

Problema de secuenciación de un sistema flow-shop con tiempos de procesamiento dependientes de la secuencia pasada con efecto aprendizaje

Ferraro Augusto*, Ramos Iñurrategui Lautaro, Rossit Daniel (1), Toncovich Adrián

Departamento de Ingeniería, Universidad Nacional del Sur

Av. Alem 1253 1° piso. Bahía Blanca, Argentina.

augusto.ferraro.raigada@hotmail.com - lautaroramosi@gmail.com - daniel.rossit@uns.edu.ar -
atoncovi@uns.edu.ar

(1) INMABB UNS CONICET, Departamento de Matemática - Av. Alem 1253, Bahía Blanca, Buenos Aires, Argentina

RESUMEN.

El fenómeno del efecto aprendizaje consiste en una reducción de los tiempos de producción debido a las competencias adquiridas por los operarios gracias a la repetición de operaciones. Biskup [1] investigó acerca de las circunstancias en las cuales puede observarse este efecto. Entre ellas se destacan la incorporación de empleados inexperimentados, la inversión o el recambio de máquinas y la realización de nuevos trabajos. Una manera de abordar este aprendizaje es a través de la utilización de tiempos de procesamiento dependientes de la secuencia pasada (*past sequence dependent*, en inglés). En el presente trabajo se expone un modelo de programación lineal matemático mixto entero (MILP) en el cual se plantea como objetivo la minimización del tiempo de finalización del programa de producción (*makespan*) en un sistema *flow-shop* teniendo en cuenta las particularidades previamente mencionadas. El modelo fue implementado en Pyomo (basado en Python) y el software de resolución fue Cplex. El análisis de los resultados de las experiencias se hizo mediante la comparación entre un modelo tradicional y el expuesto en el presente trabajo. Se observaron mejoras en el *makespan* al tener en cuenta el efecto aprendizaje, esto se debe al aprovechamiento de tiempos ociosos previamente inadvertidos. Esta consideración puede ser beneficiosa, ya que permitiría al programador de la producción fijar fechas de entrega más tempranas, aumentando el nivel de servicio al cliente, y disminuyendo el tiempo ocioso en los centros de trabajo.

Palabras claves: Efecto aprendizaje, dependencia de la secuencia pasada, flow-shop, scheduling

ABSTRACT

The learning effect phenomenon consists in a reduction in the production times due to the skills acquired by the operator thanks to the repetition of the operations. Biskup [1] researched about the circumstances under which this effect can be observed. Among them, the incorporation of inexperienced employees, the investment or replacement of machines for new ones and the production of new products, are the most usual. One way to approach this learning effect is through the use of past sequence dependent processing times (p-s-d). In this paper, a mixed integer linear programming model with makespan as the objective function and the features previously mentioned is presented. The model was executed in Pyomo (based on Python) using Cplex for solving it. The analysis of the experiments shows improvements in the makespan when is compared to the traditional approach (without learning effect). These improvements highlight the presence of idle time previously unnoticed. This consideration can be beneficial since it would allow the production scheduler to fix earlier due dates, to increase the customer service level, and to reduce idle time in the work centers.

Key words: Learning effect, past-sequence-dependency, flow-shop, scheduling

1. INTRODUCCIÓN

El estudio del fenómeno del aprendizaje en las operaciones de producción no es nuevo. Wright [2] fue el primero en analizar el fenómeno. En su trabajo, se muestra que, al duplicar la cantidad de unidades producidas, la cantidad de horas de mano de obra directa para producir una unidad decrece a una tasa constante, cuyo valor depende del proceso particular que se esté observando. La curva resultante, que relaciona el tiempo de producción con la cantidad de unidades producidas, llamada curva de aprendizaje, adquirió gran relevancia en años posteriores sobre todo en la Segunda Guerra Mundial para predecir costos y requerimientos de tiempo de los contratistas del gobierno estadounidense en la industria aeronáutica.

