

# Calibración de un algoritmo ACO para el cálculo de itinerarios alternativos en sistemas de e-learning

J. M. Marquez<sup>1</sup>, L. Gonzalez-Abril<sup>2</sup>, F. Velasco<sup>2</sup>, J. A. Ortega<sup>3</sup>

<sup>1</sup> Simosa IT, Campus Tecnológico Palmas Altas. Edificio B, Sevilla. jose.marquez@simosait.abengoa.com

<sup>2</sup> Dep. de Economía Aplicada, Univ. de Sevilla. {velasco,luisgon}@us.es

<sup>3</sup> Dep. de Lenguajes y Sistemas Informáticos, Univ. de Sevilla, ortega@lsi.us.es

## Abstract

Este artículo describe el proceso de calibración de un algoritmo ACO para el cálculo de itinerarios alternativos en sistemas de e-learning. Se pretende estudiar el comportamiento de un algoritmo ACO para la definición de itinerarios de aprendizaje, definidos en un grafo. Puesto que el caso de estudio no está sujeto a ningún modelo estadístico conocido y depende de las calificaciones obtenidas por cada alumno, para evitar la experimentación con personas se ha propuesto un modelo experimental basado en la definición de perfiles de usuario, a partir de la experiencia en cursos anteriores, y la ejecución de un gran número de tests que sirvan para predecir el comportamiento del algoritmo en determinadas situaciones. Este artículo muestra como a través de la calibración de los parámetros del algoritmo puede definirse un comportamiento más o menos estable del mismo, pudiéndose ajustar el algoritmo a los requisitos del equipo pedagógico.

ración de itinerarios formativos orientados a competencias en lugar de a recursos educativos. Sin embargo, aunque las competencias adquiridas con varios recursos educativos sean las mismas, la diferencia del grado de conocimientos y el tiempo que es necesario emplear para asimilarlos depende en gran medida de factores como la calidad de estos recursos, de su adaptación al nivel de conocimientos de los alumnos (a su zona de andamiaje) y del orden en que se realizan. Es decir, dependen en gran medida del itinerario de aprendizaje seguido por el alumno. Además, también depende del momento, puesto que un determinado orden o conjunto de recursos educativos puede mostrarse eficaz durante un determinado periodo de tiempo pero perder valor en el futuro o aparecer nuevos recursos que mejoren el rendimiento de los participantes, por lo que es necesario un sistema que pueda evolucionar y seleccionar la mejor ruta en cada momento. Un sistema con itinerarios de aprendizaje adaptativos.

## 1 Introducción

El Problema de las Rutas de Aprendizaje consiste en averiguar la mejor secuencia de cursos que necesita realizar un alumno para adquirir un conjunto de competencias de forma que se maximice el conocimiento adquirido y se minimice el tiempo empleado.

Imagine que se cuenta con una base de datos de competencias y sus relaciones con una serie de recursos educativos que pueden facilitarnos la adquisición de dichas competencias. Este es el fin de los estándares IEEE Reusable CompetencyDefinitions[1] y IEEE Simple Reusable CompetencyMap[2] encargados de la definición de competencias y de un mapa que las relacione entre sí, permitiendo jerarquías de competencias y competencias afines.

Partiendo de esta base de datos que nos relaciona competencias con recursos educativos podrían definirse itinerarios formativos que posibiliten la adquisición de un determinado número de competencias, facilitando la elabo-

## 2 Escenario

Sea una empresa que desea preparar un itinerario formativo para la promoción de trabajadores de cara a ocupar puestos de mayor responsabilidad. Estos puestos requieren de un conjunto de habilidades y conocimientos (competencias) que los aspirantes han de adquirir para optar al mismo, y para ello es necesario superar con éxito una serie de cursos de formación específicos. La empresa desea que este itinerario formativo pueda repetirse en distintas ediciones y pueda adaptarse dinámicamente a las necesidades cambiantes que pueden darse en cada edición, contribuyendo a la mejora de la formación de los alumnos participantes.

La adquisición de una determinada competencia requiere la superación de un determinado conjunto de cursos, a menudo en un determinado orden. Igualmente, las competencias necesarias para el puesto pueden ser interdependientes y requerir cierto orden. No obstante las restricciones de ordenación son opcionales y podría suceder que las competencias necesarias fueran independientes entre sí y no importase el orden en el que fueran adquiridas. Partiendo



de la hipótesis de que un mismo itinerario de aprendizaje no siempre es el más adecuado para poblaciones de alumnos diferentes, la empresa desea diseñar un itinerario formativo que permita diferentes rutas alternativas, de forma que existan itinerarios especialmente adaptados para alumnos con necesidades especiales (por ejemplo, hándicaps visuales o sonoros) y con diferentes ritmos de aprendizaje, de forma que el sistema gestor de aprendizaje escoja la mejor ruta en cada momento y se maximice la calificación final de los trabajadores así como se minimice el tiempo dedicado a la formación.

## 2.1 Representación

Para facilitar la consecución de los objetivos planteados en el escenario anterior, se propone el uso de un grafo con restricciones de navegación para el diseño del itinerario de aprendizaje por el equipo pedagógico (Figura 1), en el que se representen los diferentes caminos de aprendizaje alternativos.

