

SECUENCIACIÓN DE SISTEMAS DE TIPO JOB SHOP MEDIANTE APRENDIZAJE AUTOMÁTICO

Paolo Priore Moreno; Raúl Pino Diez; Alberto Gómez Gómez
Universidad de Oviedo

RESUMEN

Una forma habitual de secuenciar de modo dinámico los trabajos en los sistemas de fabricación es mediante el empleo de reglas de secuenciación. Sin embargo, el problema que presenta este método es que el comportamiento de estas reglas depende del estado del sistema, y no existe una regla que supere a las demás en todos los posibles estados que puede presentar el mismo. Por lo tanto, sería interesante usar en cada momento, la regla más adecuada. Para lograr este objetivo, en este trabajo se presentará un método de secuenciación que utiliza aprendizaje automático. Mediante esta técnica, analizando el comportamiento previo del sistema (ejemplos de entrenamiento), se obtiene un conjunto de reglas heurísticas que permite determinar la regla de secuenciación más apropiada en cada momento. Este enfoque se aplicará a una configuración de tipo Job Shop y los resultados demostrarán que se produce una mejora del comportamiento del sistema si se compara con la forma tradicional de utilizar las reglas de secuenciación.

INTRODUCCIÓN

La secuenciación de trabajos forma parte del proceso de control en un sistema de fabricación y es necesaria cuando un conjunto común de recursos debe ser compartido para fabricar una serie de productos durante el mismo período de tiempo. El objetivo de la secuenciación es la asignación eficiente de máquinas y otros recursos a los trabajos, o a las operaciones contenidas en éstos, y la determinación del momento en el cual cada uno de estos trabajos es procesado (Shaw et al. [12]).

Uno de los métodos más utilizados para resolver el problema de secuenciación es el empleo de reglas de secuenciación. Hasta la fecha, muchos investigadores han intentado evaluar el comportamiento de las reglas de secuenciación en los sistemas de fabricación, pudiéndose concluir a partir de estos estudios que el comportamiento de estas reglas depende del criterio elegido, de la configuración del sistema y de las condiciones de éste (carga global del sistema, equilibrio de las cargas en las distintas máquinas, fechas de entrega, etc.). Por ello, sería interesante cambiar las reglas de secuenciación en el momento apropiado, para la cual existen básicamente dos enfoques. En el primero, la regla de secuenciación se determina para cada período de tiempo, simulando el conjunto de reglas de secuenciación predeterminadas y eligiendo la que mejor comportamiento presente (ver por ejemplo, Wu and Wysk [14] y Ishii and Talavage [5]). En el segundo enfoque, que pertenece al campo de la inteligencia artificial (IA), se emplean un conjunto de simulaciones previas del sistema (ejemplos de entrenamiento) para determinar cuál es la mejor de las reglas en cada posible estado del sistema. Este conocimiento se utiliza posteriormente para hacer decisiones inteligentes en tiempo real (ver por ejemplo, Shaw et al. [12] y Nakasuka and Yoshida [9]).

Por otro lado, durante los últimos quince años, se ha dedicado un esfuerzo importante para desarrollar métodos basados en IA para resolver problemas de secuenciación (ver por ejemplo, Fox and Smith [4], Kusiak and Chen [6] y Shaw and Whinston [13]). El aprendizaje automático es uno de los paradigmas que pertenece al campo de la IA. El aprendizaje automático es un campo de investigación que está actualmente desarrollándose de forma notable, el cual permite estudiar métodos para desarrollar sistemas de IA que son capaces de aprender (Michalski [8]). La capacidad para aprender y mejorar es esencial para los sistemas inteligentes; sin embargo, hasta la fecha se han realizado escasos trabajos en los cuales se aplique aprendizaje automático para secuenciar tareas en sistemas de fabricación (Shaw et al. [12]). Aytug et al. [1] muestran una revisión de trabajos en los cuales se aplica aprendizaje automático para resolver el problema de secuenciación.

