

Un Enfoque Evolutivo Multi-Objetivo al Problema de la Construcción de Grupos de Estudiantes Universitarios

An Evolutionary Multi-Objective Approach to the Problem of Building College Student Groups

Iván Jacho-Sánchez, Lorena Arboleda-Castro, Olga P. Cedeño-Fuentes, Eduardo Samaniego-Mena, Pavel Novoa-Hernández

Resumen— En el ámbito educativo, la creación de grupos de trabajo de estudiantes es un proceso común que frecuentemente es desarrollado por el docente de manera intuitiva. Sin embargo, desarrollar dicho proceso de forma óptima es en realidad una tarea compleja, sobre todo por la presencia de varios estudiantes y criterios. En particular, estos criterios suelen estar en conflicto dado que son reflejo de los intereses educativos del docente y, por otro lado, de las preferencias individuales de cada estudiante. En este sentido, el presente trabajo tiene por objetivo proponer una solución matemático-computacional que automatice eficientemente, en términos de tiempo de cómputo y calidad de las soluciones, el proceso de creación de grupos de trabajo de estudiantes en el ámbito universitario. Los resultados obtenidos en dos escenarios reales en la Universidad Técnica Estatal de Quevedo indican que la propuesta constituye una alternativa eficaz al modelo tradicional.

Palabras Clave— Creación de grupos, optimización multi-objetivo evolutiva, meta-heurísticas

Abstract— The creation of working groups of students in education is a common process that is often developed by the teacher intuitively. However, such a process is actually a complex task since various students and criteria must be taken into account. In general, these criteria are often in conflict because they are a reflection of the educational interests of teachers and on the other hand, the individual preferences of students. In this sense, this paper has as general goal: to propose a mathematical-computational solution that efficiently automatizes, in terms of computational time and solution quality, the creation of working groups of college students. The results obtained from two real

Article history:

Received 18 January 2017

Accepted 11 May 2017

Los autores I. Jacho-Sánchez (ijacho@uteq.edu.ec), L. Castro-Arboleda (larboleda@uteq.edu.ec) y O.P. Cedeño-Fuentes (ocedeno@uteq.edu.ec) son docentes de la Facultad de Ciencias Empresariales de la Universidad Técnica Estatal de Quevedo, Quevedo - Los Ríos, Ecuador.

E. Samaniego-Mena (esamaniego@uteq.edu.ec) y P. Novoa-Hernández (pnovoa@uteq.edu.ec) son docentes de la Facultad de Ciencias de la Ingeniería de la Universidad Técnica Estatal de Quevedo, Quevedo - Los Ríos, Ecuador.

P. Novoa-Hernández es también Profesor Invitado de la Universidad Estatal de Milagro, Milagro - Guayas, Ecuador.

scenarios of the Universidad Técnica Estatal de Quevedo indicate that the proposal is an effective alternative to the traditional model.

Index Terms— Group building, evolutionary multi-objective optimization, metaheuristics.

I. INTRODUCCIÓN

UNA de las competencias más valiosas en el ámbito de la Educación del Siglo XXI [1] es el trabajo en grupo (también conocido como aprendizaje cooperativo). Un aspecto importante dentro de dicha competencia es el proceso de creación de los grupos. En la práctica, esta tarea puede ser desarrollada o bien por el profesor, quien se guiaría por objetivos educativos, o bien por los estudiantes, quienes buscarían aprovechar sus preferencias personales (ej. amistad y compañerismo). En el primer enfoque, donde la creación de los grupos es controlada por el profesor, el objetivo principal es potenciar el aprendizaje de los miembros de cada grupo mediante asociaciones estratégicas entre sus miembros. En particular estas asociaciones buscarían homogenizar el aprendizaje a partir de la presencia de estudiantes con diferentes niveles de conocimiento en un mismo grupo. Como beneficio adicional, el docente podría tener en cuenta también la diversidad de género, de raza, de nivel económico, entre otros, con el objetivo de superar posibles marginalizaciones. En cambio, el segundo enfoque al ser controlado por los estudiantes estaría centrado en la afinidad de sus miembros. Lo cual pudiera estar propenso a la presencia de grupos no deseables desde el punto de vista educativo. Por ejemplo, grupos elitistas de estudiantes muy sobresalientes, o grupos de un solo género o condición social. De manera que el principal reto aquí es lograr un balance adecuado entre ambos enfoques de manera que se cumplan efectivamente los objetivos de cada parte.

Assuming that this balance can be achieved, it remains to be resolved a difficulty: how to deal with a high number of students (ej. más de 30). From the point of view of combinatorial, it is complex to assign optimally students to groups taking into account all the objectives

trazados. Esta problemática ha sido abordada en algunas investigaciones previas. Véase por ejemplo [2], donde el problema fue modelado sin tener en cuenta las preferencias de los estudiantes. Sin embargo, hasta donde se conoce no existen estudios que consideren las preferencias de los estudiantes y los objetivos del docente al mismo tiempo.