En el grafo de la Figura 1 se distinguen tres tipos de entidades: nodos, arcos y restricciones de navegación.

Los nodos representan cursos y las aristas o arcos dirigidos que los unen representan las posibles transiciones entre un curso y el siguiente. Cada arista es ponderada con un peso que designa la probabilidad de ser el curso destino de la arista el que sea entregado al alumno. Así, las aristas con una probabilidad mayor serán elegidas con mayor frecuencia.

Las restricciones de navegación se representan con una flecha curva etiquetada con un símbolo & (restricción AND) o + (restricción OR). Las restricciones posibles se muestran en la Tabla 1. Todas las restricciones afectan a todos los arcos de salida del nodo para el que se definen.

Tabla 1: Restricciones de navegación

Tipo	Representación	Descripción	Sintaxis	Secuencias
AND		Restricción de Navegación obligatoria con orden específico.	$A \& (B,C)$	$A \rightarrow B \rightarrow C$
AND		Restricción de Navegación obligatoria sin importar el orden	$A*(B,C)$	$A \rightarrow B \rightarrow C$ $A \rightarrow C \rightarrow B$
OR		Restricción de Navegación opcional.	$A (B,C)$	$A \rightarrow B$ $A \rightarrow C$
LINK		Enlace directo.	$A,B$	$A \rightarrow B$

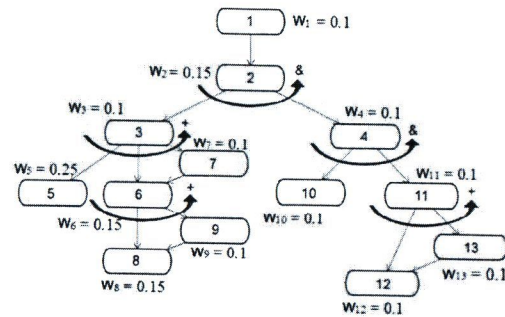


Figura 1: Grafo de Itinerarios de Aprendizaje (GIA)

La restricción AND indica que las transiciones han de realizarse en el orden establecido, por lo que para esta restricción el orden en el que se indican los nodos destinos es especialmente importante, a diferencia de la restricción OR en la que el orden en que se indiquen no tiene importancia.

La restricción de navegación AND es útil para delimitar secuencias obligatorias, no sólo de cursos, sino de bloques de cursos, por lo que puede ser usada por el equipo pedagógico para separar los conjuntos de cursos que forman al alumno para la adquisición de una determinada competencia.

La restricción de navegación OR sirve para definir caminos alternativos en función de las necesidades identificadas por el equipo de formación (caminos de refuerzo, caminos especialmente indicados para alumnos con ritmos de aprendizaje diferente, caminos de profundización, etc.)

El itinerario propuesto en la Figura 1 podría representar tres grandes competencias A, B y C, determinadas por la primera relación AND que relaciona el nodo 2 con los nodos destino 3 y 4. De la misma forma la relación &(10,11) puede identificar dos bloques dentro de la competencia C (Figura 2). En este caso se pretende definir en el grafo itinerarios alternativos al habitual formado por la secuencia ordenada de nodos 1, 2, 3, 5, 4, 10, 11, 12. De esta forma según criterio del equipo pedagógico pueden definirse itinerarios de refuerzo a diferentes niveles, mediante relaciones OR, por ejemplo en los nodos 3, 6 y 11.

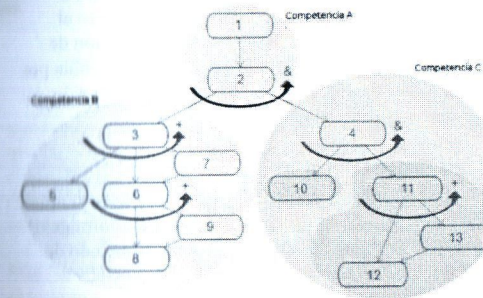


Figura 2: Identificación de competencias en el GIA

El GIA puede transformarse siguiendo las reglas de transformación indicadas en trabajos previos [3] en un grafo dirigido como el de la Figura 3.

## 3 Adaptación del mejor itinerario

El problema de encontrar el camino más corto consiste en encontrar un camino entre dos nodos de tal manera que la suma de los pesos de las aristas que lo constituyen sea mínima.

El algoritmo de Dijkstra[4] determina el camino más corto desde un vértice origen al resto de vértices en un grafo ponderado. El mecanismo de este algoritmo consiste en ir explorando todos los caminos más cortos que parten del vértice origen y que llevan a todos los demás vértices; cuando se obtiene el camino más corto desde el vértice origen al resto de vértices que componen el grafo, el algoritmo se detiene.

En nuestro problema, los vértices representan los cursos, pero en cambio, el peso de las aristas depende del concepto de distancia que se desee aplicar. Las aristas expresan la posibilidad de transición de un curso A a otro B,

pero el peso de la misma podría asociarse a diversos conceptos relacionados con el nodo destino:

- La duración media del curso (tiempo medio empleado por los alumnos en realizar el curso destino).
- Peso pedagógico del curso.
- Nivel de dificultad del curso.
- Calificación media obtenida por los participantes en el curso.