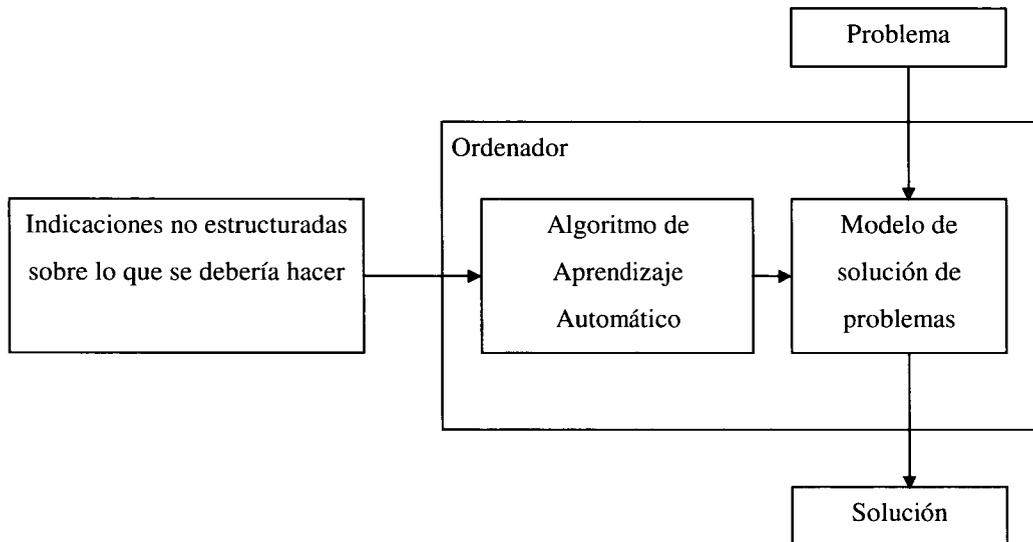
APRENDIZAJE AUTOMÁTICO

Desde un punto de vista computacional, el problema de aprendizaje es sintetizar procedimientos computables para realizar tareas de las cuales sólo se tienen algunas descripciones parciales sobre el modo

en que debería de trabajar el sistema. Una representación esquemática de lo expuesto anteriormente se muestra en la figura 1.

Un caso particular de aprendizaje automático es cuando la fuente de información poco estructurada de la cual los algoritmos de aprendizaje automático hacen uso, está dada por una colección de ejemplos (denominados de entrenamiento) que pueden ser considerados como una muestra del comportamiento del cual se quiere aprender. Dentro del aprendizaje automático, se pueden distinguir una serie de paradigmas, como son las redes neuronales, los algoritmos genéticos, el razonamiento basado en casos, etc. El paradigma empleado en este trabajo se denomina aprendizaje inductivo, en el cual el modelo de solución de problemas será un conjunto de reglas obtenidas a partir de los ejemplos de entrenamiento.

FIG. 1. ESQUEMA GENERAL DEL PROBLEMA DE APRENDIZAJE



En este caso, los ejemplos se describen mediante una serie de atributos, con un atributo especial que se denomina la clase. El objetivo del modelo de solución de problemas es poder aprender a clasificar o averiguar la clase de nuevos casos similares a aquellos que formaban el conjunto de entrenamiento, de los que conocemos todos los atributos excepto la clase. Entre las diversas formas que existen para representar el conocimiento, las más usadas son las reglas y los árboles de decisión. Las primeras tienen la siguiente forma:

$$\text{IF } (b_{i1} \geq a_1 \geq c_{i1}) \text{ AND } \dots (b_{in} \geq a_n \geq c_{in}) \text{ THEN } C_i$$

donde a_j representa el atributo j ; b_{ij} y c_{ij} definen el rango para el atributo a_j y C_i representa la clase. Por otra parte, en los árboles de decisión las ramas son usadas para representar los distintos rangos de los valores de los atributos y los nodos terminales (hojas) indican la clase a la que presumiblemente pertenece el nuevo ejemplo a clasificar.

