

Método híbrido de reducción de incertidumbre aplicado a la predicción del comportamiento de incendios forestales

Miguel Méndez-Garabetti^{1,2}, Germán Bianchini¹, Paola Caymes-Scutari^{1,2} y María Laura Tardivo^{1,2,3}

¹ Laboratorio de Investigación en Cómputo Paralelo/Distribuido (LICPaD), Departamento de Ingeniería en Sistemas de Información, Facultad Regional Mendoza - Universidad Tecnológica Nacional. Mendoza, Argentina. (M5502AJE) Mendoza, Argentina.

² Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

³ Departamento de Computación, Facultad de Ciencias Exactas, Físico-Químicas y Naturales (UNRC), Córdoba, Argentina.

mmendez@mendoza-conicet.gob.ar, gbianchini@frm.utn.edu.ar, pcaymesscutari@frm.utn.edu.ar, lauratardivo@dc.exa.unrc.edu.ar

Abstract. Los incendios forestales causan anualmente grandes pérdidas y daños alrededor del mundo. El pronóstico del comportamiento de un incendio puede ser una herramienta fundamental para tomar decisiones en situaciones de emergencia. Sin embargo, este proceso suele estar afectado por la existencia de incertidumbre en las variables que alimentan al modelo. Por este motivo, desde diferentes áreas, se trabaja en el desarrollo y perfeccionamiento de métodos que permiten reducir los efectos de la incertidumbre y obtener predicciones más precisas. En este trabajo se presenta un método híbrido de reducción de incertidumbre que combina las virtudes de dos metaheurísticas poblacionales evolutivas: Algoritmos Evolutivos y Evolución Diferencial. Dicho método se denomina Sistema Estadístico Evolutivo Híbrido con Modelo de Islas (HESS-IM).

Keywords: predicción de incendios, reducción de incertidumbre, algoritmos evolutivos, evolución diferencial, metaheurísticas híbridas

1 Introducción

Los incendios forestales ocasionan anualmente grandes pérdidas y daños en diferentes áreas alrededor del mundo. Las consecuencias negativas tras la ocurrencia de estos fenómenos suelen ser muy significativas. Tal es el caso del daño en el suelo, el agua, la atmósfera, la economía, la flora, la fauna y en ocasiones se debe lamentar la pérdida de vidas humanas. Debido a esto es que, desde diferentes áreas de la ciencia, se trabaja en el desarrollo de herramientas, técnicas, métodos y sistemas que permiten minimizar tales efectos, ya sea antes, durante o después de los mismos. Una de estas técnicas tiene el objetivo de predecir el

comportamiento del fenómeno, es decir, se intenta determinar, con cierto tiempo de antelación, la dirección futura de propagación del incendio. Si la predicción generada por el método es de calidad y es obtenida antes que el incendio finalice, la misma se vuelve de vital importancia ya que puede permitir mejorar el impacto de la toma de decisiones, posibilitando la optimización del uso de recursos en las tareas de extinción, evacuación, planificación, etc.

El comportamiento del fuego en un entorno forestal está determinado por diferentes variables, tales como: la velocidad y dirección del viento, la cantidad y tipo de combustible, la topografía del terreno, el tipo de vegetación, entre otros. Esta información es necesaria para poder determinar el futuro comportamiento del fenómeno. Por lo general, obtener los valores de dichas variables en tiempo real resulta una tarea compleja. Si bien las redes de sensores inalámbricos (WSN, por sus siglas en inglés) [1] pueden ser de gran ayuda, ya que permiten obtener mediciones en tiempo real de las variables de interés, es prácticamente imposible contar con instrumental de medición en toda área forestal con potencial riesgo de ignición. En [2], las WSNs son utilizadas como herramienta para el monitoreo y detección temprana de incendios forestales. Más allá de que no es económicamente viable contar con WSNs desplegadas en grandes superficies, una alternativa interesante puede ser el uso de redes de sensores inalámbricas móviles (MWSNs) [3], en las cuales los sensores no se encuentran en ubicaciones fijas, pudiendo ser reutilizados en prácticamente cualquier área afectada por incendios. Este tipo de implementaciones puede reducir la imprecisión en los valores de entrada de las variables que alimentan el modelo e incidir en mejoras en la calidad de predicción del método.