Yelle [3] realizó un estudio exhaustivo sobre el tema, recopilando y organizando todos los avances hasta ese momento. En su revisión, Yelle, presenta los modelos alternativos a la curva de Wright que reflejan con mayor precisión el fenómeno del aprendizaje, como también la estimación de parámetros para esos modelos alternativos. Por otra parte, Yelle también muestra algunas aplicaciones de la curva de aprendizaje, como la fijación de estándares de trabajo y su uso para el pronóstico de los requerimientos de mano de obra. Además, indica los estudios realizados sobre la relación de la curva de aprendizaje con el sistema de control de gestión, estándares de presupuestos y la planificación agregada, entre otros.

Es recién en 1999 cuando Biskup [1] hace foco en el efecto aprendizaje aplicado a problemas de secuenciación, en particular en los de una sola máquina. En su trabajo, demuestra que este tipo de problemas siguen siendo resolubles polinomialmente para los objetivos considerados.

En su revisión del 2008, Biskup [4] indica algunas características claves de los ambientes de producción en los que intervienen los problemas de secuenciación y que tienen un alto uso del factor humano. Entre ellas destaca la preparación de cada máquina para llevar a cabo la operación, su limpieza luego del procesamiento de un trabajo, la operación y el control de las máquinas, su mantenimiento planificado, la lectura, entendimiento e interpretación de la información de la maquinaria y todo tipo de trabajos manuales, ya sea durante el tiempo de procesamiento regular o luego para corregir errores. Biskup advierte que, en los casos en los que se procese por años la misma variedad de productos, los trabajadores sean los mismos, y las maquinarias no se modifiquen, el efecto aprendizaje alcanza su máximo nivel, y ya no se observan mejoras significativas. Sin embargo, cuando el ambiente de producción cambia, ya sea por la incorporación de empleados sin experiencia, por nuevas inversiones, recambio de maquinaria o renovación de productos, el efecto aprendizaje vuelve a tener impacto. Otros ejemplos de pequeñas modificaciones en el sistema productivo en los que puede observarse el fenómeno de efecto aprendizaje puede ser, una actualización de un software, un nuevo diseño del formato de documentos importantes como la lista de materiales o una nueva organización del depósito de piezas de repuesto.

Un aspecto clave para poder enlazar el efecto aprendizaje con los problemas de secuenciación es la forma de modelarlo. Biskup indica claramente dos opciones: el aprendizaje basado en la posición y el enfoque basado en la suma de los tiempos de procesamiento. La primera implica que el aprendizaje se produce por la cantidad de veces que los productos fueron procesados. En cambio, la segunda toma en cuenta el tiempo de procesamiento de todos los productos que ya han sido procesados. Cada uno, mantiene Biskup, tiene su propia validez.

A partir del trabajo de Biskup de 1999, se ha puesto mucha atención en la secuenciación de operaciones con efecto aprendizaje (véase [5], [6], [7], [8], [9], [10], [11], [12], [13], [14] y [15]). Todos ellos se refieren al problema de secuenciación con efecto aprendizaje en una sola máquina o en dos ofreciendo soluciones óptimas mediante reglas de secuenciación, excepto Wang y Xia que proponen un algoritmo heurístico para el caso de múltiples máquinas [7]. Rossit y otros estudiaron el impacto del efecto aprendizaje en la aplicación de subloteo en un problema flow-shop [16], describiendo el aprendizaje como un ajuste al tiempo estándar de procesamiento con un enfoque lineal, utilizado en [17].

La mayoría de los avances anteriormente descriptos no enfocan su atención en el problema flow-shop con múltiples máquinas. En aquellos casos en los que sí lo hacen, o bien no obtienen soluciones óptimas [7] o la representación del efecto aprendizaje no se asemeja fielmente a la realidad [16].

En este trabajo se presenta un modelo de programación matemática lineal mixto entero para resolver un problema de flow-shop con efecto aprendizaje, que tiene en consideración la representación del efecto aprendizaje de forma no lineal. Para ello, se aproxima la curva de aprendizaje propuesta en [11] con restricciones lineales. En la experimentación, se resuelven problemas de hasta 10 máquinas y 10 trabajos con el modelo propuesto y se comparan los resultados con el problema sin considerar el efecto aprendizaje.

