

MÉTODO HÍBRIDO PARALELO DE REDUCCIÓN DE INCERTIDUMBRE APLICADO A LA PREDICCIÓN DEL COMPORTAMIENTO DE INCENDIOS FORESTALES

Miguel Méndez-Garabetti^{a,b}, Germán Bianchini^a, Paola Caymes Scutari^{a,b},
y María L. Tardivo^{a,b,c}

^aLaboratorio de Investigación en Cómputo Paralelo/Distribuido (LICPaD), Departamento de Ingeniería en Sistemas de Información, Facultad Regional Mendoza Universidad Tecnológica Nacional. (M5502AJE) Mendoza, Argentina, <http://www2.licpad.utn.frm.edu.ar/>

^bConsejo Nacional de Investigaciones Científicas y Técnicas (CONICET), <http://www.conicet.gov.ar/>

^cDepartamento de Computación. Universidad Nacional de Río Cuarto, Río Cuarto, Córdoba, Argentina.

Keywords: Reducción de Incertidumbre, Predicción, Incendios Forestales, Paralelismo, Metaheurísticas.

Abstract. Año a año, los incendios forestales consumen aproximadamente dos millones de hectáreas de forestación alrededor del mundo, causando enormes pérdidas y daños. Con el objetivo de reducir los efectos provocados por éstos, continuamente se desarrollan estrategias y herramientas para la prevención, monitoreo y/o predicción de incendios. Los sistemas de predicción suelen verse afectados por la incertidumbre presente en los parámetros de entrada del modelo de comportamiento de fuego. Ante esta problemática, los métodos de reducción de incertidumbre permiten contrarrestar dichos efectos mejorando la calidad de predicción por medio de diferentes técnicas y estrategias. El Sistema Estadístico Evolutivo con Modelo de Islas (ESS-IM) es un método general de reducción de incertidumbre que ha sido aplicado satisfactoriamente en la predicción del comportamiento de incendios forestales. ESS-IM utiliza Computación de Alto Rendimiento, Análisis Estadístico y Algoritmos Evolutivos Paralelos como metaheurística interna. En este trabajo se presenta una nueva arquitectura de ESS-IM donde se utilizan múltiples metaheurísticas operando en paralelo, bajo un esquema híbrido de paralelismo basado en los paradigmas "master-worker" y "modelo de islas". La nueva arquitectura es validada mediante la aplicación del método a un conjunto de quemas reales controladas, evaluando tanto calidad de predicción como rendimiento.

1 INTRODUCCIÓN

Los incendios forestales son uno de los fenómenos más perjudiciales de todos los tiempos, entre sus daños se destacan: los ecológicos, económicos y humanos. A modo de ejemplo podemos citar el incendio forestal ocurrido en agosto de 2016 en la provincia de San Luis (Argentina) ([Diario La Nación, 2016](#)), donde cerca de 10.000 hectáreas fueron consumidas por las llamas y más de 100 personas debieron ser evacuadas (Fig. 1). Situaciones similares a éstas ocurren frecuentemente alrededor del mundo, por lo cual es importante trabajar en el desarrollo de métodos y sistemas que minimicen éstos efectos. Una vez que un incendio forestal ha comenzado, lograr predecir su comportamiento puede ser una herramienta prometedora, ya que esto puede permitir tomar decisiones que minimicen sus efectos, siempre que la predicción resultante sea obtenida en tiempos aceptables. Sin embargo, esto no es una tarea sencilla principalmente debido a la incertidumbre que afecta el proceso de predicción.

Generalmente, cuando se intenta predecir este tipo de fenómenos, es necesario contar con mediciones de las variables que condicionan su comportamiento. El comportamiento de los incendios forestales depende de diferentes factores, tales como: la cantidad de combustible, el tipo de combustible, la velocidad y dirección del viento, la topografía del terreno, el tipo de vegetación, las cantidades de humedad, etc. Cuando un incendio está ocurriendo, resulta difícil contar con esta información en tiempo real, ya que si bien existen tecnologías para dar respuesta a esta problemática, e.g., Redes de Sensores Inalámbricos (Wireless Sensor Network, WSN) ([Sitharama Iyengar and R.R., 2013](#)), es prácticamente inviable contar con dicho instrumental de medición en grandes áreas forestales con potencial riesgo de ignición. Además, las técnicas de predicción clásica han demostrado no ser lo suficientemente confiables como para poder tomar decisiones a partir de sus predicciones.