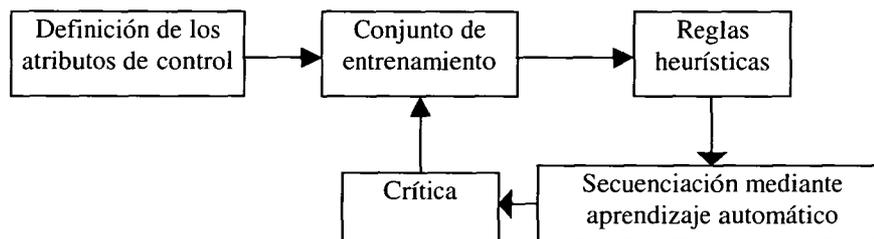
SECUENCIACIÓN MEDIANTE APRENDIZAJE AUTOMÁTICO

La metodología que se propone en este trabajo se puede dividir en cinco etapas, tal como se muestra en la figura 2. Las fases son las siguientes:

1. Definición de los atributos adecuados que identifiquen el comportamiento del sistema de fabricación. Obviamente, como no es posible tenerlos en cuenta a todos ellos, se deben de elegir los más significativos. Los atributos seleccionados se denominarán atributos de control.
2. Creación de un conjunto de ejemplos de entrenamiento utilizando diferentes valores de los atributos de control. Los valores utilizados deben ser aquellos que se presenten con más frecuencia en el sistema de fabricación a estudiar. La clase de cada ejemplo de entrenamiento se obtendrá a partir de la regla de secuenciación que genere el mejor comportamiento en el sistema. Para poder realizar lo anterior, se deberá de construir un

- modelo de simulación del sistema a estudiar, y probar para cada conjunto de valores de los atributos de control (ejemplo de entrenamiento) el comportamiento del sistema frente a las diversas reglas de secuenciación que se pretende utilizar.
3. Obtención de las reglas heurísticas por medio de un programa de aprendizaje inductivo. La forma que presentará cada una de estas reglas será la siguiente:
 IF $(b_{i1} \geq a_1 \geq c_{i1})$ AND..... $(b_{in} \geq a_n \geq c_{in})$ THEN
 regla de secuenciación
 donde a_j es el atributo de control j .
 4. Utilización de las reglas heurísticas previamente calculadas para seleccionar la regla de secuenciación más adecuada dependiendo de los valores que presenten los atributos de control en cada momento.
 5. Comparación del comportamiento del sistema de fabricación utilizando las reglas heurísticas obtenidas del programa de aprendizaje inductivo con la regla de secuenciación que globalmente se comporta mejor. Si el segundo método produce un comportamiento del sistema superior, se deberá de regresar al segundo paso.

FIG. 2. SECUENCIACIÓN MEDIANTE APRENDIZAJE AUTOMÁTICO



ESTUDIO EXPERIMENTAL

El sistema de fabricación considerado es una clásica configuración de tipo Job Shop, con cuatro centros de trabajo, que ha sido empleada por otros autores en el estudio de problemas de secuenciación (ver por ejemplo, Baker [2]). Las reglas de secuenciación utilizadas en esta configuración son: SPT (Shortest Processing Time); EDD (Earliest Due Date); MDD (Modified Job Due Date) y MOD (Modified Operation Due Date). Estas reglas ordenan los diversos trabajos que compiten por el uso de una máquina dada mediante diferentes esquemas de prioridad. A cada trabajo se le asigna un índice de prioridad y aquel que posea el menor índice será seleccionado en primer lugar. El cálculo del índice de prioridad para cada regla se realiza del siguiente modo:

$$\begin{array}{ll}
 \text{EDD} & d_i \\
 \text{SPT} & p_{ij} \\
 \text{MDD} & \max \{t + P_{ij}, d_i\} \\
 \text{MOD} & \max \{t + p_{ij}, d_{ij}\}
 \end{array}$$