Por tales motivos la presente investigación tiene por objetivo desarrollar un modelo matemático-computacional que automatice eficientemente el proceso de creación de grupos de trabajo de estudiantes en el ámbito universitario. En esencia, dicho proceso se ha modelizado como un problema de optimización discreto multi-objetivo. Dada la complejidad computacional presente en dicho modelo (véase [2]) se ha aplicado un algoritmo evolutivo que permite obtener múltiples soluciones de calidad en un tiempo relativamente corto. De esta forma se podrá contar con varias alternativas de solución de alta calidad.

II. TRABAJOS RELACIONADOS

Aunque en la literatura existen algunos trabajos importantes relacionados con el tema (véase por ejemplo [3], [4]), hasta donde se conoce estos están enfocados a establecer solamente directrices sobre cómo formar los grupos, o los beneficios de emplear este recurso educativo. Esto es, no se deja claro de qué forma se debe realizar esta tarea.

Por otro lado, existen trabajos que automatizan procesos de creación de grupos en el contexto de: la educación superior [5], [6], el desarrollo de software [7], [8], y los deportes [9]. En todos estos trabajos se aplican técnicas computacionales que resuelven eficientemente problemas complejos de creación de grupos [10]. Sin embargo, es importante notar que, aunque estas investigaciones constituyen propuestas novedosas, en ninguna se aborda directamente el problema de la creación de grupos de estudiantes universitarios.

De manera que, resulta de interés conocer cómo aprovechar los avances actuales de las tecnologías de la información y la comunicación (TICs) para automatizar este proceso.

III. EL PROBLEMA DE LA CONSTRUCCIÓN DE GRUPOS

En esencia, el problema que se desea resolver queda descrito como sigue:

Sean conocidos por cada estudiante de una unidad de aprendizaje su nivel de conocimiento en la unidad, su condición socio-económica, su vinculación laboral, su sexo, y preferencias individuales, crear “e” grupos de “m” estudiantes de manera que se maximicen:

1. la heterogeneidad (diversidad en cuanto a su nivel de conocimiento, condición socio-económica, vinculación laboral, sexo);
2. la presencia de estudiantes con capacidad de liderazgo en el grupo; y
3. el nivel de preferencia individual de los integrantes por pertenecer.

La descripción anterior puede ser transformada en un modelo matemático conducente a un problema de optimización multi-objetivo como se describirá en los

siguientes apartados. Es importante hacer notar que el modelo propuesto es una extensión del propuesto en nuestra investigación previa [2], sin embargo en el del actual trabajo se han tenido en cuenta la preferencia de los estudiantes con lo que se logra un acercamiento mucho mayor a la realidad.

A. Datos

Se asumirá que se cuenta con los siguientes datos:

n : cantidad de estudiantes de la clase.

m : cantidad máxima de estudiantes que tendrá un grupo.

$e = \lfloor \frac{n}{m} \rfloor$: número de grupos a formar, donde $\lfloor \cdot \rfloor$ representa el operador parte entera.

$h_i \in \{0,1,2\}$: Nivel en conocimiento del estudiante i . Donde:

- 0 corresponde a un nivel bajo,
- 1 corresponde a un nivel medio, y
- 2 corresponde a un nivel bueno.

$c_i \in \{0,1\}$: Nivel económico-social del estudiante i . Donde:

- 0 corresponde a un nivel bajo, y
- 1 corresponde a un nivel aceptable.

$t_i \in \{0,1\}$: Si trabaja o no el estudiante i . Donde:

- 0 no trabaja,
- 1 trabaja.

$s_i \in \{0,1\}$: Sexo del estudiante i . Donde:

- 0 si es femenino, y
- 1 si es masculino.

$l_i \in \{0,1\}$: Competencia de liderazgo del estudiante i . Donde:

- 0 no tiene la competencia,
- 1 tiene la competencia.

$p_{ik} \in \{0,1,2\}$: Preferencia individual del estudiante i por el estudiante k . Donde:

- 0, si a i le resulta irrelevante que k pertenezca o no a su grupo,
- 1, si i siente cierta preferencia por k ,
- 2, si i desea que k forme parte de su grupo.

B. Variables de decisión

Las variables de decisión corresponderán a la asignación de un estudiante a un grupo determinado. Formalmente, se definen como $x_{ij} \in \{0,1\}$, donde:

- 0 significa que el estudiante i no pertenece al grupo j ,
- 1 por el contrario.

C. Restricciones

Las principales restricciones del problema tienen que ver con la estructura del grupo. Formalmente se tendrán en cuenta las siguientes.