2. PRESENTACIÓN DEL PROBLEMA Y DESCRIPCIÓN DEL MODELO

El problema a resolver consiste en encontrar la secuenciación óptima de N trabajos que van a ser procesados en M máquinas de forma tal, de conseguir el menor tiempo de producción total y considerando que los tiempos de producción de cada trabajo no son constantes, sino que existe el fenómeno de aprendizaje. Este fenómeno es proporcional al tiempo de producción acumulado, y dado que se trata de un problema con productos distintos entre sí, el tiempo de producción acumulado para

un producto dado, será dependiente de la secuencia pasada. Este fenómeno fue modelado por Wang y otros [11] de la siguiente forma:

$$p_{jk} = p_{jk}^* \left(\alpha l^{\sum_{i=1}^M p_{ik}^{*y_{ij}}} + \beta \right) \quad (1)$$

Donde p_{jk} es el tiempo de procesamiento real del trabajo j en la máquina k , p_{jk}^* es el tiempo de procesamiento estándar del trabajo j en la máquina k , α y β son constantes que representan la proporción del trabajo que puede ser eliminada con el efecto del aprendizaje y la que no, respectivamente. Además, α y β , deben cumplir $\alpha + \beta = 1$. La constante l ($0 < l < 1$) es una constante que indica la velocidad de aprendizaje y mientras más cercana sea a 0, mayor será la rapidez de aprendizaje. La variable y_{jj} es una variable binaria cuyo valor será uno si el trabajo j' precede al trabajo j y 0, en caso contrario.

La consecuencia de utilizar la Ecuación (1) como representación del efecto aprendizaje es que los tiempos de procesamiento reales variarán entre el tiempo de producción estándar como máximo y una proporción β de ese tiempo de procesamiento como cota inferior. Una representación gráfica de la forma en la que varía el tiempo de procesamiento real con el tiempo de producción pasado puede encontrarse en la Figura 1:

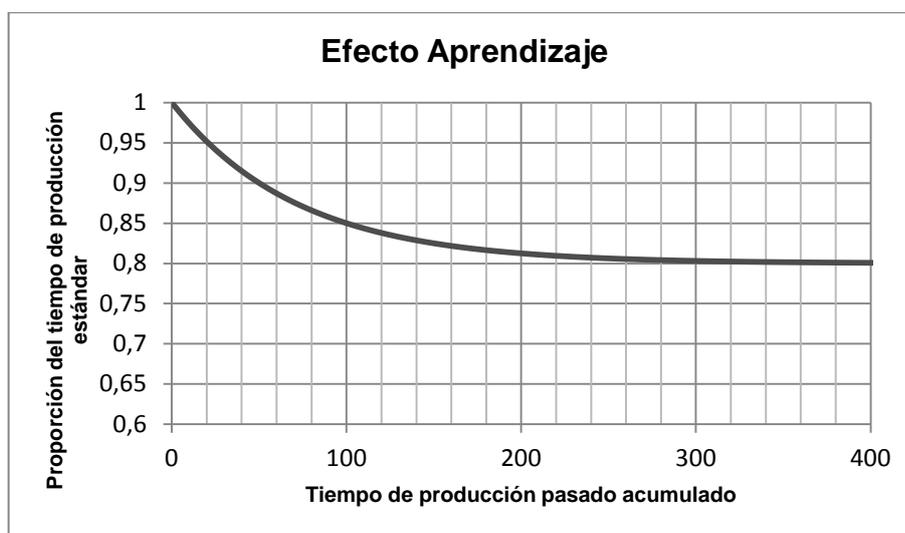


Figura 1 Curva de efecto aprendizaje ($\beta=0,8$ y $a=0,98$)

2.1. Modelo real

El modelo real para resolver el problema previamente definido se indica a continuación:

- Sets:

j : índice para los trabajos, $j = 1, 2, \dots, N$

k : índice para las máquinas, $k = 1, 2, \dots, M$

- Parámetros:

p_{jk}^* : tiempo de procesamiento estándar del trabajo j en la máquina k

G : número arbitrariamente grande

α : proporción del trabajo que presenta efecto aprendizaje

β : proporción del trabajo que no presenta efecto aprendizaje

l : coeficiente de aprendizaje

- Variables:

c_{max} : tiempo de finalización de todos los trabajos

c_{jk} : tiempo de finalización del trabajo j en la máquina k

p_{jk} : tiempo de procesamiento estándar del trabajo j en la máquina k

y_{jj} : variable binaria que toma valor 1 si el trabajo j' está antes que j y 0, en caso contrario

- Función objetivo:

$$\text{Min } z = c_{max} \quad (2)$$

- Restricciones:

$$c_{jk} - p_{jk} \geq c_{j'k} - (1 - y_{j'j})G \quad \forall j, j', k (j \neq j') \quad (3)$$

$$y_{j'j} + y_{jj'} = 1 \quad \forall j, j' (j \neq j') \quad (4)$$

$$c_{jk} \geq c_{jk-1} + p_{jk} \quad \forall j, k \neq 1 \quad (5)$$

$$c_{j1} \geq p_{j1} \quad \forall j \quad (6)$$

$$c_{max} \geq c_{jM} \quad (7)$$

$$p_{jk} = p_{jk}^* \left(\alpha l^{\sum_{i=1}^N p_{ik}^* y_{ij}} + \beta \right) \quad (8)$$

La Ecuación (2) indica que la función objetivo a minimizar es el tiempo total del programa de producción. La Ecuación (3) indica que el instante de inicio de un trabajo debe ser posterior al de uno que se secuenció antes en la misma máquina. La Ecuación (4) indica que, si un trabajo j precede a otro j' , este último no puede preceder a j . La Ecuación (5) sostiene que para que un trabajo sea procesado en una máquina, debe ser procesado previamente en la máquina anterior de la secuencia tecnológica. La Ecuación (6) expresa que el instante de finalización de todo trabajo secuenciado en la primera máquina no puede ser menor que su tiempo de procesamiento. La Ecuación (7) asegura que el tiempo de finalización del programa de producción sea el máximo de los tiempos de finalización de cada trabajo en la última máquina. La Ecuación (8) indica el valor del tiempo de procesamiento real. Este modelo matemático tiene la dificultad de que la Ecuación (8), en particular, indica una dependencia exponencial entre las variables. De esta forma el modelo se clasifica como mixto entero no lineal, por lo que no puede asegurarse que sea un problema convexo. La intención es, entonces, aproximar la curva de aprendizaje de forma tal que el modelo resultante pueda ser un modelo de programación matemática mixto entero lineal. En la siguiente sección, se explica el enfoque utilizado.

2.2. Modelo aproximado

La curva aprendizaje a aproximar es la expresada en (1), específicamente la expresión encerrada entre paréntesis, que puede expresarse de la siguiente forma:

$$p_{jk} = p_{jk}^*(y) \quad (9)$$

En la Ecuación (9), la expresión no lineal entre paréntesis en (1) está representado por y . Esta variable auxiliar y representa el efecto aprendizaje que se pretende modelar. Este efecto aprendizaje tal como se ve en (1) tiene una fórmula exponencial, que impide abordar el problema como un simple modelo mixto-entero lineal, entrando en los sistemas no lineales. Dentro de los problemas que esto genera, uno de los más importantes es el de la multimodalidad, lo cual implica la existencia de óptimos locales. En consecuencia, resolver el problema de forma óptima exige métodos de optimización adecuados que generalmente requieren un mayor esfuerzo computacional, derivando en una restricción en la capacidad de resolución de problemas flow-shop de instancias medianas y grandes. Por eso se presenta la siguiente aproximación para salvar esa complejidad, representando de forma genérica la no linealidad en cuestión en la Ecuación (10).