Ante esta situación, se han desarrollado diversos métodos de reducción de incertidumbre, tal es el caso del *Sistema Estadístico Evolutivo con Modelo de Islas* (Evolutionary-Statistical System with Island Model, ESS-IM) ([Méndez-Garabetti et al., 2016](#)). ESS-IM pertenece a la clasificación de Métodos Guiados por Datos con Múltiples Soluciones Solapadas (Data-Driven Methods with Multiple Overlapped Solutions, DDMMOS). Los DDMMOS operan sobre un gran número de valores de entrada, y mediante alguna técnica de optimización, intentan encontrar un conjunto de configuraciones de valores que describan –de la mejor manera posible– el comportamiento previo del fenómeno y puedan ser utilizados para describir el comportamiento de un instante futuro. ESS-IM utiliza como técnica de optimización Algoritmos Evolutivos bajo un esquema de paralelización basado en islas.

En este trabajo se presenta una nueva metodología de reducción de incertidumbre basada en ESS-IM, la cual se denomina *Sistema Estadístico Evolutivo Híbrido con Modelo de Islas* (Hybrid Evolutionary-Statistical System with Island Model, HESS-IM). HESS-IM aprovecha el esquema de paralelización implementado en ESS-IM donde cada isla pueda operar con diferentes metaheurísticas de forma colaborativa. HESS-IM, al igual que ESS-IM, han sido implementados bajo arquitecturas paralelas utilizando Análisis Estadístico ([Montgomery and Runger, 2014](#)), Computación Paralela ([Buyya, 1999](#)), Metaheurísticas Evolutivas Paralelas (Algoritmos Evolutivos ([Alba and Tomassini, 2002](#)) y Evolución Diferencial ([Das et al., 2016](#))) como herramientas colaborativas de optimización, bajo un esquema de paralelización basado en el Modelo de Islas ([Mühlenbein, 1991](#)).

En la siguiente sección se describen los componentes principales de HESS-IM: a) las metaheurísticas involucradas, las estrategias de paralelización e hibridación. A continuación, en la Sección 3 se comentan las limitaciones de la Predicción Clásica y la arquitectura y fun-

cionamiento de HESS-IM. Luego se brindan los detalles de los experimentos realizados y se comentan los resultados obtenidos. Finalmente, se discuten las conclusiones y las líneas futuras de trabajo.



Figura 1: Incendio forestal ocurrido en San Luis, Argentina, agosto de 2016.

2 METAHEURÍSTICAS: PARALELISMO E HIBRIDACIÓN

Ciertos problemas de optimización poseen un grado de complejidad tal, que impide resolverlos de manera exacta sin hacer uso de grandes cantidades de recursos y/o tiempo. Sin embargo, algunos de estos problemas permiten soluciones no exactas, i.e., pueden ser resueltos mediante técnicas de optimización aproximadas, lo que ofrece una reducción considerable en la cantidad de cómputo y tiempo necesario. En este contexto, las metaheurísticas han cobrado vital importancia, ya que permiten resolver problemas de optimización de alta complejidad con rasgos de incertidumbre y dinamicidad, en plazos razonables de tiempo (Bui et al., 2005).

Según Glover (1986), las metaheurísticas conforman estrategias inteligentes y generales que tienen como objetivo mejorar y/o diseñar procedimientos heurísticos para resolver problemas de alta complejidad. Para este tipo de problemas, o en aquellos en los que se debe lidiar con altos índices de incertidumbre, las implementaciones tradicionales de las metaheurísticas no suelen brindar los resultados esperados, ya sea tanto en términos de:

- a) Calidad de las soluciones encontradas: cuando las soluciones encontradas no poseen una calidad aceptable, se suele utilizar un esquema de participación colaborativa, mediante el uso de dos o más metaheurísticas, fortaleciendo así el mecanismo de búsqueda, permitiendo encontrar soluciones de mejor calidad.
- b) Cantidad de tiempo utilizado: cuando la complejidad asociada al problema tratado impide que el mismo sea resuelto en cantidades razonables de tiempo, el problema debe ser resuelto usando sistemas de computación de alto rendimiento (High Performance Computing, HPC) (Buyya, 1999). Esto implica que las metaheurísticas deben ser adaptadas para poder ser instanciadas eficientemente en ambientes paralelos.