- Restricciones funcionales de capacidad del grupo (todos los grupos tienen m integrantes).

$$\sum_{i=1}^n x_{ij} = m \quad \forall j = 1, \dots, e \quad (1)$$

- Restricciones funcionales de pertenencia de los estudiantes (un estudiante pertenece a un solo grupo):

$$\sum_{j=1}^m x_{ij} = 1 \quad \forall i = 1, \dots, n \quad (2)$$

TABLA I
ESCENARIOS CONSIDERADOS EN LOS EXPERIMENTOS

Características	Escenario 1	Escenario 2
Carrera	Ing. Contabilidad y Auditoría	Ing. Industrial
Unidad de aprendizaje	Inglés III	Inglés II
Número de estudiantes	30	55
Número de integrantes por grupo	5	5
Número de grupo	6	11
Distribución de nivel general de habilidades (Speaking, Writting, Listening)	Alto (10), Medio (13) Bajo (7)	Alto (20), Medio (25),Bajo (10)
Distribución del nivel socio-económico	Alto (14), Bajo (16)	Alto (35), Bajo (20)
Distribución de la vinculación laboral	Sí (17), No (13)	Sí (27), No (28)
Distribución del sexo	Mujeres (26), Hombres (4)	Mujeres (11) Hombres (44)
Distribución de liderazgo	Sí (5) No (25)	Sí (12) No (43)
Tamaño del espacio de búsqueda (número de soluciones a considerar)	$\approx 8.88 \times 10^{19}$	$\approx 1.71 \times 10^{50}$

Fuente: Gavidia et al [2].

- Restricciones de dominio de las variables de decisión:

$$x_{ij} \in \{0, 1\} \quad \forall i = 1, \dots, n \quad \forall j = 1, \dots, m$$

D. Funciones objetivo

En general se tienen dos grandes objetivos a maximizar: el relacionado con los intereses del docente y el de las preferencias de los estudiantes. En relación al primero, se buscaría maximizar la diversidad (heterogeneidad) de los integrantes de cada grupo, en relación a los criterios siguientes 1) nivel de conocimiento en la unidad de aprendizaje, 2) nivel económico-social, 3) vínculo laboral, y 4) sexo. Para cuantificar la diversidad de cada grupo se empleó el índice de Mueller y Schuessler [11] (D) como sugiere [2]. Este índice es un análogo al estadígrafo de la varianza en variables continuas. Es importante notar que este índice toma valores en el rango $[0, 1]$, donde un valor cercano a 1 indica una diversidad alta, mientras que uno cercano a 0, lo contrario.

Aplicando este índice, se pueden definir cuatro funciones que corresponderán a la heterogeneidad de los grupos en cuanto al grado de conocimiento en la materia (F_1), condición económico-social (F_2), vínculo laboral (F_3), y sexo (F_4):

$$\max_X F_1(X) = \sum_{j=1}^e D(H(X_j)) \quad (3)$$

$$\max_X F_2(X) = \sum_{j=1}^e D(C(X_j)) \quad (4)$$

$$\max_X F_3(X) = \sum_{j=1}^e D(T(X_j)) \quad (5)$$

$$\max_X F_4(X) = \sum_{j=1}^e D(S(X_j)) \quad (6)$$

donde las funciones H , C , T , y S toman como argumento la j -ésima fila (grupo j) de la matriz X , y retornan un vector con

valores correspondiente a los integrantes del grupo j de acuerdo al indicador en cuestión. Esto es, para los integrantes del grupo j , H retorna el nivel de conocimiento en la asignatura, C los niveles económico-sociales, T la vinculación al trabajo, y S los sexos.

El requerimiento que exista un estudiante con capacidad de líder en cada grupo se puede modelar como:

$$\max_X F_5(X) = \sum_{j=1}^e L(X_j) \quad (7)$$

donde $L: \mathbb{B}^m \rightarrow \mathbb{B}$, es una función booleana que toma como argumento al grupo X_j y retorna 0 si no existe un líder en el grupo, y 1 por el contrario.

En relación a las preferencias de los estudiantes, se tiene la siguiente función objetivo:

$$\max_X F_6(X) = \sum_{j=1}^e S(X_j) \quad (9)$$

donde $S: \mathbb{B}^m \rightarrow \mathbb{N}$ es una función que devuelve la suma de todas las preferencias correspondientes a todos los integrantes del grupo X_j .

Dado que una de las mayores complicaciones que posee un problema multi-objetivo es tener que optimizar varias funciones objetivo a la vez, en la presente investigación se consideró llevar todas las funciones definidas en las expresiones (3-7) a una sola, representando así el objetivo del docente:

$$\max_X F_7(X) = \sum_{i=1}^5 F_i \quad (10)$$

De manera que usando una notación el objetivo general del modelo queda definido como:

$$\max_X \{F_6(X), F_7(X)\} \quad (11)$$

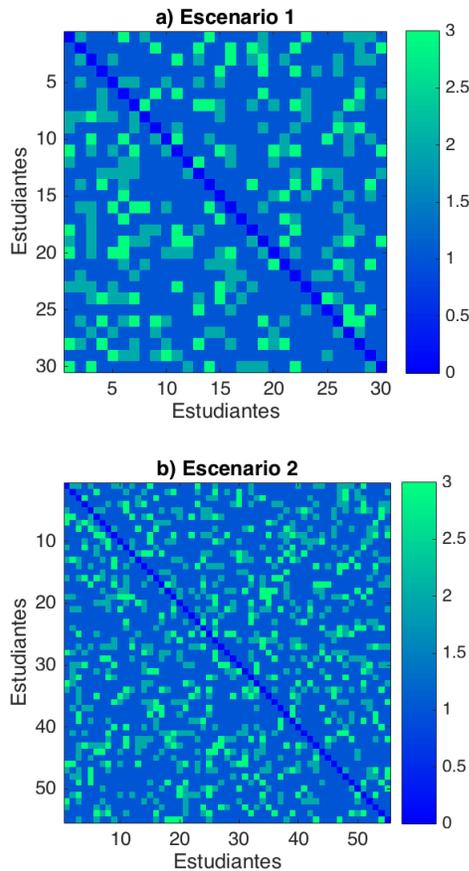


Fig 1. Distribución del nivel de preferencia de los estudiantes en los dos escenarios considerados.