$$y = \alpha l^x + \beta \quad (10)$$

La Ecuación (10) presenta la expresión genérica no lineal de (1). En donde α , β y l siguen teniendo el mismo sentido de ser constantes, y la variable x indica el exponente. En nuestro caso, x reemplaza el tiempo de procesamiento acumulado en trabajos anteriores de la expresión (1). Dado que el valor de x depende de los trabajos secuenciados previos, se la modelará en términos de los valores promedios. Para ello si se requiere secuenciar N trabajos, el último trabajo tendrá un tiempo acumulado precedente de procesamiento promedio de $(N - 1)\bar{p}^*$, siendo \bar{p}^* el tiempo de procesamiento promedio de los trabajos. Por lo tanto nuestra aproximación de la función será entre $x = 0$ y $x = (N - 1) \cdot \bar{p}^*$. Es así que dicha aproximación será distinta si el problema a considerar tiene una cantidad de trabajos a secuenciar distinta.

Para aproximar la curva de aprendizaje, se considerará el siguiente razonamiento: aparentemente la Ecuación (8) debería reemplazarse taxativamente por otra expresión que sea lineal para que el modelo resultante dé lugar a un problema de programación lineal mixto entero. Sin embargo, una propuesta superadora consiste en aproximar la Ecuación (10) por el mayor valor de un conjunto de ecuaciones lineales de la siguiente manera:

$$y = \max\{y_1, y_2, y_3\} \quad (11)$$

$$y_1 = a_1 - b_1 \cdot x \quad (12)$$

$$y_2 = a_2 - b_2 \cdot x \quad (13)$$

$$y_3 = a_3 - b_3 \cdot x \quad (14)$$

Siendo $a_1 > a_2 > a_3$ y $b_1 > b_2 > b_3$. Estas constantes deberán elegirse de manera tal de poder minimizar el error producido por la aproximación. Nos ocuparemos de este tema luego. Si bien las Ecuaciones (12), (13) y (14) son lineales, la ecuación (11) continúa sin satisfacer las condiciones para

desarrollar un modelo lineal. Aun así, es posible reemplazar las cuatro ecuaciones anteriores por las siguientes tres ecuaciones (15), (16) y (17):

$$y \geq a_1 - b_1 \cdot x \quad (15)$$

$$y \geq a_2 - b_2 \cdot x \quad (16)$$

$$y \geq a_3 - b_3 \cdot x \quad (17)$$

Con estas tres ecuaciones se logra el mismo resultado que con las cuatro anteriores. En conclusión, la Ecuación (8) de nuestro modelo no lineal puede ser reemplazada por las siguientes tres restricciones lineales:

$$p_{jk} \geq p_{jk}^* \left(a_1 - b_1 \cdot \sum_{i=1}^N p_{ik}^* y_{ij} \right) \quad (18)$$

$$p_{jk} \geq p_{jk}^* \left(a_2 - b_2 \cdot \sum_{i=1}^N p_{ik}^* y_{ij} \right) \quad (19)$$

$$p_{jk} \geq p_{jk}^* \left(a_3 - b_3 \cdot \sum_{i=1}^N p_{ik}^* y_{ij} \right) \quad (20)$$

De esta manera la curva de aprendizaje podrá ser aproximada por tres funciones lineales tal como se muestra en la Figura 2:

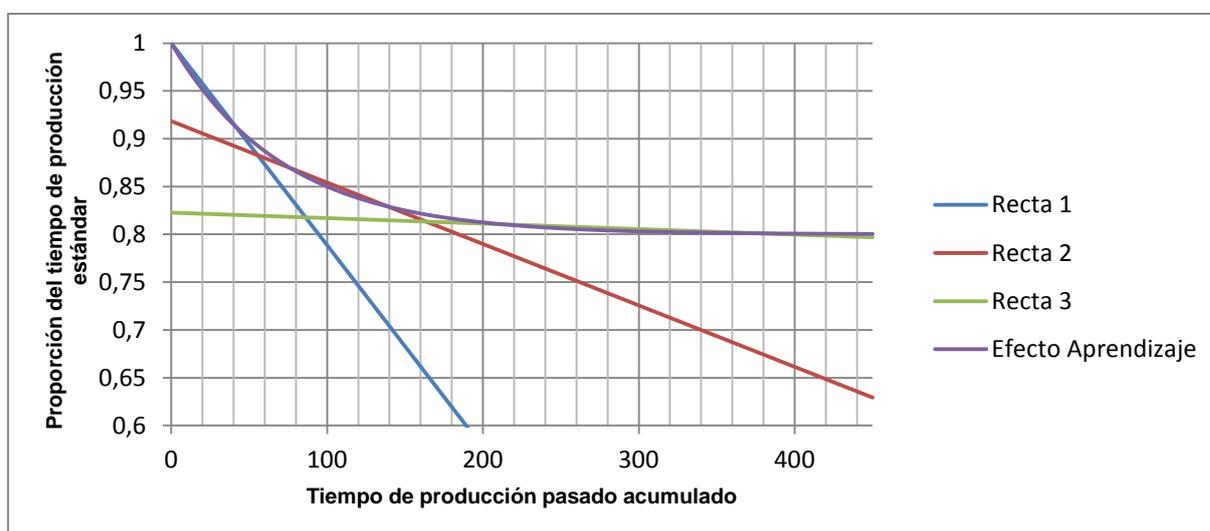


Figura 2 Aproximación de la curva de efecto aprendizaje

La determinación del número de rectas a utilizar para la aproximación de la curva de efecto aprendizaje depende de la precisión que se pretenda conseguir, para este trabajo se proponen tres rectas. Esto permite un buen grado de aproximación, así como también una correcta presentación del enfoque de aproximación.

2.3. Estimación de parámetros

La cuestión radica ahora en asignar valores a los parámetros a y b de forma de conseguir la mejor aproximación posible. En primer lugar, dado que todos los trabajos que se secuencien en la primera máquina no tienen efecto aprendizaje, la constante a_1 deberá tomar el valor 1. Para determinar el resto de los parámetros se elige aproximar la curva real de efecto aprendizaje siguiendo el criterio de mínimos cuadrados. Es decir, se elegirán a_2, a_3, b_1, b_2 y b_3 de forma tal que se minimice la siguiente expresión:

$$\sum_{i=1}^{i=3} \int_{x_{i-1}}^{x_i} (y_i - y)^2 dx \quad (21)$$

La Ecuación (21) indica la suma de tres integrales, las cuales están definidas entre dos valores de x , con $x_0 = 0$ y $x_3 = (N - 1) \cdot \bar{p}^*$. El resto de los extremos de las integrales surgen de la intersección de las rectas. La función y representa la curva de aprendizaje real y la y_i la recta que la aproxima en el tramo i . Minimizando esta expresión es posible determinar los valores óptimos de los parámetros para cada cantidad de trabajos a secuenciar considerada.

3. EXPERIMENTACIÓN Y RESULTADOS

La experimentación consistió en resolver 5 escenarios distintos para 9 instancias que surgen de la combinación de 3, 5 y 9 máquinas con 3, 5 y 9 trabajos. Cada problema fue resuelto tanto considerando efecto aprendizaje como no haciéndolo. Por lo tanto, se resolvieron en total 90 problemas. El algoritmo de resolución utilizado fue Cplex (versión 12.6.0) y el problema de programación lineal mixto entero se escribió en lenguaje Pyomo (basado en Python). Se utilizó el complemento de Excel SolverStudio desarrollado por Andrew Mason para obtener los resultados presentados en un formato tabular más conveniente [18].

3.1. Definición de parámetros

Los tiempos de procesamiento estándar se generaron considerando una distribución uniforme entre 1 y 99, según las instancias clásicas de la literatura de flow-shop [19].