Tal como se comentó en la sección previa, HESS-IM ha sido implementado utilizando dos metaheurísticas de forma paralela, estas son Algoritmos Evolutivos (Evolutionary Algorithms, EA) y Evolución Diferencial (Differential Evolution, DE), las cuales son descritas brevemente a continuación.

2.1 Algoritmos Evolutivos

Los EAs son métodos de optimización estocásticos cuyo funcionamiento se encuentra inspirado en la teoría de evolución natural de las especies (Darwin, 1859). Pertenecen a la clasificación de metaheurísticas poblacionales, las cuales se caracterizan por conformar una población de soluciones candidatas, que son sometidas a un proceso iterativo que permite imitar el principio de selección natural y supervivencia del más apto. Dicho mecanismo, permite la evolución de los individuos a soluciones de mejor calidad mediante la aplicación de ciertos operadores evolutivos: selección, cruce, mutación y migración. Cada individuo posee un valor que permite cuantificar la calidad de la solución que dicho individuo representa para el problema. Este valor se conoce como aptitud o fitness y es calculado utilizando la función matemática que describe el problema. En cada iteración evolutiva, se selecciona cierta cantidad de individuos que son perturbados generando así nuevas soluciones candidatas. Posteriormente, se lleva a cabo un procedimiento de reemplazo con el objetivo de determinar aquellos individuos que sobrevivirán o aquellos que serán reemplazados (Yu and Gen, 2010). Al finalizar el ciclo de iteración evolutiva, se espera que algún individuo represente una solución aceptable para el problema tratado.

2.2 Evolución Diferencial

Al igual que EA, DE es una metaheurística poblacional estocástica, pero a diferencia ésta no es bioinspirada. DE utiliza una población de individuos para explorar el espacio de búsqueda. Generalmente los individuos son creados de manera aleatoria y uniformemente distribuida dentro del rango del problema. El mecanismo central de DE está basado en la diferencia de vectores, lo que permite modificar de forma iterativa la población mediante el uso de operadores. A diferencia de EA, todos los operadores (i.e., mutación, cruzamiento y selección) son aplicados sobre cada uno de los individuos de la población.

En primer lugar se realiza la operación de mutación, la cual modifica la población mediante la aplicación de diferencias de vectores entre los miembros diferentes individuos de la población, de esta forma se determina tanto el grado como la dirección de los nuevos individuos. Posteriormente, se somete cada individuo mutado junto con el individuo de la población actual al operador de cruce, generando un nuevo vector, llamado vector de prueba. A continuación, se realiza la selección para mantener en la población siguiente (i.e., próxima generación), a aquellos individuos con mejores características, para esto se evalúa para cada vector de prueba el valor de su función objetivo y se contrasta con su correspondiente de la población actual. Una vez comparados, si el vector de prueba tiene mejor o igual valor de función objetivo, se reemplaza el vector actual en la siguiente generación.

2.3 Paralelismo y Colaboración entre Diferentes Metaheurísticas

Las metaheurísticas pueden paralelizarse siguiendo diferentes criterios y estrategias, algunas de ellas, sólo mejoran el tiempo de respuesta del algoritmo sin influir en los resultados obtenidos (Gong et al., 2015). HESS-IM utiliza un esquema de paralelización basado en islas con doble jerarquía master-worker (un esquema general puede observarse en la Fig. 2). 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. Es importante remarcar que cada isla inicializa una