Sin embargo, en la mayoría de los incendios forestales, no es posible contar con mediciones en tiempo real de las variables de interés. Debido a esto, los valores deben ser tomados a partir de mediciones indirectas, interpolaciones o aproximaciones, lo que nos ubica ante una situación de *incertidumbre*. La incertidumbre en los parámetros de entrada afectan de forma directa la calidad de predicción del método, por lo tanto, si deseamos obtener predicciones cercanas a la realidad, dicha incertidumbre debe ser reducida a valores aceptables. Los sistemas de predicción aplicados a fenómenos naturales son de alta criticidad debido a la sensibilidad de las decisiones que pueden ser tomadas a partir de sus predicciones y del poco margen de tiempo disponible para obtener los resultados. Es debido a esto que dichos sistemas suelen ser implementados en ambientes computacionales de alto rendimiento o HPC [4].

En este trabajo se presenta un nuevo método de reducción de incertidumbre, el cual saca provecho del esquema de paralelización basado en islas del método denominado *Sistema Estadístico Evolutivo con Modelo de Islas* [5],[6] (ESS-IM por sus siglas en inglés). Esta nueva metodología, llamada *Sistema Estadístico Evolutivo Híbrido con Modelo de Islas* (Hybrid Evolutionary-Statistical System with Island Model, HESS-IM), permite que cada isla pueda operar con diferentes metaheurísticas de forma colaborativa. HESS-IM utiliza Análisis Estadístico [7], Computación Paralela [4], metaheurísticas evolutivas paralelas (Algoritmos Evo-

lutivos [8] y Evolución Diferencial [9]) como herramientas colaborativas de optimización, bajo un esquema de paralelización basado en el Modelo de Islas [8].

La siguiente sección comienza con una breve descripción de la técnica de hibridación y las metaheurísticas utilizadas: Algoritmos Evolutivos (EAs) y Evolución Diferencial (DE). Seguido a esto se comenta el esquema de paralelización implementado y el funcionamiento interno de HESS-IM. Posteriormente se brindan los detalles de la experimentación realizada y se exponen los resultados obtenidos. Finalmente, se presentan las conclusiones y el trabajo futuro.

2 Sistema Estadístico Evolutivo Híbrido con Modelo de Islas (HESS-IM)

El *Sistema Estadístico Evolutivo Híbrido con Modelo de Islas* (HESS-IM), es un método general de reducción de incertidumbre que basa su funcionamiento en un esquema colaborativo entre diferentes metaheurísticas poblacionales. En esta primera aproximación, el método opera con Algoritmos Evolutivos y Evolución Diferencial.

2.1 Hibridación de las técnicas de optimización

La eficiencia de un método de optimización puede verse incrementada mediante la combinación de múltiples metaheurísticas, debido a la utilización de diferentes estrategias de búsqueda sobre un mismo espacio de soluciones. Este tipo de combinación da lugar a lo que se conoce como metaheurísticas híbridas (Hybrid Metaheuristics, HMs). Si bien existen diferentes enfoques para clasificar a las HMs, en [10] se dividen en dos grandes grupos: metaheurísticas híbridas de *combinación colaborativa* y HMs de *combinación integrativa*. Las HMs colaborativas tienen como propósito intercambiar información entre las diferentes técnicas de optimización, ya sea que operen de forma secuencial o paralela. En otras palabras, podemos decir que cada metaheurística opera de forma casi independiente, colaborando entre sí sólo mediante el intercambio de soluciones candidatas. En cambio, en las integrativas, una metaheurística utiliza a otra, operando esta segunda como parte de la primera de forma subordinada. En este esquema la colaboración es a nivel interno del mecanismo de optimización, donde el funcionamiento de una metaheurística se ve enriquecido por las bondades de otra/s. Es decir, no intercambian soluciones ya que ambas operan sobre el mismo conjunto de soluciones.

En HESS-IM la técnica de optimización consiste en una hibridación colaborativa entre un Algoritmo Evolutivo y uno de Evolución Diferencial, ambas son metaheurísticas poblacionales o de múltiples soluciones, las cuales operan mejorando de forma iterativa un conjunto de soluciones. A continuación se proporciona una breve descripción de cada una de ellas.