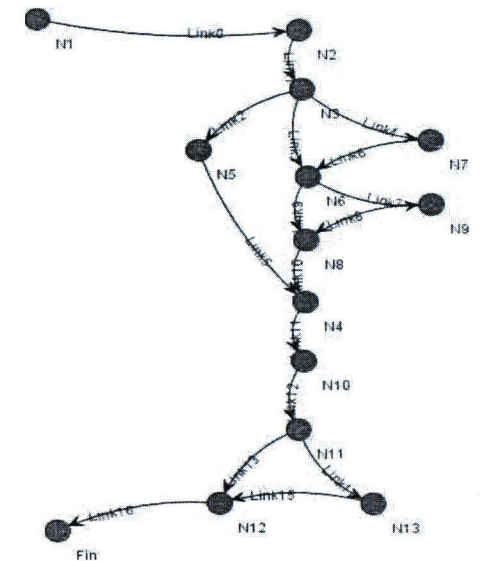


Figura 3: GIA una vez eliminadas las restricciones de navegación

Para cualquiera de estos conceptos de distancia, el algoritmo de Dijkstra obtiene el camino de menor distancia de forma determinista. En cambio en el problema de las rutas de aprendizaje, esta distancia no es un valor determinado, sino que depende de los resultados obtenidos por los alumnos participantes en una edición así como de valores históricos a partir de los cuales inferir conocimiento.

Valigiani et al. [5] comenzaron a aplicar técnicas ACO a entornos de e-learning, gracias a que el material educativo disponible en internet puede ser organizado en forma de grafos que relacionan las diferentes unidades didácticas. Al igual que en [5], nuestra propuesta de solución



también se basa en técnicas ACO que permitan al sistema recomendar la mejor opción en función de los resultados obtenidos por los alumnos. En nuestra aproximación, cada estudiante representa el papel de una de las hormigas virtuales empleadas por las técnicas ACO, moviéndose en el grafo, desde el nodo inicial, siguiendo la dirección marcada por cada arista y liberando feromonas en los arcos recorridos hasta llegar al nodo final. A diferencia de las feromonas positivas y negativas de valor fijo, propuestas en [5], en nuestra solución utilizaremos una cantidad de feromonas a depositar variable, que será función de la calificación obtenida por el alumno en el curso o cursos anteriores.

La cantidad de feromonas a depositar por el alumno  $k$  en el arco  $L_{ij}$  en función de la calificación obtenida,  $\varepsilon_j$ , trasladada a la escala  $[0,1]$ , en el curso del nodo  $j$ , vendrá determinada por la siguiente expresión:

$$\Phi_{ij}^k(\varepsilon) = \begin{cases} -(1 - \varepsilon_j^k)\varphi - \omega_3 \left(\frac{m_i}{M} - \varepsilon_j^k\right) & \text{si } \varepsilon_j^k < \frac{m_i}{M} \\ \varepsilon_j^k \varphi + \omega_3 \left(\varepsilon_j^k - \frac{m_i}{M}\right) & \text{si } \varepsilon_j^k \geq \frac{m_i}{M} \end{cases}$$

En la ecuación anterior,  $\varphi$  representa una constante con el valor unitario de una feromona y  $\omega_3$  es una constante de calibración del sistema. La cantidad de feromonas a depositar depende por tanto de la calificación obtenida por el alumno, así como del mínimo deseado,  $m_i$ , que puede ser definido para cada curso.

El algoritmo utilizado se basa en la utilización de las acciones de los alumnos aplicando la meta-heurística ACO, de forma que los alumnos actúan como las hormigas utilizadas en los algoritmos ACO modificando la probabilidad  $a_{ij}$ , correspondiente a la probabilidad de decisión del arco  $L_{ij}$  definida en [6], mediante el depósito paso a paso de  $\Phi$  feromonas adicionales en cada arco recorrido.

Al igual que en [7] nuestra aproximación también estudia la utilización de pesos, definidos por el equipo pedagógico que diseña el itinerario, y definidos en el GIA.

Con estas consideraciones se define el concepto de distancia de nuestro problema, expresado como función de ajuste de cada arco:

$$f_{ij} = \omega_1 W_j P_{ij} + \omega_2 \Phi_{ij}$$

donde  $\omega_1$  y  $\omega_2$  son constantes de calibración que permiten ajustar el sistema durante la experimentación;  $W_j$  es el peso asignado por el equipo pedagógico,  $P_{ij}$  es el factor de idoneidad del arco  $L_{ij}$  y  $\Phi_{ij}$  es la suma de feromonas depositadas en él:

$$\Phi_{ij} = \sum_{k=1}^n \Phi_{ij}^k(\varepsilon)$$

Mientras que el peso pedagógico,  $W_j$ , es definido en tiempo de diseño del itinerario, para el factor de idoneidad

poden utilizarse varias aproximaciones, desde la calificación media en el nodo  $j$  de aquellos alumnos que transitaron el arco  $L_{ij}$  hasta el uso de Redes Bayesianas.