donde d_i es la fecha de entrega del trabajo i ; p_{ij} es el tiempo de procesamiento de la operación j del trabajo i ; d_{ij} es la fecha de entrega de la operación j del trabajo i ; P_{ij} es el tiempo de procesamiento que queda del trabajo i al comienzo de la operación j y t es el momento en que se toma la decisión de secuenciación. La fecha de entrega del trabajo i (d_i) y de la operación j del trabajo i (d_{ij}) se calculan, de acuerdo a Baker [2], mediante las siguientes expresiones:

$$\begin{array}{l}
 d_i = t_i + p_i * F \\
 d_{ij} = d_{i,j-1} + p_{ij} * F
 \end{array}$$

donde F es un parámetro que determina la holgura de la fecha de entrega del trabajo i ; t_i es el momento en que llega el trabajo i al sistema y p_i es el tiempo de procesamiento total del trabajo i .

DEFINICIÓN DE LOS ATRIBUTOS DE CONTROL

Hasta la fecha, la mayor parte de los trabajos que estudian este tipo de problemas utilizan dos tipos de atributos de control para identificar los posibles estados del sistema. Por una parte, algunos autores emplean atributos de tipo global como la utilización global del sistema, la variabilidad en la

utilización de las diferentes máquinas, etc. (ver por ejemplo, Shaw et al. [13]). Sin embargo, otros autores (ver por ejemplo, Chiu and Yih [3] y Nakasuka and Yoshida [9]) emplean atributos de tipo local, como la holgura mínima o la holgura media de los trabajos candidatos para una máquina.

El inconveniente de los atributos de tipo global es que, a veces, es difícil de obtener los mismos valores en éstos con diferentes reglas de secuenciación en un caso de entrenamiento. Por otra parte, los atributos de tipo local presentan el problema de que es difícil medir las características del sistema en cada máquina individual, y por lo tanto de generar ejemplos de entrenamiento (Lee et al. [7]). Por todo ello, en este trabajo se empleará un conjunto de atributos de control, de tipo global, diferentes a los utilizados normalmente. La ventaja de estos atributos es que, a diferencia de los empleados por la mayor parte de los autores, tienen el mismo valor para cada una de las reglas puesto que son parámetros de entrada del sistema. Estos atributos son los siguientes:

1. Ritmo medio de llegada de los trabajos al sistema (λ)
2. Porcentaje de operaciones asignadas a la máquina i (PO_i)
3. Holgura asignada a las fechas de entrega (F)

Si el número de máquinas en el sistema fuese elevado, en vez de emplear el porcentaje de operaciones asignadas a cada máquina, se podría usar la media así como su desviación estándar.

El criterio que se utilizará para medir el comportamiento del sistema será el retraso medio de los trabajos, ya que es éste uno de los más empleados en todos los sistemas de fabricación. El retraso medio se define como:

$$\frac{\sum T_i}{N}$$

donde $T_i = \max \{0, L_i\}$; N es el número de trabajos finalizados y L_i es la diferencia entre la fecha en que se termina el trabajo y la fecha de entrega comprometida (d_i).

GENERACIÓN DE LOS EJEMPLOS DE ENTRENAMIENTO

Los ejemplos de entrenamiento necesarios para la etapa de aprendizaje se obtendrán mediante simulación, utilizando el programa Witness. Se supondrá que los trabajos llegan al sistema siguiendo una distribución de Poisson y que los tiempos de procesamiento se ajustan a una distribución exponencial con un valor medio de 1. El número de operaciones que se asignará a cada trabajo sigue una distribución uniforme entera, siendo los valores extremos del intervalo 1 y 4. La probabilidad de asignar una operación a una máquina depende de los parámetros NO_i . El ritmo de llegada variará de forma que la utilización global del sistema oscile entre el 60% y el 95%. Por otra parte, el valor del factor F estará comprendido entre 2 y 6. En total, se generarán 1000 diferentes combinaciones de los seis atributos de control de forma aleatoria, utilizándose los 100 últimos como ejemplos de test. En cada combinación de atributos, se determinarán los valores de retraso medio resultantes de emplear cada una de las cuatro reglas de secuenciación de forma aislada, y se elegirá la mejor regla como la clase para dicha combinación, formado así un ejemplo de entrenamiento.