Algoritmos Evolutivos. Los EAs constituyen un método de búsqueda, aplicado a la resolución de problemas de optimización, inspirado en la teoría de

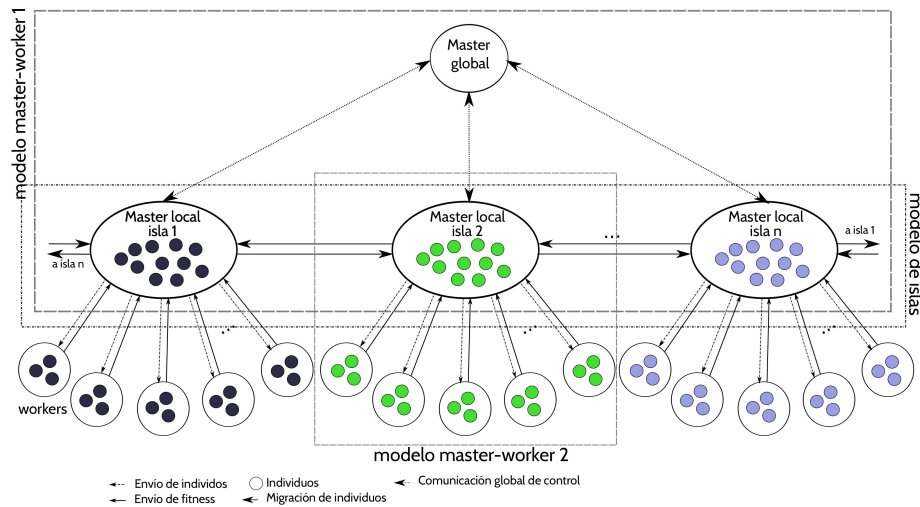


Fig. 1. Esquema de paralelización jerárquico basado en islas con doble modelo master-worker.

evolución natural de las especies [11]. El proceso se compone de cierto número de iteraciones, llamadas generaciones, donde un conjunto de soluciones candidatas, que conforman una población, evolucionan mediante la aplicación de operadores que permiten imitar los principios de selección natural y supervivencia del más apto. Cada individuo tiene asociado un valor de aptitud o fitness que determina la calidad de la solución para el problema tratado; este valor se calcula utilizando la función matemática que describe el problema. Los mecanismos que permiten evolucionar a los individuos de la población son denominados operadores evolutivos: selección, mutación, cruzamiento y reemplazo. En cada iteración, se selecciona una cantidad preestablecida de individuos, los cuales se reproducen utilizando operadores de variación y generando así nuevas soluciones candidatas. A continuación, se aplica un proceso de reemplazo para determinar qué individuos de la población sobrevivirán [12]. Al término de un número razonable de generaciones, se espera que el mejor individuo de la población represente a una solución lo suficientemente próxima a la solución óptima del problema.

Evolución Diferencial. Los DE, al igual que los EAs, son metaheurísticas del tipo poblacional estocástica. DE comienza explorando el espacio de búsqueda mediante la generación de una población de individuos, la cual se crea de manera aleatoria y uniformemente distribuida dentro del rango del problema. En términos generales DE utiliza la diferencia de vectores para modificar de forma iterativa la población mediante tres operaciones vectoriales: la mutación, el cruzamiento y la selección. Es importante remarcar que estos operadores son aplicados sobre cada uno de los individuos de la población. La operación de mutación perturba la población mediante la aplicación de diferencias de vectores

entre los miembros de la población, de esta forma se determina tanto el grado como la dirección de los nuevos individuos generados a partir de este proceso. Luego de la fase de mutación, que da como resultado el vector mutante, se somete el mismo junto con el individuo de la población actual al operador de cruce, generando un nuevo vector denominado vector de prueba. Finalmente, se lleva a cabo el proceso de selección con el objetivo de mantener en la población de la generación siguiente a aquellos individuos que posean mejores características, por lo tanto, se evalúa para cada vector de prueba el valor de su función objetivo y se compara con su correspondiente de la población actual. Si el vector de prueba tiene mejor o igual valor de la función objetivo, se reemplazará el vector actual en la siguiente generación.

2.2 Esquemas de Paralelización

Existe gran número de alternativas para paralelizar metaheurísticas: según la cantidad de poblaciones involucradas, el tratamiento de los operadores, el grado de relación entre cómputo y comunicación, entre otros. Existen ciertas estrategias de paralelización que mejoran el tiempo de resolución del algoritmo, por tratarse de implementaciones paralelas de un algoritmo secuencial, pero dicho paralelismo no influye en los valores numéricos, por lo que éstas implementaciones llegan a los mismos resultados que la implementación secuencial [13].