Como en todos los algoritmos ACO, las feromonas no son persistentes en los arcos, sino que se evaporan con el tiempo (medido en nuestro caso en cambios de nodo de una hormiga) siendo la ecuación que expresa la cantidad de feromonas en un arco en función del tiempo:

$$\Phi_{ij}(t+1) = (1 - \rho)\Phi_{ij}(t) + \theta_{final}(\varepsilon)$$

donde  $\Phi_{ij}(t+1)$  representa la cantidad de feromonas existentes en el arco  $L_{ij}$  en el instante  $t+1$  y  $\rho$  es la tasa de evaporación. Mientras que la deposición de las feromonas por el recorrido de los alumnos se realiza paso a paso, la evaporación de las feromonas depositadas por éstos se lleva a cabo una vez que el grupo de alumnos ha completado el itinerario. El término  $\theta_{final}(\varepsilon)$  representa la variación de feromonas dependientes de la calificación final obtenida por el alumno  $k$ , y se deposita sólo en los arcos del recorrido seguido, una vez completado el recorrido.

#### 4 Experimentación

El método de prueba usado consiste en la simulación del comportamiento de los alumnos por las hormigas del algoritmo ACO, de forma que aplicando el método de Monte Carlo pueda tanto generarse un estado inicial y a partir de él comprobarse la capacidad de la solución propuesta para adaptar de forma autónoma el itinerario en función de las calificaciones medias obtenidas en cada nodo.

Se utiliza el algoritmo ASALI (*AntSystem for Adaptive Learning Itineraries*) desarrollado por los autores, en sucesivas iteraciones, guardando el estado al final de cada iteración en una hoja de cálculo, para comprobar la evolución del itinerario en cada iteración. Para tal fin se ha desarrollado un *framework* que procesa los GIA y ejecuta el algoritmo sobre una colonia de hormigas de tamaño configurable, así como una aplicación con interfaz gráfica que facilita la calibración del sistema, ejecuta el algoritmo y recolecta y almacena los resultados en hojas de cálculo (Figura 4). El objetivo final del algoritmo es maximizar el resultado de la función beneficio  $B^k$  que nos devuelve la calificación media ponderada con el peso total del recorrido realizado por la hormiga  $k$ . El beneficio obtenido por la hormiga  $k$  en su recorrido es:

$$B^k = \frac{\sum_i^n \bar{\varepsilon}_i}{\sum_i^n W_i}$$

donde  $\bar{\varepsilon}_i \in R^k$  y su grado de entrada,  $g_{in}(i)$ , es mayor que cero. Se obtiene mediante la división de la suma de las calificaciones medias de cada nodo perteneciente al recorrido (excepto el nodo inicial) entre la suma de los pesos de los nodos de este recorrido (a excepción del peso del primer nodo).




Figura 4: Aplicación desarrollada para la experimentación

Para simular los diferentes perfiles de alumnos utilizaremos un generador de números pseudo-aleatorios, que ha sido modificado para generar números de forma aleatoria dentro de un rango dado con una probabilidad determinada. Se utiliza una distribución de probabilidad normal.

Se utilizan tres perfiles diferentes de alumnos, High, Medium y Low, relacionados respectivamente con alumnos de alto, medio y bajo rendimiento académico (en función exclusivamente de sus calificaciones obtenidas), considerándose el rendimiento alto cuando el 95% de sus calificaciones están comprendidas entre un 7 y un 9 sobre un máximo de 10; medio, cuando el 95% de las calificaciones caen en el intervalo [5,7] y bajo cuando el 95% de sus calificaciones se encuentran en el intervalo [3,5].

Durante la experimentación se prueba el comportamiento del algoritmo ASALI con diferentes proporciones de hormigas virtuales de cada perfil, estudiando el comportamiento con la variación de los parámetros  $\alpha$ ,  $\beta$ ,  $\omega_1$ ,  $\omega_2$ ,  $\omega_3$  y  $\rho$ .

En primer lugar se estudia la estrategia de ponderación del grafo: equiponderación vs ponderación por peso pedagógico, utilizando en ambos casos los mismos valores para los parámetros de calibración, escogidos según los valores recomendados para el algoritmo AntSystem por Marco Dorigo[6]:  $\alpha=2$ ,  $\beta=5$ ,  $\omega_1=0.5$ ,  $\omega_2=0.5$  y  $\omega_3=0.5$ .

Para analizar la estrategia de ponderación se utiliza el grafo de la Figura 5, con el fin de estudiar la rapidez de bloqueo y la influencia de los pesos en el algoritmo.

Tras este estudio se realiza el estudio de calibración, utilizando el grafo de la Figura 3 analizando el comportamiento del algoritmo según los valores de los parámetros indicados.




Figura 5: Grafo utilizado para el análisis de la estrategia de ponderación

#### 5 Resultados

Los resultados obtenidos revelan que utilizando, la estrategia de equiponderación, el camino elegido es aleatorio, pero termina llevando al algoritmo a una situación de bloqueo, a partir de la cual, independientemente de la calificación obtenida por un alumno, siempre será encaminado por el camino elegido. La situación de bloqueo se presenta ligeramente antes cuanto mayor es la proporción de alumnos de perfil High o Medium, siendo ligeramente más tardío (se necesitan más alumnos) cuando la proporción de alumnos de perfil Low es predominante (Figura 6) y no depende del número de opciones posibles en un nodo de decisión.