TABLA II
VARIANTES DEL ALGORITMO NSGA-II QUE SE CONSIDERARON EN LOS EXPERIMENTOS.

Variante del algoritmo NSGA-II	Población	Tasa de cruzamiento
NSGAI(5,0.3)	$5 \times n^*$	0.3
NSGAI(5,0.6)	$5 \times n$	0.6
NSGAI(5,0.9)	$5 \times n$	0.9
NSGAI(10,0.3)	$10 \times n$	0.3
NSGAI(10,0.6)	$10 \times n$	0.6
NSGAI(10,0.9)	$10 \times n$	0.9
NSGAI(15,0.3)	$15 \times n$	0.3
NSGAI(15,0.6)	$15 \times n$	0.6
NSGAI(15,0.9)	$15 \times n$	0.9

* n indica la cantidad de estudiantes.

IV. MÉTODO DE SOLUCIÓN APLICADO

Si se analiza con detenimiento las características del modelo anterior, es posible observar que se puede aplicar un enfoque de solución basado en los conceptos de Dominancia de Pareto [12]. Para facilitar el estudio y posterior comparación de los

resultados, se consideró al algoritmo NSGA-II¹ [13] en su versión *elitista controlada*. Esta técnica meta-heurística [14] es un algoritmo genético que emplea la teoría de Dominancia de Pareto. Ambas características le permiten encontrar varias soluciones de alta calidad en un tiempo razonablemente corto². De esta forma, tanto el docente como los estudiantes podrán contar con variantes atractivas de forma rápida.

Aunque otros métodos pueden aplicarse [12], en esta ocasión la elección del NSGA-II se debe a su efectividad en escenarios complejos tales como: Análisis estructural (Método Escenario de Godet) [15], Robótica [16], Planificación [17], Bioinformática [18], [19], Control Automatizado [20], entre otros.

Con la idea de adaptar el NSGA-II al modelo propuesto se hace necesario redefinir los operadores de *inicialización*, *cruzamiento* y *mutación* de este algoritmo. Otro aspecto importante es que codificación (representación) de las soluciones (individuos) resulta más adecuada. En este caso, se representó a cada solución como una permutación de n números enteros en el rango $[1, n]$. Más detalles sobre la implementación de este método puede ser encontrada en la Ayuda del software *Matlab* [21], así como en el Apéndice I del presente trabajo. El lector interesado puede solicitar también el código fuente de la implementación desarrollada a los correos de los autores.

V. RESULTADOS NUMÉRICOS

El objetivo principal del estudio experimental desarrollado es analizar la propuesta en escenarios de aplicación reales. Para ello, se han seleccionado dos escenarios relacionados con las unidades de aprendizaje Inglés que se imparten respectivamente en las carreras Ingeniería en Contabilidad y Auditoría e Ingeniería Industrial, de la Universidad Técnica Estatal de Quevedo (Ecuador). Las principales características de estos escenarios se resumen en la Tabla I. Estos escenarios han sido definidos en la investigación previa [2].

En relación al nivel de preferencias de los estudiantes, en la Fig. 1 se muestran las distribuciones que exhibe este criterio para los dos escenarios considerados en el estudio.

Para analizar convenientemente el método de solución aplicado, se configuraron 9 variantes de NSGA-II atendiendo a la combinación de dos de sus parámetros fundamentales: tamaño de la población (número de soluciones candidatas) y tasa de cruzamiento. Específicamente se valoraron las combinaciones que se muestran en la Tabla II.

Para evaluar la calidad de las soluciones encontradas por las distintas variantes del algoritmo, se eligió como medida de convergencia el *promedio de la distancia mínima al frente de Pareto* [22]:

$$I_s = \frac{1}{\mu} \sum_{i=1}^{\mu} \min_{v \in S_{OP}} (\|F(v) - F(y_i)\|_2) \quad (10)$$

¹ Siglas en inglés de Non-Dominated Sorting Genetic Algorithm.

² Por definición, las meta-heurísticas sacrifican calidad a favor de una disminución del tiempo de cómputo.

donde, μ es el tamaño de la población (número de soluciones candidatas en el algoritmo), S_{OP} es el conjunto óptimo de Pareto del problema, y y_i es la i -ésima solución del conjunto de Pareto obtenido por la variante s del algoritmo. El objetivo de esta medida es promediar la menor distancia euclidiana de las soluciones obtenidas por la configuración s y el frente óptimo $F(v)$. De manera que un valor bajo de esta medida implica un buen nivel de convergencia del algoritmo hacia al mejor frente de Pareto conocido del problema.