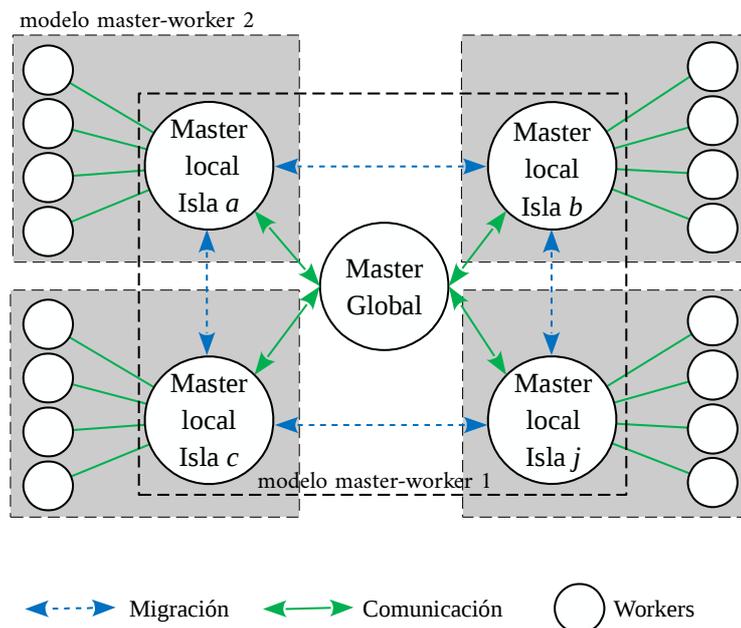


Figura 2: Esquema de paralelización jerárquico basado en islas con doble modelo master-worker.

población diferente, las cuales son perturbadas mediante diferentes metaheurísticas. La colaboración entre cada metaheurísticas se lleva a cabo por el operador de migración, el cual intercambia individuos entre las diferentes islas y/o metaheurísticas cada ciertos eventos (i.e., cantidad de generaciones realizadas, valor de aptitud de la población, detección de estancamientos en óptimos locales, etc.).

3 MÉTODOS DE PREDICCIÓN Y REDUCCIÓN DE INCERTIDUMBRE

Esta sección comienza con una breve descripción del funcionamiento y limitaciones de la predicción clásica, para luego brindar los detalles del funcionamiento e implementación de HESS-IM.

3.1 Predicción Clásica

La técnica de Predicción Clásica consiste en utilizar algún tipo de simulador de propagación de incendios y evaluar la evolución del frente de fuego luego de un determinado intervalo de tiempo. En la Fig. 3 se puede observar un esquema general de su funcionamiento. Como puede verse, el simulador de incendios (SI), recibe los parámetros de entrada (PE) que representan las condiciones actuales (e.g., condiciones del viento, vegetación, características de la superficie, etc.) y estado inicial del incendio (i.e., línea de fuego real en el instante t_0 , LFR_0). Con esta información, el simulador genera la predicción de la línea de fuego (línea de fuego predicha, LFP) para el instante t_1 , esperando que coincida lo mejor posible con el estado real del incendio LFR_1 . Sin embargo, a causa de la incertidumbre en los parámetros de entrada, la complejidad del fenómeno que se intenta predecir y debido a que la predicción es generada a partir de una única simulación, esta metodología generalmente no ofrece una predicción cercana a la realidad.

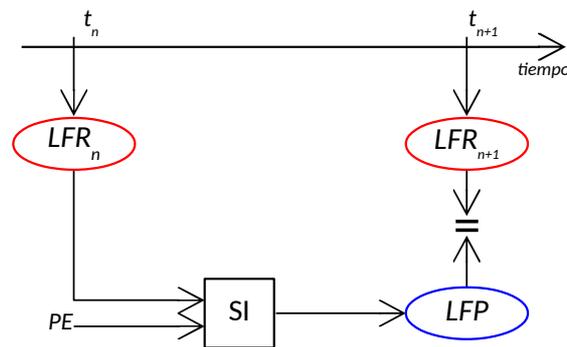


Figura 3: Esquema general del método de Predicción Clásica. **SI**: simulador de incendios; **PE**: parámetros de entrada; **LFP**: línea de fuego predicha; **LFR_x**: línea de fuego real en tiempo x .