Figura 6: Comparativa de la evolución de elecciones en los caminos que producen bloqueo según perfil

Para la estrategia de baremación según peso pedagógico se observa un bloqueo ligeramente más rápido al observado en la estrategia de equiponderación, observándose una característica interesante en los experimentos realizados: el camino que pasa por el nodo de mayor peso acaba siendo el que causa el bloqueo en el 90% de las veces, mientras que asignando el mismo peso a todos los nodos, todos



las opciones tienden a ser los bloqueantes en el mismo número de veces. Además también se favorece, aunque en menor medida, los caminos cortos (con menor número de nodos) frente a los más largos. Por tanto esta estrategia, elimina la aleatoriedad y es tendenciosa. Mediante el análisis del comportamiento con los parámetros de calibración se examinó si la sensibilidad de este comportamiento tendencioso puede suavizarse con el objetivo de conseguir que el algoritmo adapte su preferencia (tendencia) a los cambios en las calificaciones medias del conjunto de alumnos o las diferentes distribuciones de los perfiles de éstos.

Para el estudio de calibración se utilizó el grafo de la Figura 3 con una colonia de 100 hormigas, simulando el comportamiento de 100 alumnos, que completan un recorrido cada uno. Inicialmente el grafo no tiene feromonas en sus arcos. Para el estudio de calibración de  $\alpha$  y  $\beta$ , se fija un valor de un parámetro y se repite 25 veces el experimento para cada valor del otro. Los valores seleccionados para  $\beta$  son 0.5, 1, 2, 5, 10 y 25; y para  $\alpha$ , 0, 1, 2, 5, 10, 25 y 50. En cada iteración se utiliza el grafo en las condiciones iniciales y no en el estado (funciones de ajuste y feromonas en cada arco) que hubiera quedado tras la iteración anterior. La Tabla 2 muestra los valores iniciales para cada nodo del grafo, siendo los principales puntos de interés en el grafo los llamados Nodos de Decisión: aquellos nodos con grado de salida mayor que cero (N3, N6 y N11).

Tabla 2: Estado inicial del GIA

Nodo	$W_i$	$m$	$M$	$\bar{E}$	Grado Salida	Arcos
N1	1	5	10	0	1	Link0
N2	1	5	10	0	1	Link1
N3	1	5	10	0	3	Link2, Link3, Link4
N4	1	5	10	0	1	Link11
N5	1	5	10	0	1	Link5
N6	0.5	8	10	0	2	Link7, Link9
N7	0.25	8	10	0	1	Link6
N8	0.75	6	10	0	1	Link10
N9	0.6	7	10	0	1	Link8
N10	1	5	10	0	1	Link12
N11	1	5	10	0	2	Link13, Link14
N12	1	5	10	0	1	Link16
N13	0.7	5	10	0	1	Link15
Fin	-	-	-	-	-	-

#### Estudio marginal de $\beta$

En el estudio marginal del parámetro  $\beta$ , se observa que para  $\beta=0.5$ , los itinerarios I y J, son los elegidos entre el 30% y el 69% de las veces, pero que conforme el valor del parámetro aumenta, el impacto de las feromonas  $\Phi$  es tan fuerte que cualquier itinerario puede convertirse en el predominante sin necesidad de que sea elegido por un alto número de hormigas, pudiendo producirse el bloqueo en cualquier itinerario, que será el elegido por una proporción de hormigas superior al 80% y que en algunas ocasiones puede ser el 100%.

La explicación, es que en nuestro algoritmo, los elementos de la tabla de decisión se calculan según la expresión:

$$a_{ij}(t) = \frac{[\tau_{ij}(t)]^\alpha [f_{ij}]^\beta}{\sum_{l \in N_i} [\tau_{il}(t)]^\alpha [f_{il}]^\beta} \quad \forall j \in N_i$$

dónde  $f_{ij}$  es la función de ajuste para el arco  $l_{ij}$  y  $\tau$  son las feromonas definidas en el algoritmo AntSystem, que se depositan y evaporan al final de la iteración, por lo que su influencia en esta iteración inicial es nula. En cambio, las feromonas  $\Phi$  aunque también se evaporan al finalizar la iteración (cuando toda la colonia ha construido una solución), al ser depositadas al vuelo, puede tener un efecto inmediato sobre las siguientes en la misma iteración. Por tanto el valor de  $\beta$  puede aumentar el impacto de la actuación de la hormiga anterior si  $\beta > 1$  o minimizarlo  $\beta < 1$ .

Resumiendo, para valores menores a 1 el algoritmo se muestra excesivamente explorador repartiendo en gran medida a las hormigas por cada uno de los caminos posibles. La convergencia hacia un camino predominante acaba alcanzándose pero muy lentamente. Esta opción podría ser adecuada para utilizarse en un entorno de aprendizaje en el que explícitamente se desea que los alumnos opten por diferentes itinerarios.