HESS-IM hereda de ESS-IM un esquema de paralelización basado en islas con doble jerarquía master-worker (un esquema general puede observarse en la Fig. 1). Como puede apreciarse, en el nivel superior se encuentra el *modelo master-worker 1*, donde un proceso *master global* coordina el funcionamiento de la totalidad de las islas. El master local de cada isla cumple la función de worker respecto del master global. Posteriormente en el segundo nivel de jerarquía master-worker, *modelo master-worker 2*, cada master de isla controla a un conjunto de workers dentro de cada isla, quienes son los encargados de evaluar la función de aptitud. Es importante remarcar que cada isla inicializa una población diferente, las cuales son evolucionadas mediante metaheurísticas distintas. La colaboración entre las diferentes metaheurísticas es provista mediante el operador de migración, el cual intercambia individuos entre las diferentes islas/metaheurísticas cada ciertos eventos (i.e., cantidad de generaciones realizadas, valores de aptitud de la población, detección de estancamientos en óptimos locales, etc.).

2.3 HESS-IM: Metodología de Funcionamiento

HESS-IM utiliza como técnica de optimización una metaheurística híbrida basada en Algoritmos Evolutivos y Evolución Diferencial. En esta primera aproximación del método, la hibridación se basa en un esquema colaborativo, donde las metaheurísticas operan con poblaciones diferentes y sólo intercambian individuos cada determinados eventos o cierta cantidad de generaciones.

En la Fig. 2, se presenta un esquema general del funcionamiento de HESS-IM. Tal como se puede observar, la estrategia de paralelización corresponde con el diseño presentado en la Fig. 1, donde existen tres tipos de procesos: a)

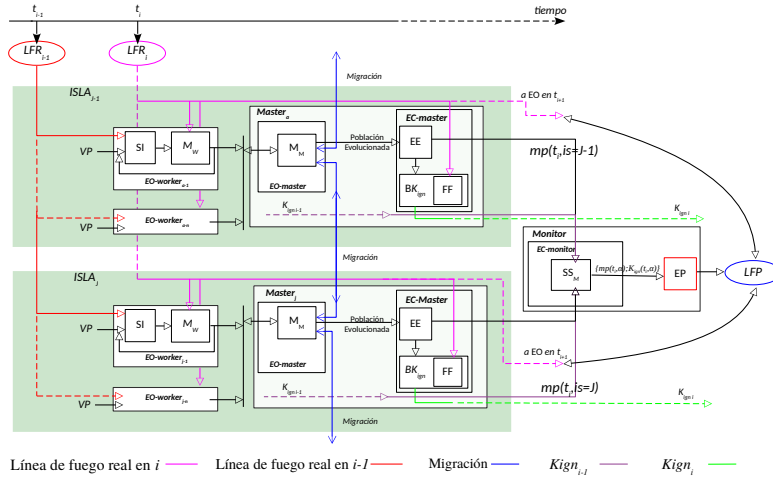


Fig. 2. Sistema Estadístico Evolutivo Híbrido con Modelo de Islas: **SI**: simulador de incendios; **M_M**: etapa metaheurística en master; **M_W**: etapa metaheurística en worker (evaluación de fitness); **EO**: etapa de optimización; **EE**: etapa estadística; **BK_{ign}**: búsqueda de K_{ign} ; K_{ign} : valor clave de ignición; **FF**: función de fitness; **EC**: etapa de calibración; **EP**: etapa de predicción; **LFP**: línea de fuego predicha; **LFR_x**: línea de fuego real en tiempo x ; **VP**: vector de parámetros de entrada; **EE_M**: etapa estadística en proceso monitor; **mp**: mapa de probabilidad.

proceso *monitor* (i.e., *master global* en Fig. 1), b) proceso *master* (i.e., *master local* en Fig.1), y c) los procesos de tipo *worker*. En una instancia de HESS-IM donde operen j islas, y w workers por isla, intervendrán en paralelo un total de $1 + j + w * j$ procesos, i.e., 1 proceso monitor, j procesos masters (uno por cada isla), y $w * j$ procesos workers.