3.2 HESS-IM: Sistema Estadístico Híbrido Evolutivo con Modelo de Islas

HESS-IM es un método general de reducción de incertidumbre que utiliza una técnica de optimización híbrida y colaborativa entre dos metaheurísticas poblacionales evolutivas: a) Algoritmos Evolutivos y b) Evolución Diferencial. Tal como se mencionó en la Sección 2.3, el esquema de paralelización de HESS-IM corresponde con una estrategia basado en islas con doble jerarquía master-worker, permitiendo a cada isla operar con una metaheurística diferente sobre el mismo espacio de búsqueda. Un esquema general del funcionamiento de HESS-IM puede observarse en la Fig. 4. La cadena de predicción comienza en el proceso *monitor*, el cual envía a cada isla dos conjuntos de datos iniciales:

- a) Conjunto de datos del incendio: un mapa con el frente de fuego real, intervalos de tiempo a considerar para cada paso de predicción, valores y rangos para cada parámetro de entrada.
- b) Conjunto de datos de las metaheurísticas: cantidad de islas, metaheurística que cada isla deberá utilizar, cantidad de workers por isla y tipo de migración.

Dichos conjuntos de datos son recibidos por el proceso *master* de cada isla, donde se instancia la Etapa de Optimización (EO_{master}), que da inicio a la metaheurística requerida por el proceso *monitor*, ya sea: EA o DE. Dicho procesamiento se realiza en la Etapa Metaheurística la cual 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).

La etapa M_M realiza diferentes operaciones dependiendo del momento en que se encuentre operando el método y en función de la metaheurística configurada en dicha isla, sin embargo, existen ciertas funciones que todas las islas realizan en común:

- 1) Inicialización de la población: al inicio del proceso de predicción, esta etapa se encarga de inicializar la población de individuos y de enviar los mismos a los workers para que éstos sean tratados.
- 2) Migración de individuos: mientras los workers computan a los individuos, la etapa M_M lleva a cabo la migración de individuos hacia las islas vecinas. La migración se realiza en función de la topología de comunicación y tipo de migración configurada, esta última puede ser: a) con mayor frecuencia entre islas que operen con la misma metaheurística, o b) con un único valor de frecuencia para todas las islas.

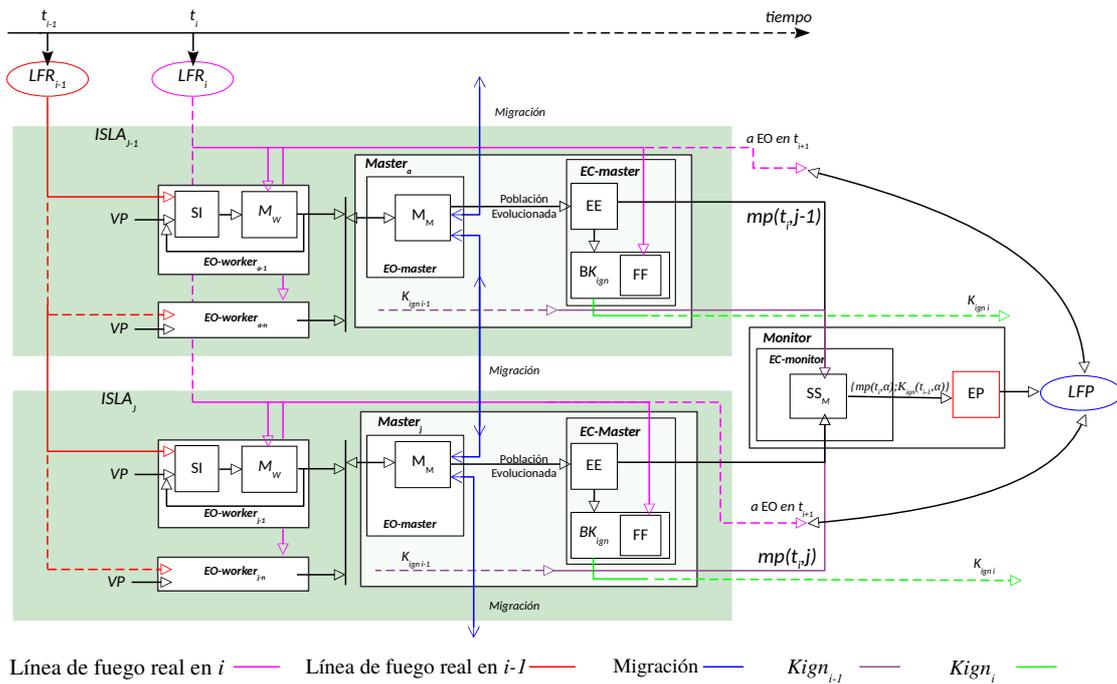


Figura 4: Sistema Estadístico Evolutivo Híbrido con Modelo de Islas: **SI**: simulador de incendios; **M_M**: etapa metaheurística en master; **M_W**: etapa metaheurística en worker (evaluación de fitness); **EO**: etapa de optimización; **EE**: etapa estadística; **BK_{ign}**: búsqueda de K_{ign} ; 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.