En el escenario planteado inicialmente, los valores que mejor se ajustan son los comprendidos entre  $\beta = 1$  y  $\beta = 2$ , puesto que potenciarán los caminos que el equipo pedagógico defina como recomendables, pero a su vez, permitirán la evolución hacia otros caminos si las calificaciones en estos no es inferior a la deseada, sin que por ello se produzca un bloqueo fácilmente en alguno de estos caminos. Cuanto más cercano a  $\beta=2$  más rígido al cambio se mostrará el algoritmo y cuanto más cercano a  $\beta=1$  más flexible pero también menos propenso a producir un itinerario predominante.

#### Estudio marginal de $\alpha$

Para estudiar la influencia del parámetro  $\alpha$  en el comportamiento del algoritmo, se repitieron las mismas pruebas que para el estudio marginal del parámetro  $\beta$  pero conservando el estado de las feromonas del grafo entre cada prueba. Para ello se configuró el algoritmo para que cada hormiga construyera 10 soluciones, con lo que se simulaban diez ediciones diferentes del mismo curso, al ejecutarse cada iteración de la colonia secuencialmente. De esta forma se analiza la influencia de las feromonas  $\tau$  de una edición en otra.

Cuando  $\alpha = 0$  las feromonas  $\tau$  no tienen efecto en la tabla de decisión, y el algoritmo sólo tiene en cuenta en la siguiente iteración a la función de ajuste, una vez evaporadas las feromonas  $\Phi$ . Esto hace que en la segunda iteración, se produzca un bloqueo en el camino que más fue recorrido en la primera iteración, manteniéndose en sucesivas iteraciones con un porcentaje cercano al 100%.

En cambio, al aumentar el valor del parámetro  $\alpha$  se observa que se potencia el camino en el que se obtuvo mejor calificación en la iteración anterior gracias al efecto de las feromonas  $\tau$ , que ahora, al ser  $\alpha > 0$ , sí tienen efecto en la tabla de decisión (Tabla 3).

Tabla 3: Evolución de elecciones con  $\alpha = 1$

Mejor Camino	C	C	G	G	H	H	H	H	H	G
Mejor Calificación	7.13	6.73	7.25	7.25	7.26	7.24	7.29	7.26	7.27	7.17
Itinerario	1ª Il.	2ª Il.	3ª Il.	4ª Il.	5ª Il.	6ª Il.	7ª Il.	8ª Il.	9ª Il.	10ª Il.
A	0	0	0	0	0	0	0	0	0	0
B	0	0	0	0	0	0	0	0	0	0
C	2	44	93	10	0	0	0	0	0	0
D	0	1	1	0	0	0	0	0	0	0
E	0	0	0	0	0	0	0	0	0	0
F	0	0	0	0	0	0	0	0	0	0
G	5	0	1	90	99	99	99	99	99	100
H	0	0	0	0	1	1	1	1	1	0
I	91	53	5	0	0	0	0	0	0	0
J	2	2	0	0	0	0	0	0	0	0

Se observa como en efecto, la combinación de ambos parámetros, al definirse como refuerzo para el mejor camino el valor de la función de ajuste, aumenta la probabilidad de elección del mejor camino en la siguiente iteración.

#### Calibración fina

El aumento de probabilidad, puede calibrarse de una manera más fina con las variables de calibración  $\omega_1, \omega_2$  y  $\omega_3$  a partir del caso extremo en el que todas las hormigas eligen el arco  $l_{ij}$  en la iteración  $k$ . La función de ajuste en ese caso tendrá como valor máximo:

$$f_{ij} = \omega_1 W_j P_{ij} + \omega_2 \Phi_{ij} = 1 + \omega_2 \Phi_{max}$$

Para la estimación de  $\Phi_{ij}$  suponemos que se obtiene la calificación máxima, que normalizada al intervalo  $[0, 1]$  es  $v_j = 1$  y que la mínima calificación deseada en el arco de destino es el 50% de la máxima calificación posible ( $m_j = M_j/2$ ). Puesto que  $W_j < 1$  y  $P_{ij} < 1$ , el mayor valor posible para el primer sumando se alcanza con  $\omega_j = 1$  y vale 1.

$$\Phi_{max} = \sum_{k=1}^n \Phi_{max}^k(\epsilon_{max}) = N \left( \varphi + \frac{\omega_3}{2} \right)$$

dónde  $N$  es el número de hormigas de la colonia y  $\varphi$  es un valor constante que simboliza la unidad mínima de feromonas a depositar. Suponiendo el caso más extremo

(mayor valor de la función de ajuste) y sustituyendo en la ecuación de la función de ajuste:

$$f_{ij} = 1 + \omega_2 N \left( \varphi + \omega_3/2 \right)$$

Estableciendo  $\omega_j = 1$ , para que el segundo sumando de la ecuación de la función de ajuste, las feromonas depositadas on-line por cada hormiga, no tenga una influencia excesiva con respecto al peso pedagógico, se decide igualarlo al máximo caso posible, esto es a 1:

$$1 = \omega_2 N \left( \varphi + \frac{\omega_3}{2} \right)$$

Y por tanto obtenemos una relación entre las dos variables  $\omega_2$  y  $\omega_3$ :

$$\omega_2 = \frac{1}{N \left( \varphi + \frac{\omega_3}{2} \right)}$$

Con una hoja de cálculo es fácil calcular varios valores posibles conociendo la población de la colonia (que se haría coincidir con la población real de alumnos) y el valor unitario de una feromona, que en nuestro caso es constante y se ha definido como  $\varphi=0.01$ . Por ejemplo para una colonia de 100 hormigas, la Tabla 4 muestra los valores adecuados para  $\omega_2$  y  $\omega_3$ .