Desde el punto de vista del funcionamiento del método, el proceso *monitor* es el encargado de iniciar la cadena de predicción mediante el envío de la información del incendio a ser analizado (i.e., mapa real del incendio, intervalos de tiempo a considerar, parámetros, etc.), a los *masters* de cada isla. Posteriormente, en cada *master* se ejecuta la Etapa de Optimización (EO_{master}), donde se da inicio a la metaheurística que cada isla tiene asignada (i.e., EA o DE). Tal como se puede observar, la Etapa Metaheurística se encuentra dividida en dos subetapas: por un lado la Etapa Metaheurística del proceso master (M_M), y por el otro, la Etapa Metaheurística de los procesos workers (M_W). En términos generales, diremos que la etapa M_W se encarga de la evaluación de aptitud de los individuos, y la etapa M_M se ocupa del resto de las operaciones involucradas en cada metaheurística. Los workers de cada isla evalúan la aptitud de los individuos mediante la utilización del simulador de incendios (*SI*). El *SI* se basa en el modelo definido por Rothermel [14] e implementado mediante la librería fireLib [15]. Para realizar la evaluación de aptitud en t_i es necesario contar con la línea de fuego real del incendio (LFR) en t_{i-1} (i.e., LFR_{i-1}) y los valores de

los parámetros de entrada, los cuales se almacenan en los vectores de parámetros (VP).

Una vez evaluados los individuos, éstos son enviados junto a su correspondiente valor de aptitud, a la etapa M_M . Esta etapa, además de realizar el resto de las operaciones de cada metaheurística (i.e., alteración de individuos, evolución de la población, etc.), se encarga de la migración de individuos hacia las islas vecinas. El proceso de migración se encuentra dividido en tres pasos: selección, envío-recepción y reemplazo. El proceso de *selección* consiste en escoger, de la población actual, aquellos individuos que serán enviados al resto de las islas. Se utiliza un criterio semi-elitista, donde el 50% de los individuos a migrar corresponde a los mejores y el otro 50% se selecciona de forma aleatoria. El siguiente paso, *envío-recepción*, es el mecanismo que efectúa la comunicación entre las diferentes islas, el cual envía y recibe individuos cada cierta cantidad de generaciones, también llamado frecuencia de migración, siguiendo una topología de anillo. La frecuencia de migración está establecida como un parámetro variable que depende de la cantidad máxima de generaciones. El proceso de *reemplazo* determina los individuos de la población actual que serán reemplazados por los que arriben provenientes de otras islas; el criterio utilizado es similar al proceso de selección, donde los peores individuos son reemplazados por los mejores y el resto son reemplazados de forma aleatoria.

Finalmente, cuando las poblaciones de las distintas islas han evolucionado, éstas son enviadas a la Etapa de Calibración del proceso master (EC_{master}). En esta etapa se calcula un mapa de probabilidad, en función de todos los individuos, el cual se utiliza para generar el valor clave de ignición (K_{ign} , por sus siglas en inglés). El K_{ign} representa el patrón de comportamiento del incendio y es obtenido en la etapa Búsqueda del K_{ign} (BK_{ign}).

En todo instante de tiempo i , en cada isla is , se genera un valor clave de ignición $K_{ign}(t_i, is)$ y un mapa de probabilidad $m_p(t_i, is)$, los cuales son enviados a la etapa de calibración del proceso *monitor* ($EC_{Monitor}$), donde en la etapa estadística (EE_M) genera en t_i un par $\{m_p(t_i, \alpha); K_{ign}(t_i, \alpha)\}$, donde α , indica el número de isla cuyo par de valores ha obtenido el mejor valor de fitness. Éstos valores finalmente son ingresados en la etapa de predicción (EP) la cual realiza el cálculo de predicción (i.e., línea de fuego predicha) para el próximo instante de tiempo $i + 1$, i.e., LFR_{i+1} .