OBTENCIÓN DE LAS REGLAS HEURÍSTICAS

Para obtener las reglas heurísticas se utilizará el programa de aprendizaje C4.5 (Quinlan [11]). El proceso de aprendizaje en C4.5 consiste en una secuencia de pasos de especialización guiados por una función de entropía de información para evaluar la pertenencia a una clase (Shaw et al. [12]). De acuerdo a la tabla 1, que muestra los resultados de la etapa de aprendizaje, se decide elegir las reglas obtenidas con 600 ejemplos de entrenamiento. El número de reglas obtenidas fue 28, de las cuales 17 y 11 corresponden, respectivamente, a la regla o clase MDD y MOD. La clase o regla por defecto es MOD y será la regla a utilizar cuando no se elija, en el momento de evaluación, ninguna de las restantes 27 reglas heurísticas. Debido a que las reglas SPT y EDD fueron elegidas como las mejores en pocos casos de entrenamiento (y en éstos, la diferencia en tardiness con respecto a las otras dos reglas era muy pequeño) se optó por no considerarlas, puesto que de esta forma el error de test era menor. El conjunto de reglas heurísticas obtenidas del programa C4.5 son las siguientes:

Regla 1: IF $F = 6$ AND $NO3 > 0.26$ THEN MDD

Regla 2: IF $F = 6$ AND $\lambda > 0.77$ AND $\lambda \leq 0.95$ THEN MDD

Regla 3: IF $F = 4$ AND $NO3 > 0.25$ AND $NO3 \leq 0.27$ AND $\lambda > 0.9$ AND $\lambda \leq 1.04$ THEN MDD

Regla 4: IF $F = 5$ AND $NO2 \leq 0.25$ AND $NO3 \leq 0.25$ AND $\lambda > 0.78$ AND $\lambda \leq 1.08$ THEN MDD

Regla 5: IF $NO3 > 0.25$ AND $NO4 > 0.25$ AND $\lambda \leq 0.82$ THEN MDD

Regla 6: IF F = 5 AND NO4 <= 0.23 THEN MDD
 Regla 7: IF F = 6 AND NO1 > 0.26 AND $\lambda > 0.77$ THEN MDD
 Regla 8: IF NO3 > 0.24 AND $\lambda <= 0.68$ THEN MDD
 Regla 9: IF F = 5 AND NO2 <= 0.27 AND NO3 <= 0.25 AND $\lambda > 0.9$ AND $\lambda <= 1.08$ THEN MDD
 Regla 10: IF F = 3 AND NO2 > 0.23 AND NO3 > 0.26 AND $\lambda <= 0.84$ THEN MDD
 Regla 11: IF F = 5 AND NO3 > 0.25 AND $\lambda <= 1.07$ THEN MDD
 Regla 12: IF F = 4 AND $\lambda > 1.01$ AND $\lambda <= 1.05$ THEN MDD
 Regla 13 IF F = 4 AND NO1 > 0.24 AND NO1 <= 0.25 AND NO2 <= 0.26 AND NO4 <= 0.26 AND $\lambda > 0.75$ AND $\lambda <= 0.99$ THEN MDD
 Regla 14: IF F = 1 AND NO3 > 0.25 AND $\lambda <= 0.71$ THEN MDD
 Regla 15: IF F = 3 AND $\lambda <= 0.66$ THEN MDD
 Regla 16: IF F = 6 AND $\lambda > 1.09$ THEN MDD
 Regla 17: IF F = 3 AND NO3 <= 0.24 AND $\lambda > 1$ THEN MDD
 Regla 18: IF F = 2 AND NO2 > 0.23 AND NO3 <= 0.25 THEN MOD
 Regla 19: IF F = 2 AND $\lambda > 0.7$ AND $\lambda <= 1.02$ THEN MOD
 Regla 20: IF F = 1 AND $\lambda > 0.71$ THEN MOD
 Regla 21: IF NO3 <= 0.25 AND NO4 > 0.23 AND $\lambda > 0.67$ AND $\lambda <= 0.78$ THEN MOD
 Regla 22 IF F = 3 AND NO3 > 0.25 AND NO3 <= 0.26 AND NO4 > 0.23 AND NO4 <= 0.25 THEN MOD
 Regla 23: IF F = 3 AND NO2 > 0.23 AND $\lambda > 0.84$ AND $\lambda <= 0.9$ THEN MOD
 Regla 24: IF F = 4 AND NO3 <= 0.25 AND $\lambda > 0.69$ AND $\lambda <= 0.99$ THEN MOD
 Regla 25: IF F = 3 AND NO3 <= 0.25 AND $\lambda > 0.66$ THEN MOD
 Regla 26: IF NO3 > 0.25 AND NO3 <= 0.27 AND NO4 <= 0.25 AND $\lambda > 1.04$ THEN MOD
 Regla 27: IF F = 6 AND NO1 <= 0.26 AND NO3 <= 0.25 AND $\lambda > 0.95$ AND $\lambda <= 1.09$ THEN MOD
 Regla 28 o regla por defecto: MOD

