estacionarias, lo cual puede no reflejar plenamente la dinámica real de una línea de producción sujeta a desgaste acumulativo, variaciones en la calidad de la materia prima y cambios en la competencia del personal operativo. Además, el análisis se centra exclusivamente en la minimización del makespan, sin considerar otros objetivos potencialmente relevantes, como la minimización de los costos de preparación, el balanceo de carga entre máquinas o la reducción del consumo energético.

Como trabajo futuro, se propone extender el modelo hacia un enfoque multiobjetivo que integre simultáneamente la minimización del makespan, la reducción de los costos de mantenimiento y la optimización del consumo energético, empleando algoritmos evolutivos avanzados como NSGA-II o MOEA/D. Otra alternativa a investigar para calcular el número de réplicas con esta metodología consiste en utilizar un criterio de convergencia que implica realizar iteraciones hasta que el error relativo de la media sea inferior a un umbral con un nivel de confianza estadística predefinido. También es necesario realizar un diseño de experimentos y un análisis de sensibilidad para hacer una mejor selección de los parámetros del algoritmo genético, además de comparar estadísticamente diversos algoritmos evolutivos para identificar la mejor opción de optimización. Asimismo, sería valioso validar el modelo mediante un estudio de caso longitudinal en la planta real, comparando el desempeño operativo antes y después de la implementación de la secuenciación optimizada.

Declaración sobre el uso de Inteligencia Artificial generativa y tecnologías asistidas por IA

Durante la preparación del presente manuscrito, los autores utilizaron la herramienta Grammarly para la corrección gramatical y mejora de la redacción, traducción. Todo el contenido generado o sugerido por la herramienta fue revisado y editado por los autores, quienes asumen plena

responsabilidad por la exactitud, originalidad, integridad y rigor científico del contenido final del manuscrito.

Referencias

Al-Fandi, L., Abedalrohman, R., & Almasarwah, N. (2026). A simulation-based genetic algorithm approach for solving no-wait two stages elective surgery scheduling problem under uncertainty. Journal of Industrial Engineering and Management, 19(2), 443-461.

Arranz de la Peña, J., & Parra Truyol, A. (2007). Algoritmos genéticos (pp. 1–8) Recuperado de: https://d1wqtxts1xzle7.cloudfront.net/35889597

Cubukcuoglu, A., Karacan, I., Ceylan, Z., & Bulkan, S. (2025). Minimizing Makespan in Ordered Flow Shop Scheduling Using a Robust Genetic Algorithm. Processes , 13 (5), 1583. DOI: 10.3390/pr13051583

Di Rado, A., & Podestá, G. (2014). Algoritmos genéticos binarios con control de diversidad [Tesis de licenciatura]. Recuperado de: https://gestion.dc.uba.ar/media/academic/grade/thesis/podesta.pdf

Ding, H., & Gu, X. (2020). Improved particle swarm optimization algorithm based novel encoding and decoding schemes for flexible job shop scheduling problem. Computers & Operations Research, 121, 104951.

Goldberg, D. E. (2013). Genetic algorithms. Pearson Education India.

Fu, M. C. (Ed.). (2015). Handbook of simulation optimization (Vol. 216). New York: Springer.

Guzmán-Marín, B. C., & Dumont-Viollaz, A. (2026). Algoritmos genéticos: de la teoría evolutiva a la eficiencia industrial. Revista de divulgación científica iBIO, 8(2), 328-328.

Hojjati, S. M. H., & Sahraeyan, A. (2009). Minimizing makespan subject to budget limitation in hybrid flow shop. In 2009 International Conference on Computers & Industrial Engineering (pp. 18-22). IEEE CIE 2009 (pp. 18–22).

Holland, J. H. (1992). Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence. The MIT press.

Kuri, Á., & Galaviz, J. (2002). Algoritmos genéticos. Recuperado de: http://cursos.itam.mx/akuri/PUBLICA.CNS/2000/AGS.PDF?

Law, A. M. (2015). Simulation Modeling and Analysis. 5th ed. McGraw-Hill.

Ma, J., Gao, W., & Tong, W. (2025). A deep reinforcement learning assisted adaptive genetic algorithm for flexible job shop scheduling. Engineering Applications of Artificial Intelligence, 149, 110447.