3 Experimentación y Resultados

En este apartado se comentan los resultados preliminares obtenidos tras evaluar la calidad de predicción de HESS-IM en contraste con la metodología previa ESS-IM. Para ello, ambos métodos fueron aplicados a una quema real controlada realizada en Serra de Lousã (Gestosa, Portugal), en el marco del proyecto Spread [16]. La porción del incendio bajo análisis tiene una duración total de 10 minutos, a partir del minuto 2 hasta el minuto 12. Para la evaluación de la calidad de predicción se han definido pasos de tiempo discretos, los cuales representan el avance del frente de fuego. Cada intervalo tiene una duración de 2 minutos, dando

un total de 5 muestras (i.e., minuto 4, 6, 8, 10 y 12). Es importante remarcar que desde el instante t_0 (minuto 2) a t_1 (minuto 4), ambos métodos efectúan el cálculo del primer K_{ign} , lo que impide generar predicciones para el instante de tiempo inicial (t_1 , minuto 4), por estar ambos métodos en la etapa de calibración. Para ambos métodos el criterio de finalización de cada metaheurística consistió en alcanzar un umbral de la aptitud igual a 0,7, o llegar a un máximo de 200 iteraciones, y para los parámetros particulares de cada metaheurística se utilizó una configuración clásica de valores. Además, el tamaño de población para cada metaheurística fue establecido en 200 individuos.

En la Fig. 3, se puede observar la calidad de predicción alcanzada por cada método. En el eje de ordenadas se presenta la calidad de predicción o fitness, donde un valor igual a 1 equivale a una predicción perfecta, y un valor igual a 0, indica una predicción completamente errónea. El eje de abscisas contiene los instantes de tiempo para los cuales se ha calculado la calidad de predicción.

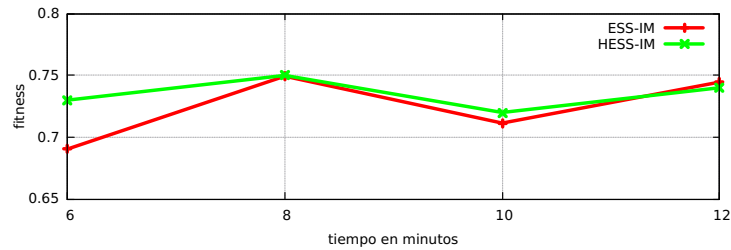


Fig. 3. Calidad de predicción obtenida por HESS-IM y ESS-IM para cada paso de predicción.

Tal como se puede observar, en la mayor cantidad de pasos de predicción (i.e., minuto 6, 8 y 10), la calidad de predicción alcanzada por HESS-IM es superior a la de ESS-IM, excepto en el último instante de tiempo (minuto 12). La mayor diferencia se observa en el primer paso de predicción y decae en los siguientes. A simple vista, puede parecer que la hibridación no impacta demasiado en la salida, pero es importante destacar que en este tipo de métodos, donde existe alta complejidad e incertidumbre en el fenómeno estudiado, suele ser difícil alcanzar incrementos mínimos de calidad de predicción, por lo que consideramos realmente positivos los resultados encontrados. Es importante remarcar que ambos métodos poseen un comportamiento no determinista, por lo que los resultados expuestos han sido calculados mediante el promedio de 30 ejecuciones.

Finalmente, es importante remarcar que debido a que este trabajo corresponde a un estudio preliminar, por el momento no se han realizado experimentaciones con mayor cantidad de casos, pero en próximos trabajos se incluirán mayor cantidad de resultados.

4 Conclusiones

En este trabajo se ha presentado HESS-IM, un nuevo método general de reducción de incertidumbre aplicado a la predicción de fenómenos naturales de propagación. Dicho método consiste en utilizar, como técnica de optimización, una metaheurística híbrida paralela basada en Algoritmos Evolutivos y Evolución Diferencial, bajo un esquema de paralelización basado en islas con doble jerarquía master-worker.

Se evaluó la calidad de predicción del método mediante su aplicación en la predicción del comportamiento de un incendio forestal controlado. Dicha calidad de predicción fue contrastada con los de una metodología previa basada en Algoritmos Evolutivos Paralelos (ESS-IM). Los resultados obtenidos demuestran que la técnica de hibridación utilizada, junto con las metaheurísticas seleccionadas, favorecen el mecanismo de búsqueda del método; permitiendo obtener resultados de mejor calidad. Dicho incremento en la calidad de los resultados es traducido en predicciones más precisas y confiables, lo que puede impactar en diferentes aspectos (optimizar el proceso de lucha contra incendios, minimizar riesgos y daños a las personas, mejorar el proceso de toma de decisiones ante situaciones de catástrofe, etc.).