- 3) Evolución de la población: cuando se alcanza la cantidad máxima de iteraciones o el umbral de aptitud, dentro de cada iteración, se realiza la evolución de la población hacia la próxima generación evolutiva.
- 4) Finalización y envío: cuando la población ha evolucionado, cumpliendo la condición de finalización, se envía, desde la etapa M_M la población final de individuos hacia la Etapa de Calibración (EC_{master}).

Por su lado, los workers, tienen como función principal evaluar la aptitud de cada individuo mediante la utilización de un simulador de comportamiento de incendios forestales (*SI*). Dicho simulador está basado en el modelo definido por Rothermel (1972) e implementado mediante la librería fireLib (Collin D. Bevins, 1996). El cálculo de la evaluación de aptitud en el instante t_i necesita 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) (i.e., los individuos de la población).

La función de aptitud utilizada para determinar la calidad de cada individuo está basada en el índice de Jaccard (Real and Vargas, 1996), ver Ec. (1). Esta función permite comparar el mapa simulado con el mapa real en t_i (LFR_i) y, en función de la diferencia entre los dos mapas, se determina el valor de aptitud para cada individuo. Todo valor estará en el rango $[0 : 1]$, en el que un valor igual a 1 representa una predicción perfecta, y un valor de aptitud igual a 0 indicaría el error máximo. Donde A representa el conjunto de celdas en el mapa real sin el conjunto de celdas quemadas antes de iniciar la predicción, y B representa las celdas en el mapa simulado

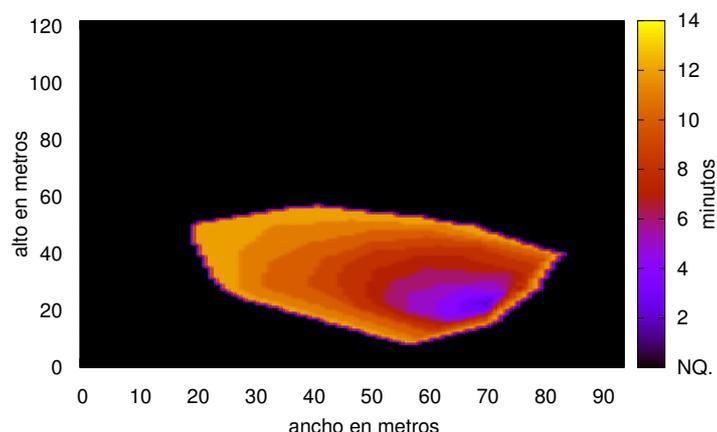


Figura 5: Experimento A: Representación computacional del incendio utilizado por HESS-IM.

sin el conjunto de celdas quemadas antes de la simulación.

$$Fitness = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

La Etapa de Calibración del proceso master (EC_{master}) calcula un mapa de probabilidad, en función de todos los individuos de la población final. Dicho mapa se utiliza para obtener el valor clave de ignición (Key Ignition Value, K_{ign}), el cual representa el patrón de comportamiento del incendio y es obtenido en la etapa Búsqueda del K_{ign} (BK_{ign}).

Para cada instante de tiempo i , cada isla j , genera un $K_{ign}(t_i, j)$ y un mapa de probabilidad $m_p(t_i, j)$, los cuales son enviados a la etapa de calibración del proceso *monitor* ($EC_{Monitor}$). El primero es enviado a $EC_{Monitor}$ en t_{i+1} y el segundo a $EC_{Monitor}$ en t_i , de esta manera se conforma en t_i un par $\{m_p(t_i, \alpha); K_{ign}(t_{i-1}, \alpha)\}$, donde α , indica el número de isla que obtuvo mejor desempeño en términos de aptitud. Éstos valores finalmente son ingresados en la etapa de predicción (EP) la cual realiza el cálculo de predicción (i.e., línea de fuego predicha, LFP) para el próximo instante de tiempo LFR_{i+1} . Debido a esto HESS-IM no pudo generar predicción en el primer instante de tiempo, ya que en dicho momento se calcula el primer K_{ign} .