Para la elección de los parámetros de la curva aprendizaje se tuvo en cuenta el trabajo realizado por Ranasinghe y Senanayake [20], en el que se desarrolló un análisis empírico del modelado de la curva de aprendizaje para la industria de la confección textil. En el mismo, se indica que este tipo de industria es intensiva en mano de obra y con cambios rápidos de producto, dos de los factores a tener en cuenta mencionados por Biskup. Cada vez que existe un cambio en el tipo del producto, indican Ranasinghe y Senanayake, es necesario que el operario lleve adelante un proceso de aprendizaje para alcanzar una velocidad de producción constante. Con la información empírica de los tiempos de producción, se evaluaron distintos modelos para la curva aprendizaje. Uno de ellos (modelo de tiempo constante), que tuvo una buena aproximación a los datos, indica que los valores de α y β son aproximadamente 0,2 y 0,8, respectivamente. A pesar de que la curva modelada en este trabajo no es la misma que la modelada en [11], las características son muy similares. En el caso del coeficiente de aprendizaje l se eligió un valor de manera tal que al procesar el primer trabajo exista un efecto aprendizaje promedio del 10%. Es decir, la mitad del efecto aprendizaje se consigue con el primer trabajo procesado.

3.2. Resultados obtenidos

A continuación, en la Tabla 1, se muestran los resultados promedio obtenidos tanto teniendo en cuenta el efecto aprendizaje como no haciéndolo.

Tabla 1 Resultados

Máquinas	Trabajos	Tiempo de finalización		
		Sin aprendizaje	Con aprendizaje	Mejora porcentual
3	3	244,0	225,1	7,7%
	5	356,6	315,0	11,7%
	10	563,0	473,4	15,9%
5	3	355,8	332,2	6,6%
	5	542,8	474,2	12,6%
	10	723,0	609,8	15,7%
10	3	675,2	634,7	6,0%
	5	755,6	671,2	11,2%
	10	1042,2	877,1	15,8%
		Tiempo de cómputo [s]		
		Sin aprendizaje	Con aprendizaje	Aumento porcentual
3	3	0,0560	0,0982	75,4%
	5	0,0264	0,0528	100,0%
	10	5,5976	15,8984	184,0%
5	3	0,0250	0,0288	15,2%
	5	0,0312	0,0616	97,4%
	10	0,9172	8,1556	789,2%
10	3	0,0232	0,0352	51,7%
	5	0,0374	0,0954	155,1%
	10	1,8662	16,3504	776,1%

4. DISCUSIÓN DE RESULTADOS Y CONCLUSIONES

La Tabla 1 muestra una mejora considerable en los tiempos de finalización al considerar el efecto aprendizaje, desde un 6% de mejora a casi 16%. Es posible observar que la reducción en el tiempo de finalización es aún mayor mientras más trabajos se procesen, mientras que no hay una dependencia clara con respecto a la cantidad de máquinas consideradas. Una posible explicación de este resultado es que, al considerar más trabajos en la secuencia, el aprendizaje se vuelve más significativo.

El tiempo de cómputo de la experimentación aumenta considerablemente en términos relativos al secuenciar trabajos con efecto aprendizaje. Sin embargo, el aumento absoluto de tiempos de cómputo es pequeño (menos de 15 segundos en el caso más desfavorable). Esto muestra, en parte el beneficio de lograr aproximar linealmente el modelo de efecto aprendizaje.

Las reducciones del tiempo total de procesamiento revelan tiempos que pueden permanecer ocultos en una planificación que no considere efectos aprendizaje.

Este trabajo introduce una forma novedosa de modelar el efecto aprendizaje para resolver problemas de secuenciación en ambientes flow-shop. Gracias a ello, fue posible observar las ganancias conseguidas por considerar este efecto y así poder tener un programa de producción más confiable y realista.

En el futuro, se propondrá un análisis robusto en la estimación de los parámetros de las rectas de aprendizaje, así como también evaluar otras posibilidades de aproximación. Por otro lado, las secuencias de trabajos en una sola máquina consiguen el menor tiempo de finalización cuando se utiliza la regla heurística SPT (*shortest processing time*) [11]. Es así que se debería estudiar una eventual correlación entre los tiempos de producción estándar de los trabajos y su orden en la secuencia óptima.