Finalmente, como trabajo futuro se abre un gran abanico de temáticas y estudios pendientes. Por un lado, es preciso evaluar el método con una mayor cantidad de casos de incendios (i.e., con diferentes dimensiones, tipo de vegetación, condiciones climáticas, etc.). Por otro lado, se considera importante realizar un estudio de calibración de los parámetros evolutivos de cada metaheurística participante. Esto permitirá explotar las bondades de cada técnica de optimización y obtener así resultados de mejor calidad. Finalmente, se pretende realizar un análisis de rendimiento computacional, y evaluar la incorporación de otras metaheurísticas.

Agradecimientos

Este trabajo ha sido financiado por la Universidad Tecnológica Nacional mediante los proyectos EIUTIME0003939TC y EIUTNME0003952. Además, el primer autor agradece a CONICET por la beca doctoral otorgada.

Referencias

1. Sitharama Iyengar S., Brooks R.R.: Distributed Sensor Networks, Second Edition: Sensor Networking and Applications. Chapman and Hall/CRC, Florida (2013)
2. Aslan Y.E., Korpeoglu I., Ulusoy Ö.: A framework for use of wireless sensor networks in forest fire detection and monitoring, *Comput. Environ. Urban Syst.* 36, <http://dx.doi.org/10.1016/j.compenvurbsys.2012.03.002>, 614–625 (2012)
3. Rezazadeh J., Moradi M., Ismail A.S.: Mobile Wireless Sensor Networks Overview, *IJCCN International Journal of Computer Communications and Networks*, Volume 2, Issue 1, 17–22 (2012)

4. Buyya R.: High Performance Cluster Computing: Architectures and Systems, Prentice Hall, PTR, NJ, USA, (1999)
5. Méndez-Garabetti M., Bianchini G., Tardivo M.L., Caymes-Scutari P.: Comparative Analysis of Performance and Quality of Prediction Between ESS and ESS-IM, *Electronic Notes in Theoretical Computer Science*, Volume 314, SSN 1571-0661, <http://dx.doi.org/10.1016/j.entcs.2015.05.004>, pp. 45–60. Elsevier, Berlin (2015)
6. Méndez-Garabetti M., Bianchini G., Caymes-Scutari P., Tardivo M.L.: Increase in the quality of the prediction of a computational wildfire behavior method through the improvement of the internal metaheuristic, *Fire Safety Journal*, Volume 82, ISSN 0379-7112, <http://dx.doi.org/10.1016/j.firesaf.2016.03.002>, pp. 49–62. Elsevier, Berlin (2016)
7. Montgomery D.C, Runger G.C.: *Applied Statistics and Probability for Engineers*. 6th Edition. Limusa Wiley & Sons, New Jersey (2014)
8. Alba E., Tomassini M.: Parallelism and evolutionary algorithms, in *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 5, 443–462 (2002)
9. Das S., Mullick S.S., Suganthan P.N.: Recent advances in differential evolution – An updated survey, *Swarm and Evolutionary Computation*, Volume 27, ISSN 2210-6502, <http://dx.doi.org/10.1016/j.swevo.2016.01.004>, 1–30 (2016)
10. Blum C., Raidl G.R.: *Hybrid Metaheuristics, Powerful Tools for Optimization*, Springer International Publishing, Switzerland (2016)
11. Darwin D.: *On the Origin of Species by Means of Natural Selection*. London (1859)
12. Yu X., Gen M.: *Introduction to Evolutionary Algorithms*, Springer-Verlag, London (2010)
13. Gong Y., Chen W., Zhan Z., Zhang J., Li Y., Zhang Q., Li J.: Distributed evolutionary algorithms and their models: A survey of the state-of-the-art, *Applied Soft Computing*, Volume 34, pp. 286–300, Elsevier, Berlin (2015)
14. Rothermel R.C.: A mathematical model for predicting fire spread in wildland fuels, Res. Pap. INT-115, US Dept. of Agric., Forest Service, Intermountain Forest and Range Experiment Station. Ogden, UT., (1972)
15. Bevins C.D.: *FireLib User Manual & Technical Reference*, <http://www.fire.org/>
16. Viegas D.X.: *Project Spread – Forest Fire Spread Prevention and Mitigation*, <http://www.algosystems.gr/spread/>, (2004)