TABLA 1. ETAPA DE ENTRENAMIENTO

NÚMERO DE EJEMPLOS DE ENTRENAMIENTO	NÚMERO DE REGLAS	ERROR EN LOS DATOS DE ENTRENAMIENTO	ERROR EN LOS DATOS DE TEST
100	9	15%	29%
200	14	8%	25%
300	19	7%	22%
400	17	11%	22%
500	22	11%	18%
600	28	11%	16%
700	26	12%	21%
800	24	11%	17%
900	34	10%	19%

UTILIZACIÓN DE LAS REGLAS HEURÍSTICAS

A continuación, se efectuarán una serie de experimentos, en los cuales se variarán los valores de los atributos de control a lo largo del tiempo para observar cómo se comporta el sistema utilizando las reglas heurísticas obtenidas del C4.5, y se comparará con el comportamiento al emplear de forma constante una sola regla. En este último caso, sólo se utilizarán las reglas MOD y MDD puesto que eran las que proporcionaban menor retraso en los trabajos en la mayor parte de los casos de entrenamiento que se estudiaron.

Al realizar los experimentos se pudo comprobar que, en determinadas ocasiones, las reglas heurísticas no se comportaban tal como se esperaba, y eran superadas por la regla MOD o MDD empleadas de forma individual. Este fenómeno se puede explicar por el hecho de que el sistema alimentado con las reglas heurísticas reacciona de forma precipitada ante cambios en los atributos de control que sólo son transitorios en el tiempo. Por ello, se diseñará un mecanismo que permita amortiguar estos escenarios transitorios en los atributos de control que consistirá en dar un peso a cada una de las reglas de secuenciación que sean elegidas por las reglas heurísticas. Sólo cuando ese peso supere un

determinado valor limite (PL), se elegirá la regla de secuenciación. El cálculo del peso para cada regla se realizará mediante la siguiente expresión (Piramuthu et al. [10]):

$$PR_i = \sum_{j=1}^n \delta_{ij} \alpha^{n-j}$$

donde PR_i es el peso de la regla i ; δ_{ij} es un parámetro que será igual a 1 cuando la regla de secuenciación i sea seleccionada en el momento j y 0 en caso contrario; α es un número menor que 1 utilizado para dar menor peso a las reglas seleccionadas en el pasado y n es el número total de cambios que se han producido en los atributos de control desde que se ha modificado por última vez la regla de secuenciación.