Tabla 4: Correspondencia de valores entre variables

$\omega_2$	$\omega_3$
1	0
0,28571429	0,05
0,16666667	0,1
0,11764706	0,15
0,09090909	0,2
0,07407407	0,25
0,03846154	0,5
0,02597403	0,75
0,01960784	1
0,01574803	1,25
0,01315789	1,5
0,01129944	1,75
0,00990099	2
0,00419287	4,75
0,00398406	5

Para seleccionar unos valores de calibración adecuados, conociendo la población de la colonia, se realizaron



20 simulaciones para cada valor y se analizó el comportamiento del algoritmo para cada valor.

Tras aumentar el valor de  $\omega_3$  hasta  $\omega_3=2$ , observamos el comportamiento deseado, que refuerza significativamente al camino por el que se obtiene la mejor calificación, favoreciendo la posibilidad de cambio en el itinerario "preferido" por el algoritmo.

La Figura 7 representa gráficamente los datos de la Tabla 5, en la que podemos observar como en las tres

primeras iteraciones la mejor calificación se obtiene en el itinerario G, que implica la elección del arco que va del nodo N3 al nodo N7. A pesar de no ser G el itinerario elegido en mayor número de veces en las dos primeras iteraciones (200 primeras hormigas), el hecho de alcanzar la máxima calificación en cada iteración a través de él, aumenta en la siguiente iteración la probabilidad de ser elegido, lo que consigue en la tercera iteración.

Tabla 5: Resultados obtenidos tras la calibración del algoritmo

Mejor Camino	G	G	G	H	H	H	H	H	H	H	
Mejor Calificación	7,16	7,00	7,13	7,38	7,39	7,40	7,41	7,43	7,42	7,42	
ID	100	200	300	400	500	600	700	800	900	1000	Total
A	1	0	0	0	0	0	0	0	0	0	1
B	0	0	0	0	0	0	0	0	0	0	0
C	3	2	0	0	0	0	0	0	0	0	5
D	0	0	0	0	0	0	0	0	0	0	0
E	0	0	0	0	0	0	0	0	0	0	0
F	0	0	0	0	0	0	0	0	0	0	0
G	3	28	95	98	69	23	2	0	0	0	318
H	1	0	0	2	31	77	98	100	100	100	509
I	83	70	5	0	0	0	0	0	0	0	158
J	9	0	0	0	0	0	0	0	0	0	9

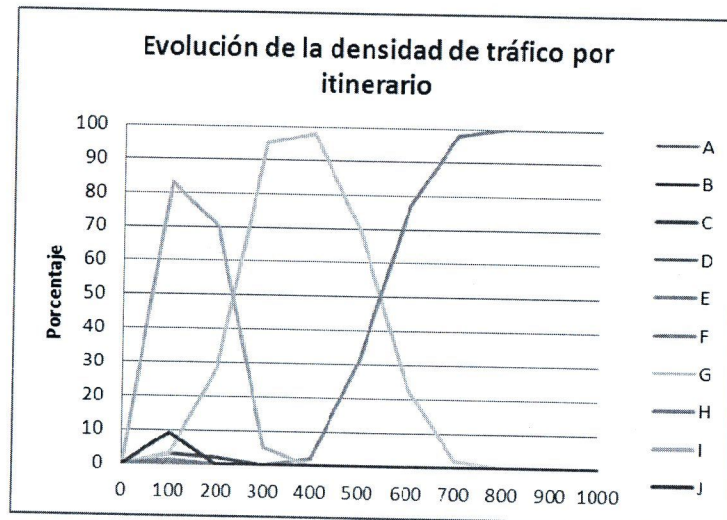


Figura 7: Evolución del porcentaje de elección de cada itinerario en cada iteración. En cada iteración participan 100 hormigas.  $\alpha=1$ ,  $\beta=1.5$ ,  $\omega_1=1$ ,  $\omega_2=0.02$ .

Este fenómeno se vuelve a repetir con el itinerario H en la cuarta iteración, consiguiendo aumentar la probabilidad de elección progresivamente y minimizando la del nodo G, desde un 98% en la cuarta iteración hasta un 69% en la quinta y 23% en la sexta. Como contrapartida, frente al comportamiento del algoritmo con  $\omega_3=1$ , podemos destacar la mayor concentración en la elección observada en cada iteración. A diferencia de los experimentos realizados con  $\omega_3=1$ , en los que se observaba gran diversidad en la elección de los caminos en las primeras iteraciones, con  $\omega_3=2$ , el número de itinerarios que en la primera iteración no han sido elegidos por ninguna hormiga, ha aumentado. Es decir, el comportamiento del algoritmo es más explotador de soluciones que explorador. Otra característica observada con el aumento de esta variable de calibración es una mayor rapidez para alcanzar el bloqueo (todas las hormigas eligen el mismo itinerario).