Marichelvam, M. K., & Geetha, M. (2026). Solving Flow-Shop Scheduling Problems with Random Machine Breakdown and Limited Buffer Using a Pigeon-Inspired Hybrid Artificial Bee Colony Algorithm. Computers, 15(8), 508.

Mario, V. A., Alfian, A., & Setiawan, H. (2026). Production Scheduling Optimization Using The Campbell Dudek Smith (CDS) Method to Minimize Makespan in A Flow Shop Manufacturing System. Jurnal Improsci, 3(5), 435-452. DOI: 10.62885/improsci.v3i5.1130

Montgomery, D. C., & Runger, G. C. (2019). Applied statistics and probability for engineers. Wiley.

Ouled Bedhief, A., Brahmi, A., & Aissaoui, N. (2026). A comprehensive literature review for hybrid flow shop scheduling problems with dedicated machines. Operational Research, 26(4), 97.

Pinzón Castiblanco, S. J., & Parra Gómez, L. M. (2020). Secuenciación Flow Shop con Tiempos de Alistamiento Mediante Algoritmo de Enfriamiento Simulado. Encuentro Internacional De Educación En Ingeniería. DOI: 10.26507/ponencia.775

Pose, M. G. (2000). Introducción a los algoritmos genéticos. *Departamento de Tecnologías de la Información y las Comunicaciones Universidad de Coruña*. Recuperado de: https://d1wqtxts1xzle7.cloudfront.net/32640693

Sevilla, J., La elaboración del chocolate, una técnica dulce y ecológica. Técnica industrial, 2007, vol. 268, p. 47-51.

Schönheit, M., Neufeld, J. S., & Lasch, R. (2026). Towards holistic environmental awareness in distributed permutation flowshop scheduling: Integrating production and transportation emissions. Computers & Industrial Engineering, 111799.

Sitahong, A., Lu, Z., Yuan, Y., Mo, P., & J. (2025). A Review of the Expansion and Integration of Production Line Balancing Problems: From Core Issues to System Integration. Sensors (Basel, Switzerland), 25. DOI: 10.3390/s25206337

Souza, M. A. A. A. de. (2023). Minimización del tiempo de finalización en un sistema de programación de talleres de flujo flexible mediante métodos computacionales en una organización de procesamiento de minerales [Tesis de pregrado]. Recuperado de: https://dspace.sti.ufcg.edu.br/handle/riufcg/33456

Sun, C., Sang, H., Meng, L., Zhang, B., & Meng, T. (2025). Efficient multi-start gray wolf optimization algorithm for the distributed permutation flowshop scheduling problem with preventive maintenance. Complex System Modeling and Simulation, 5(2), 107-124.

Robles, F. S. (2025). Simulación de procesos industriales usando FlexSim. Ingenio y Conciencia Boletín Científico de la Escuela Superior Ciudad Sahagún, 12, 68-69.

Toledo, E. A. R. (2011). Reingeniería del proceso productivo de chocolate en barra en una industria alimentaria. Recuperado de: http://biblioteca.usac.edu.gt/tesis/08/08_1212_Q.pdf

Vargas-Hernández, JG, Muratalla-Bautista, G., & Jiménez-Castillo, M. (2016). Lean Manufacturing ¿una herramienta de mejora de un sistema de producción? Ingeniería Industrial. Actualidad y Nuevas Tendencias, V (17), 153-174. Recuperado de: https://www.redalyc.org/articulo.oa?id=215049679011

Wang, G., Wang, Y., Wu, Y., & Zhang, G. (2026). A-PPO-Based Scheduling Optimization for Phase-Oriented Complex-Product Manufacturing Workshops. Processes, 14(14), 2318.

Zahmatkesh, F., Daneshmand-Mehr, M., & Abolghasemian, M. (2026). A flow shop scheduling model considering no-wait constraints between sequential tasks. Journal of Industrial Engineering and Management Studies, 13(1), 86-96.

Zheng, F., Zhang, C., & Liu, M. (2025). Optimization of Continuous Flow-Shop Scheduling Considering Due Dates. Algorithms, 18(12)