TABLA 2. MECANISMO DE ASIGNACIÓN DE PESOS

NÚMERO DE CAMBIOS EN LOS ATRIBUTOS DE CONTROL	REGLA DE SECUENCIACIÓN SELECCIONADA POR LAS REGLAS HEURÍSTICAS	PR_{MOD}	PR_{MDD}	REGLA DE SECUENCIACIÓN SELECCIONADA POR EL MECANISMO PROPUESTO
1	1	1	0	ANTERIOR
2	1	1.8	0	ANTERIOR
3	3	1.44	1	ANTERIOR
4	3	1.152	1.8	ANTERIOR
5	1	1.922	1.44	ANTERIOR
6	1	2.537	1.152	ANTERIOR
7	1	3.030	0.921	MOD
8	3	0	1	MOD
9	3	0	1.8	MOD

En la tabla 2 se muestra un ejemplo en el cual se aplica este mecanismo de asignación de pesos (suponiendo $PL=3$ y $\alpha=0.8$) en un escenario en el cual se producen 9 cambios en los valores de los atributos de control. En el primer intervalo de tiempo, aunque las reglas heurísticas seleccionan la regla MOD, como el peso es inferior a tres (PL), no se debe de seleccionar inmediatamente esta regla de secuenciación, sino que se mantiene la elegida en el intervalo anterior. Se puede observar la variación de los pesos para las reglas MOD y MDD, siendo elegida la primera sólo cuando su peso sobrepasa el valor de PL (en el séptimo intervalo). A partir de ese momento se mantendrá la regla MOD hasta que el peso de la regla MDD supere el valor de PL.

Posteriormente, se realizaron una serie de experimentos, en los cuales se utilizaron diversos valores de PL para observar cuál es el valor más adecuado de éste a emplear. Asimismo, también se modificó la frecuencia en la que se producen los cambios en los atributos de control en el sistema, variando el número de piezas fabricadas con unos valores de los atributos constante (NP). Los valores de NP utilizados en los diferentes experimentos variaron de 50 a 1400. Se observó que en función de NP, el valor óptimo de PL cambiaba; sin embargo, el valor de PL igual a 5 resultó elegido en gran parte de los experimentos. Asimismo, éstos mostraron que en el 60% de los casos el enfoque propuesto fue superior que la mejor de las reglas utilizadas de forma individual, mientras que en el 33% de los casos se comportó igual. Sólo en el 7% fue peor el enfoque propuesto. Globalmente, la mejora de este enfoque fue del 8% con respecto a la regla MOD, que es la regla de secuenciación que mejor se comporta cuando se utiliza de forma individual.

CONCLUSIONES

En este trabajo se ha propuesto un nuevo enfoque para secuenciar tareas empleando aprendizaje automático. Se ha podido comprobar que, en términos generales, el comportamiento de este método es superior al de utilizar una regla de secuenciación de forma constante. Uno de los inconvenientes de emplear esta técnica es la necesidad de ejecutar un elevado número de simulaciones para generar los ejemplos de entrenamiento; sin embargo, estas simulaciones se deben de realizar sólo una vez.

Como futuras ampliaciones de este trabajo se estudiará el comportamiento de este enfoque en configuraciones de tipo Job Shop con mayor número de máquinas y en Sistemas de Fabricación Flexible, para lo cual se deberán de considerar nuevos atributos que caractericen a dichos sistemas. Asimismo, también sería interesante estudiar cómo se comporta este enfoque en el caso de que se produzcan roturas

de máquinas. Por último, si el número de piezas a fabricar con un conjunto constante de atributos de control (NP) variara de forma considerable, sería útil obtener un conjunto de reglas mediante aprendizaje inductivo que proporcionara el valor apropiado de PL en cada caso.