En general se realizaron 20 ejecuciones por cada par escenario y variante del algoritmo. Los experimentos fueron implementados sobre la tecnología Matlab 2015 [21].

En la Fig. 2 se muestran los resultados obtenidos por las variantes del algoritmo NSGA-II sobre los dos escenarios considerados. Nótese que estas 9 variantes corresponden a la interacción de los valores de los parámetros tamaño de la población (eje x) y la tasa de cruzamiento (eje y).

En la Fig. 3 se ha graficado los frentes de Pareto óptimo, el de la mejor variante, y el de la peor variante del algoritmo NSGA-II. Finalmente, con el objetivo de ejemplificar la estructura de una solución obtenida por el método de solución aplicado, en la Tabla III se muestra la quinta (5ta) solución de acuerdo al Frente de Pareto alcanzado por la variante NSGA-II(10, 0.3). La distribución que siguen los criterios considerados para esta 5ta solución, se muestra de manera gráfica en la Fig. 4.

VI. DISCUSIÓN Y CONCLUSIONES

A partir de los resultados obtenidos en el apartado anterior se puede apreciar que los parámetros: tamaño de la población y tasa de cruzamiento, poseen una clara influencia en el rendimiento del algoritmo NSGA-II. Particularmente se observa que la mejor variante corresponde a la NSGA-II(10,0.3). Algo que se identifica mejor en el gráfico del Escenario 2 (Fig. 2). Dicha variante posee por tanto una distancia menor hacia el Frente de Pareto óptimo del problema, en comparación con el resto (véase la Fig. 3). Nótese que estos frentes de Pareto son representaciones gráficas de los dos objetivos del modelo, donde en el eje de las x se tiene a la función objetivo que corresponde a los criterios del profesor, y en el de las y al criterio de los estudiantes. En estos gráficos se observa también que no siempre la mejor variante aporta soluciones exactas con respecto al Frente óptimo, véase por ejemplo lo que sucede en el escenario 2 (Fig. 3), donde existen dos soluciones que están fuera del frente óptimo.

Otro aspecto importante que brinda este tipo de gráfico es que, a través del mismo, el decisor (en este caso el docente) puede elegir la solución que mejor represente sus intereses, siendo todas óptimas según el criterio de Pareto. Por ejemplo, un tipo de solución que resulta siempre atractiva es la que se encuentra en equilibrio en relación con los objetivos del modelo (ej. F_6, F_7). Ese es el caso de la quinta solución en el gráfico del Escenario 1 (Fig. 3).

Para comprobar cuán interesante puede resultar esta solución, a través de la Tabla III y la Fig. 4 se muestra su estructura interna. Por ejemplo, véase que en la Tabla III indica la asignación de los estudiantes a los grupos, mientras que en la Fig. 4 los valores de los 6 criterios considerados por

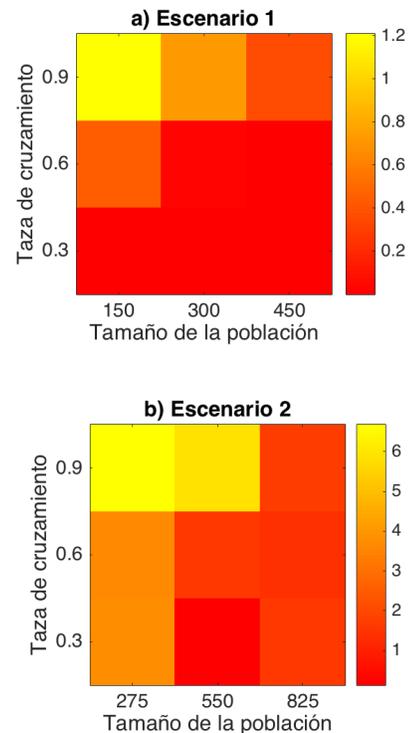


Fig 2. Resultados en términos de la distancia mínima al Frente de Pareto óptimo, obtenidos por las 9 variantes del algoritmo en los escenarios 1 y 2.

cada estudiante. Según los resultados de la Fig. 4 se aprecia que la solución logra un equilibrio adecuado entre los intereses del docente y el de los estudiantes.

Sin embargo, es también posible notar que la solución no es del todo óptima en algunos criterios. Por ejemplo, véase el criterio liderazgo en el que al grupo 3 se le han asignado dos estudiantes con aptitud de líderes, cuando grupos como el 2 y el 4 no tienen ninguno así.

Por la anterior se concluye que el objetivo de la investigación se ha alcanzado de manera efectiva. Más específicamente, el enfoque propuesto resulta efectivo para automatizar el proceso de creación de grupos de trabajo en estudiantes universitarios.

No obstante, los resultados obtenidos hasta aquí, se considera que estos pueden ser mejorados. Los trabajos futuros estarán orientados a: incluir el enfoque propuesto en una aplicación informática que facilite al docente no solo la gestión de la información involucrada, sino también la toma de decisiones en este proceso; y se considerarán otros criterios para la asignación de los estudiantes, por ejemplo, el estilo de aprendizaje. Asimismo, sería importante ampliar los experimentos con la ayuda de la herramienta DynOptLab [23].