5. REFERENCIAS BIBLIOGRÁFICAS

- [1] Biskup, D. (1999). Single-machine scheduling with learning considerations. *European Journal of Operational Research*, 115(1), 173-178.
- [2] Wright, T. P. (1936). Factors affecting the cost of airplanes. *Journal of the aeronautical sciences*, 3(4), 122-128.
- [3] Yelle, L. E. (1979). The learning curve: Historical review and comprehensive survey. *Decision Sciences*, 10(2), 302-328.
- [4] Biskup, D. (2008). A state-of-the-art review on scheduling with learning effects. *European Journal of Operational Research*, 188(2), 315-329.
- [5] Mosheiov, G. (2001). Scheduling problems with a learning effect. *European Journal of Operational Research*, 132(3), 687-693.
- [6] Lee, W. C., & Wu, C. C. (2004). Minimizing total completion time in a two-machine flowshop with a learning effect. *International Journal of Production Economics*, 88(1), 85-93.
- [7] Wang, J. B., & Xia, Z. Q. (2005). Flow-shop scheduling with a learning effect. *Journal of the Operational Research Society*, 56(11), 1325-1330.
- [8] Kuo, W. H., & Yang, D. L. (2006). Minimizing the total completion time in a single-machine scheduling problem with a time-dependent learning effect. *European Journal of Operational Research*, 174(2), 1184-1190.
- [9] Koulamas, C., & Kyparisis, G. J. (2008). Single-machine scheduling problems with past-sequence-dependent setup times. *European Journal of Operational Research*, 187(3), 1045-1049.
- [10] Wang, J. B. (2008). Single-machine scheduling with past-sequence-dependent setup times and time-dependent learning effect. *Computers & Industrial Engineering*, 55(3), 584-591.
- [11] Wang, J. B., Wang, D., Wang, L. Y., Lin, L., Yin, N., & Wang, W. W. (2009). Single machine scheduling with exponential time-dependent learning effect and past-sequence-dependent setup times. *Computers & Mathematics with Applications*, 57(1), 9-16.
- [12] Ji, M., & Cheng, T. E. (2010). Scheduling with job-dependent learning effects and multiple rate-modifying activities. *Information Processing Letters*, 110(11), 460-463.
- [13] Wang, J. B., Wang, M. Z., & Ji, P. (2012). Single machine total completion time minimization scheduling with a time-dependent learning effect and deteriorating jobs. *International Journal of Systems Science*, 43(5), 861-868.
- [14] Wang, J. B., & Wang, J. J. (2014). Flowshop scheduling with a general exponential learning effect. *Computers & Operations Research*, 43, 292-308.
- [15] Soroush, H. M. (2015). Scheduling with job-dependent past-sequence-dependent setup times and job-dependent position-based learning effects on a single processor. *European Journal of Industrial Engineering*, 9(3), 277-307.
- [16] Rossit, Daniel; Frutos, Mariano; Tohmé, Fernando; Broz, Diego. (2015). "Modelo de subloteo considerando el efecto aprendizaje en configuraciones productivas flow-shop". 44 JAIIO - SII Simposio Argentino de Informática Industrial 2015. Rosario, Argentina.
- [17] Bachman, A., & Janiak, A. (2004). Scheduling jobs with position-dependent processing times. *Journal of the Operational Research Society*, 55(3), 257-264.

- [18] Mason, A. J. (2013). SolverStudio: A New tool for better optimisation and simulation modelling in Excel. *INFORMS Transactions on Education*, 14(1), 45-52.
- [19] Taillard, E. (1993). Benchmarks for basic scheduling problems. *European journal of operational research*, 64(2), 278-285.
- [20] Ranasinghe, T.; Chanaka D. S. (2016). "Empirical Analysis and Modeling of Learning Curve in The Apparel Manufacturing Industry". Proceedings of the 2016 International Conference on Industrial Engineering and Operations Management. Kuala Lumpur, Malaysia.