A partir de  $\omega_3=2$ , la influencia de las feromonas  $\phi$  depositadas en función de la calificación es excesiva y el bloqueo se produce prácticamente desde la primera iteración, una vez que se produce la actualización y evaporación de feromonas. La explicación es que la suma de las feromonas  $\phi$  acumuladas durante la primera iteración es mucho mayor al refuerzo obtenido al itinerario de mayor calificación, por lo que éste refuerzo deja de tener influencia, bloqueándose el algoritmo en el itinerario más veces seleccionado en la primera iteración.

#### Estudio marginal de la tasa de evaporación

Por último, tras realizar experimentos similares mediante simulación, se comprueba que para valores pequeños de la tasa de evaporación, la primera iteración es determinante, conduciendo al bloqueo del algoritmo debido a la acumulación y persistencia de un mayor número de feromonas que condiciona la elección de los arcos en la siguiente iteración. Se observa que este comportamiento comienza a minimizarse con valores de  $\rho > 0.5$ . Para valores de  $0.5 < \rho < 0.8$  el algoritmo se comporta como deseamos, facilitando, sobre todo en las primeras iteraciones, cambios de itinerarios en función de las calificaciones obtenidas.

## 6 Conclusiones y trabajo futuro

Tras una larga fase de experimentación, en la que se simularon más de 25 veces para cada valor de las variables de calibración, obtenemos las siguientes conclusiones:

- Partiendo de  $\omega_1=1$ , aumentar el valor de  $\omega_1$  aumenta la importancia de los pesos pedagógicos y el factor de idoneidad, frente al impacto de las feromonas.

- Partiendo de  $\omega_2=0.02$  y  $\omega_3=1$ , aumentar  $\omega_3$  hasta un máximo de  $\omega_3=2$  fortalece en los nodos de decisión la probabilidad de selección del arco que pertenece al itinerario a través del cual se obtuvo la mayor calificación en la iteración anterior.
- Aumentar  $\omega_2$  a un valor mayor que 1, tiene el mismo efecto que aumentar  $\omega_3$  con un valor superior a 2. El bloqueo se produce desde la primera iteración en el itinerario más veces seleccionado.

Llegados a este punto de la experimentación, los valores seleccionados son:  $\alpha=1.2$ ,  $\beta=1.5$ ,  $\omega_1=1$ ,  $\omega_2=0.02$  y  $\omega_3=1.5$  y una tasa de evaporación  $\rho=0.5$ .

El procedimiento de simulación empleado está justificado por la naturaleza de los datos, no sujetos a aleatoriedad sino al resultado de la dedicación de alumnos, que han sido simulados con hormigas ACO con un determinado perfil de rendimiento.

Como principal conclusión que extraemos es que el algoritmo propuesto, basado en la metodología ACO no sólo puede emplearse para aprendizaje automático y para la optimización de soluciones en problemas NP-completos, sino que puede utilizarse también como técnica para dotar de adaptabilidad a comportamientos externos, en este caso humanos, aproximación esta, pionera hasta la fecha.

Como trabajo futuro cabe la aplicación a entornos de aprendizaje reales (LMS) de esta técnica.

## 7 Referencias

- IEEE Standard for Learning Technology - Data Model for Reusable Competency Definitions. Versión 1. 29th August 2008. Official Standard (IEEE Std 1484.20.1™-2007). Editors: Claude Ostyn and Scott Lewis.
- IEEE. Proposed Draft Standard for Learning Technology - Simple Reusable Competency Map. Revision 4. 22 February 2006. Editor: Claude Ostyn.
- Márquez, J. M.; L. González-Abril; F. Velasco and J. A. Ortega (2011). Designing adaptive learning itineraries using feature modelling and swarm intelligence. Neural Computing & Applications. Feb. 2011. doi:10.1007/s00521-011-0524-7

- [4] Dijkstra, E. W. (1959). A note on two problems in connexion with graphs. *NumerischeMathematik* 1: 269–271
- [5] Valigiani, G.; R. Biojout; Y. Jamont; E. Lutton; C. Bourgeois-Republique and P. Collet (2005). Experimenting with a real-size man-hill to optimize pedagogical paths. In *Proceedings of the 2005 ACM symposium on Applied computing, SAC'05*. ACM, New York.
- [6] Dorigo, M.; V. Maniezzo and A. Colomi (1996). The ant system: Optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics-Part B*, 26(1):29-41, 1996.
- [7] Gutiérrez, S. (2007). *Secuenciamiento de actividades educativas orientado a la reutilización y la auto-organización en tutoría inteligente*. Tesis Doctoral. Universidad Carlos III de Madrid.
- [8] Márquez, J. M., J. A. Ortega, L. González-Abril and F. Velasco. *Creating Adaptive Learning Paths Using Ant Colony Optimization and Bayesian Networks*. 2008 IEEE World Congress on Computational Intelligence (WCCI2008). Hong Kong, China. 1-6 de junio de 2008.