REFERENCIAS

- [1] UNESCO and J. Delors, *La educación encierra un tesoro: informe a la UNESCO de la Comisión Internacional sobre la educación para el siglo XXI, presidida por Jacques Delors*. Correo de la UNESCO, 1997.
- [2] M. H. Gavidia, G. C. Galarza, M. M. Robalino, D. C. Chabla, and P. Novoa-Hernández, ‘Creación automática de equipos de estudiantes universitarios: una experiencia desde la asignatura Inglés’, *Cienc.*

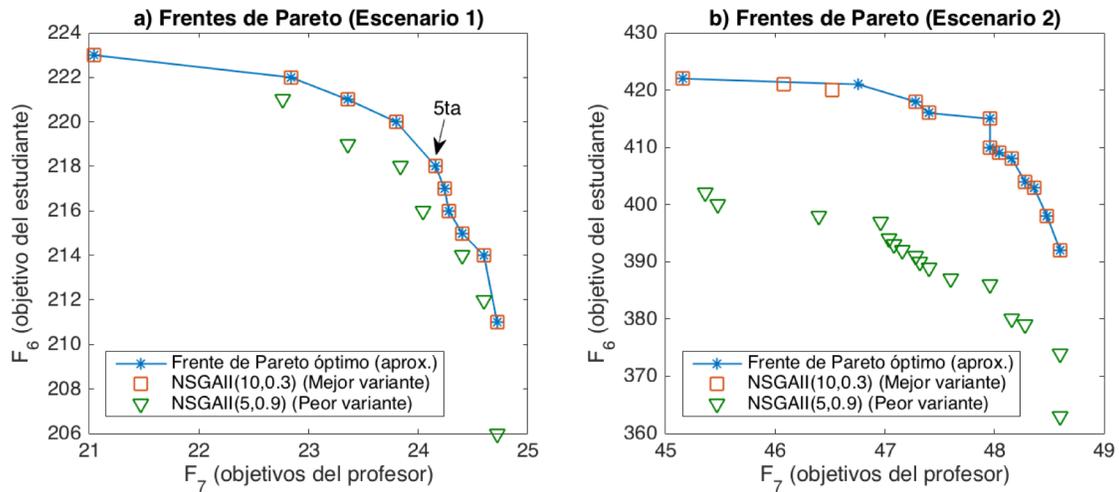


Fig 3. Ejemplo de solución obtenida por la variante NSGA-II(10,0.3) en el Escenario 1. La solución corresponde a la 5ta según el Frente de Pareto (véase Fig. 3).

TABLA III.
QUINTA (5TA) SOLUCIÓN DE ACUERDO AL FRENTE DE PARETO ALCANZADO POR LA VARIANTE NSGA-II(10,0.3).

Grupo	Miembros (Estudiantes)					
1	Est. 23	Est. 9	Est. 4	Est. 26	Est. 1	
2	Est. 15	Est. 18	Est. 6	Est. 27	Est. 2	
3	Est. 7	Est. 11	Est. 21	Est. 28	Est. 13	
4	Est. 12	Est. 22	Est. 16	Est. 3	Est. 19	
5	Est. 10	Est. 29	Est. 25	Est. 5	Est. 24	
6	Est. 30	Est. 17	Est. 8	Est. 14	Est. 20	

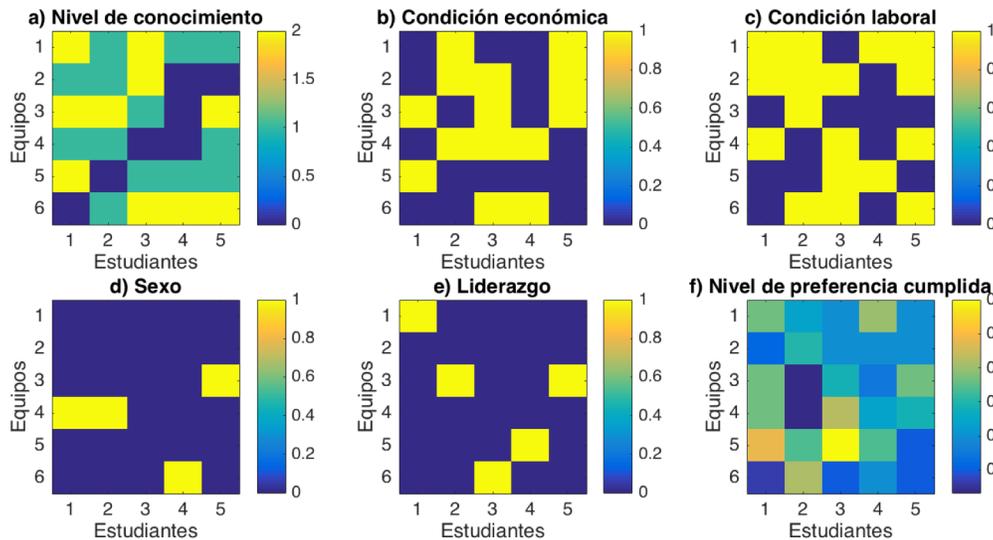


Fig 4. Distribución de los criterios de acuerdo a la 5ta solución obtenida por la variante NSGA-II(10,0.3) en el Escenario 1 (véase Fig. 3).