BIBLIOGRAFÍA

- AYTUG, H.; BHATTACHARYYA, S.; KOEHLER, G. J. AND SNOWDON, J. L. (1994): "A REVIEW OF MACHINE LEARNING IN SCHEDULING". *IEEE TRANSACTIONS ON ENGINEERING MANAGEMENT*, **41** (2), pp. 165-171.
- BAKER, K. R. (1984): "SEQUENCING RULES AND DUE-DATE ASSIGNMENTS IN A JOB SHOP". *MANAGEMENT SCIENCE*, **30** (9), pp. 1093-1104.
- CHIU, C. AND YIH, Y. (1995): "A LEARNING-BASED METHODOLOGY FOR DYNAMIC SCHEDULING IN DISTRIBUTED MANUFACTURING SYSTEMS". *INTERNATIONAL JOURNAL OF PRODUCTION RESEARCH*, **33** (11), pp. 3217-3232.
- FOX, M. S. AND SMITH, S. F. (1984): "ISIS: A KNOWLEDGE-BASED SYSTEM FOR FACTORY SCHEDULING". *EXPERT SYSTEMS*, **1** (1), pp. 25-49.
- ISHII, N. AND TALAVAGE, J. (1991): "A TRANSIENT-BASED REAL-TIME SCHEDULING ALGORITHM IN FMS". *INTERNATIONAL JOURNAL OF PRODUCTION RESEARCH*, **29** (12), pp. 2501-2520.
- KUSIAK, A. AND CHEN, M. (1988): "EXPERT SYSTEMS FOR PLANNING AND SCHEDULING MANUFACTURING SYSTEMS". *EUROPEAN JOURNAL OF OPERATIONAL RESEARCH*, **34** (2), pp. 113-130.
- LEE, C.-Y.; PIRAMUTHU, S. AND TSAI, Y.-K. (1997): "JOB SHOP SCHEDULING WITH A GENETIC ALGORITHM AND MACHINE LEARNING". *INTERNATIONAL JOURNAL OF PRODUCTION RESEARCH*, **35** (4), pp. 1171-1191.
- MICHALSKI, R. S. (1983): *A THEORY AND METHODOLOGY OF INDUCTIVE LEARNING*, IN *MACHINE LEARNING*, EDITED BY R. MICHALSKI, J. CARBONELL AND T. MITCHELL, TIOGA, PALO ALTO, CA.
- NAKASUKA, S. AND YOSHIDA, T. (1990): "DYNAMIC SCHEDULING SYSTEM UTILIZING MACHINE LEARNING AS A KNOWLEDGE ACQUISITION TOOL". *INTERNATIONAL JOURNAL OF PRODUCTION RESEARCH*, **30** (2), pp. 411-431.
- PIRAMUTHU, S.; RAMAN, N. AND SHAW, M. J. (1994): "LEARNING-BASED SCHEDULING IN A FLEXIBLE MANUFACTURING FLOW LINE". *IEEE TRANSACTIONS ON ENGINEERING MANAGEMENT*, **41** (2), pp. 172-182.
- QUINLAN, J. R. (1993): *C4.5: PROGRAMS FOR MACHINE LEARNING*. MORGAN KAUFMANN PUBLISHERS, SAN MATEO.
- SHAW, M. J.; PARK, S. AND RAMAN, N. (1992): "INTELLIGENT SCHEDULING WITH MACHINE LEARNING CAPABILITIES: THE INDUCTION OF SCHEDULING KNOWLEDGE". *IIE TRANSACTIONS*, **24** (2), pp. 156-168.
- SHAW, M. J. AND WHINSTON, A. (1989): "AN ARTIFICIAL INTELLIGENCE APPROACH TO SCHEDULING IN FLEXIBLE MANUFACTURING SYSTEMS". *IIE TRANSACTIONS*, **21** (2), pp. 70-183.
- WU, S. D. AND WYSK, R. A. (1989): "AN APPLICATION OF DISCRETE-EVENT SIMULATION TO ON-LINE CONTROL AND SCHEDULING IN FLEXIBLE MANUFACTURING". *INTERNATIONAL JOURNAL OF PRODUCTION RESEARCH*, **27** (9), pp. 1603-1623