[3] P. E. Glinz, 'Un acercamiento al trabajo colaborativo', *Rev. Iberoam. Educ.*, vol. 35, no. 2, pp. 1-13, 2005.

[4] R. L. L. Hughes and S. K. K. Jones, 'Developing and assessing college student teamwork skills', *New Dir. Institutional Res.*, vol. 2011, no. 149, pp. 53-64, 2011.

[5] P. Novoa-Hernández, M. A. Novoa-Hernández, and Y. Rivero-Peña, 'Propuesta de técnicas evolutivas para la confección automática de tribunales de trabajos de diploma', *Rev. Cuba. Ciencias Informáticas*, vol. 7, no. 4, pp. 90-99, 2013.

- [6] P. Novoa-Hernández, 'Optimización evolutiva multi-objetivo en la planificación de controles a clase en la educación superior cubana', *Comput. y Sist.*, vol. 19, no. 2, pp. 321–335, 2015.
- [7] K. Escalera Fariñas, A. L. Infante Abreu, M. André Ampuero, and A. Rosete Suárez, 'Uso de estrategias de paralelización en algoritmos metaheurísticos para la conformación de equipos de software', *Rev. Cuba. Ciencias Informáticas*, vol. 8, no. 3, pp. 90–99, 2014.
- [8] Y. Rivero Peña, P. Novoa-Hernández, Y. Fernández Ochoa, P. Novoa Hernández, and Y. Fernández Ochoa, 'La optimización evolutiva multi objetivo en la confección de equipos de desarrollo de software : una forma de lograr la calidad en el producto final', *Enfoque UTE*, vol. 29, no. 1, pp. 35–44, 2015.
- [9] F. Ahmed, A. Jindal, and K. Deb, *Cricket team selection using evolutionary multi-objective optimization*, vol. 7077 LNCS, no. PART 2. Berlin, Heidelberg: Springer-Verlag, 2011.
- [10] I. Wegener, *Complexity Theory: Exploring the Limits of Efficient Algorithms*. Springer Berlin Heidelberg, 2004.
- [11] J. H. Mueller, K. F. Schuessler, and H. L. Costner, *Statistical Reasoning in Sociology*. Houghton Mifflin, 1977.
- [12] D. A. Van Veldhuizen and G. B. Lamont, 'Multiobjective Evolutionary Algorithms: Analyzing the state of the art', *Evol. Comput.*, vol. 2, no. 1, pp. 125–147, 2002.
- [13] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, 'A fast and elitist multiobjective genetic algorithm: NSGA-II', *Evol. Comput. IEEE Trans.*, vol. 6, no. 2, pp. 182–197, Apr. 2002.
- [14] I. Boussaïd, J. Lepagnot, and P. Siarry, 'A survey on optimization metaheuristics', *Inf. Sci. (Ny)*, vol. 237, pp. 82–117, 2013.
- [15] P. J. Villacorta, A. D. Masegosa, D. Castellanos, P. Novoa, and D. A. Pelta, 'Sensitivity analysis in the scenario method: A multi-objective approach', in *International Conference on Intelligent Systems Design and Applications, ISDA*, 2011, pp. 867–872.
- [16] R. Saravanan, S. Ramabalan, N. G. R. Ebenezer, and C. Dharmaraja, 'Evolutionary multi criteria design optimization of robot grippers', *Appl. Soft Comput. J.*, vol. 9, no. 1, pp. 159–172, 2009.
- [17] M. Saadatesh, A. Mansourian, and M. Taleai, 'Evacuation planning using multiobjective evolutionary optimization approach', *Eur. J. Oper. Res.*, vol. 198, no. 1, pp. 305–314, 2009.
- [18] C. Zambrano-Vega, M. Cárdenas-Zea, and R. Aguirre-Pérez, 'Un enfoque Multi-Objetivo a la optimización del Alineamiento Múltiple de Secuencias (MSA)', *Lat. Am. J. Comput.*, vol. 3, no. 1, pp. 43–51, 2016.
- [19] S.-Y. Shin, I.-H. Lee, D. Kim, and B.-T. Zhang, 'Multiobjective Evolutionary Optimization of DNA Sequences for Reliable DNA Computing', *IEEE Trans. Evol. Comput.*, vol. 9, no. 2, pp. 143–158, Apr. 2005.
- [20] P. Woźniak, 'Preferences in multi-objective evolutionary optimisation of electric motor speed control with hardware in the loop', *Appl. Soft Comput.*, vol. 11, no. 1, pp. 49–55, 2011.
- [21] MATLAB, *version 8.5.0 (R2015b)*. Natick, Massachusetts: The MathWorks Inc., 2015.
- [22] E. Talbi, *Metaheuristics: from design to implementation*, vol. 2009. John Wiley & Sons, 2009.
- [23] P. Novoa-Hernández, C. C. Corona, and D. A. Pelta, 'A software tool for assisting experimentation in dynamic environments', *Appl. Comput. Intell. Soft Comput.*, vol. 2015, p. 5, 2015.



Lorena Arboleda-Castro. Es Máster en Finanzas y Proyectos Corporativos por la Universidad de Guayaquil (Ecuador, 2011). Se graduó de Economista con Mención en Gestión Empresarial, por la Universidad Politécnica del Litoral (Ecuador, 2009). Actualmente, es Docente de la Facultad de Ciencias Empresariales, Universidad Estatal de Quevedo, Quevedo, Los Ríos, Ecuador (2011-actualidad).



(2010-2017).

Olga P. Cedeño-Fuentes. Es Máster en Gestión Empresarial por la Universidad Estatal de Quevedo (Ecuador, 2010). En 2007 se graduó de Ingeniera en Gestión Empresarial en la Universidad Estatal de Quevedo (Ecuador, 2007). Trabajó como Docente de la Facultad de Ciencias Empresariales, Universidad Estatal de Quevedo, Quevedo, Los Ríos, Ecuador



Eduardo Samaniego-Mena. Es Máster en Conectividad y Redes de Ordenadores por la Universidad Técnica Estatal de Quevedo (2015). Se graduó de Ingeniero en Sistemas en la misma institución en el 2010 y trabaja en esta desde 2013 como docente. Además, fue profesor de la Universidad Técnica de Babahoyo (2012-2014). Es autor y coautor de publicaciones en revistas regionales y

Scopus. Sus intereses investigativos incluyen Soft Computing, problemas de optimización, análisis inteligente de datos, minería de datos, entre otros.



Pavel Novoa-Hernández. Actualmente trabaja como Profesor Agregado de la Universidad Técnica Estatal de Quevedo, Los Ríos, Ecuador, y como Profesor Invitado en la Universidad Estatal de Milagro. Es Ingeniero Informático por la Universidad de Holguín (Cuba) desde el 2007. Obtuvo el título de Master en Ciencias de la Computación e Inteligencia

Artificial por la Universidad Central de Las Villas (Cuba), en el 2010. En el 2013 obtuvo el grado de Doctor (Ph.D) en Tecnologías de la Información y la Comunicación por la Universidad de Granada (España). Ha sido Profesor Auxiliar en la Universidad de Holguín en el período 2007-2015. Sus intereses investigativos, relacionados con la Soft Computing, incluyen: problemas dinámicos de optimización, metaheurísticas, problemas de optimización multi-objetivo, entre otros.



Iván Jacho-Sánchez. Es Máster en Tributación y Finanzas, Universidad de Guayaquil (Ecuador, 2014), y Economista por la Universidad de Guayaquil (Ecuador, 2007). Actualmente es Docente de la Facultad de Ciencias Empresariales, Universidad Estatal de Quevedo, Quevedo, Los Ríos, Ecuador (2010-actualidad).

APÉNDICES

Apéndice 1. Algoritmo NSGA-II versión elitista controlada

Algoritmo NSGA-II (variante elitista controlada)

```

1:  $P \leftarrow \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_\mu\}$  Generar aleatoriamente  $\mu$  individuos (población inicial)
2: Evaluar en la función objetivo, los individuos de  $P$ 
3:  $R \leftarrow \{R_1, R_2, \dots\}$  Determinar los conjuntos Pareto a partir de los rangos (posición) de  $P$ 
4: Calcular la distancia de separación de los individuos por cada conjunto  $R_i$ 
5:  $F_{mejor} \leftarrow$  conjunto de Pareto de  $P$ , esto es,  $R_1$ 
6:  $G \leftarrow 0$  contador del número de generaciones (iteraciones)
7: mientras  $G \leq G_{max}$  y  $F_{mejor}$  no es el deseado hacer
8:      $Q \leftarrow$  generarHijos( $P$ ) mediante Selección, Cruzamiento y Mutación
9:     Evaluar en la función objetivo a los individuos de  $Q$ 
10:     $Q \leftarrow Q \cup P$ 
11:     $P \leftarrow \emptyset$ 
12:     $R \leftarrow \{R_1, R_2, \dots\}$  Determinar los conjuntos Pareto a partir de los rangos (posición) de  $Q$ 
13:     $F_{mejor} \leftarrow$  Conjunto de Pareto de  $Q$ 
14:    por cada conjunto de Pareto  $R_i \in R$  hacer
15:        Calcular la distancia de separación de los individuos de  $R_i$ 
16:        si  $\|P\| + \|R_i\| \geq \mu$  entonces
17:            Añadir a  $P$ , los  $m - \|P\|$  individuos de  $R_i$  más diferentes (según distancia)
18:            salir del ciclo
19:        si no
20:             $P \leftarrow P \cup R_i$ 
21:     $G \leftarrow G + 1$ 
22: retornar  $F_{mejor}$ 

```