Experimento	Ancho (m)	Alto (m)	Pendiente (grados)
A	95	123	21
B	75	126	19

Tabla 1: Descripción de los casos de estudio: dimensión, pendiente.

Experimento	Tiempo inicial (min)	Incremento (min)	Tiempo final (min)
A	2	2	12
B	3	1	9

Tabla 2: Descripción de los casos de estudio: tiempo de inicio, fin e incremento.

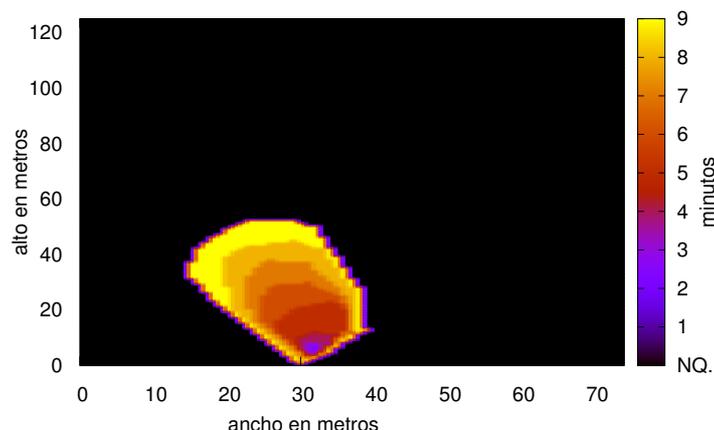


Figura 6: Experimento B: Representación computacional del incendio utilizado por HESS-IM.

4 EXPERIMENTACIÓN Y RESULTADOS

La experimentación fue llevada a cabo mediante de dos casos de quemas controladas reales realizadas en Serra de Louçã (Gestosa, Portugal), ambas en el marco del proyecto SPREAD (Viegas, 2004). La representación computacional de la evolución de cada incendio se puede observar en las Figs. 5 y 6. Con el objetivo de verificar si el nuevo método ofrece mejoras en la calidad de predicción, los resultados de HESS-IM han sido comparados con los de ESS-IM.

La calidad de predicción de ambos métodos ha sido evaluada en ciertos momentos de cada incendio. Estos instantes se denominan pasos de predicción y corresponden a una discretización para representar el avance del frente de fuego. En las Tablas 1 y 2, se puede observar la información de la dimensión y pendiente, para cada uno de los casos de estudio, y también los valores de tiempo inicial y final de cada paso de predicción y su respectivo valor de incremento.

Al igual que el valor de aptitud de los individuos, la calidad de predicción se calcula utilizando la función de fitness descrita en la Sección 3.2 (ver Ec. (1)). Donde un valor igual a 1 representa una predicción clásica, y un valor igual a 0 una predicción completamente errónea. Siguiendo este criterio, a continuación se comentan los resultados obtenidos.

4.1 Caso A

Este caso de estudio corresponde a un incendio forestal realizado en una parcela donde el fuego ha sido iniciado en un único punto de ignición, la simulación tiene una duración total de 10 minutos. En la Fig. 5, se puede observar el área total quemada por el fuego y la forma del frente de fuego en cada minuto, el área de color negro indica que no ha sido quemada (No Quemada, NQ). Resulta interesante observar que a causa de la dirección y velocidad del viento, el fuego se propaga consumiendo una superficie elíptica con una velocidad de propagación considerable, ya que la duración de los intervalos es de 2 minutos.

Luego de aplicar cada método, los resultados de calidad de predicción obtenidos se han graficado en la Fig. 7. A simple vista se puede apreciar que HESS-IM obtiene mejor desempeño en tres de los cuatro pasos de predicción (minuto 6, 8 y 12). En la Tabla 3, se destaca en negrita los mejores valores de cada paso de predicción, además se muestra el promedio que cada método ha obtenido, donde se puede observar que HESS-IM supera a ESS-IM. Si bien desde este punto de vista, la diferencia no es tan evidente, el valor promedio nos sirve como

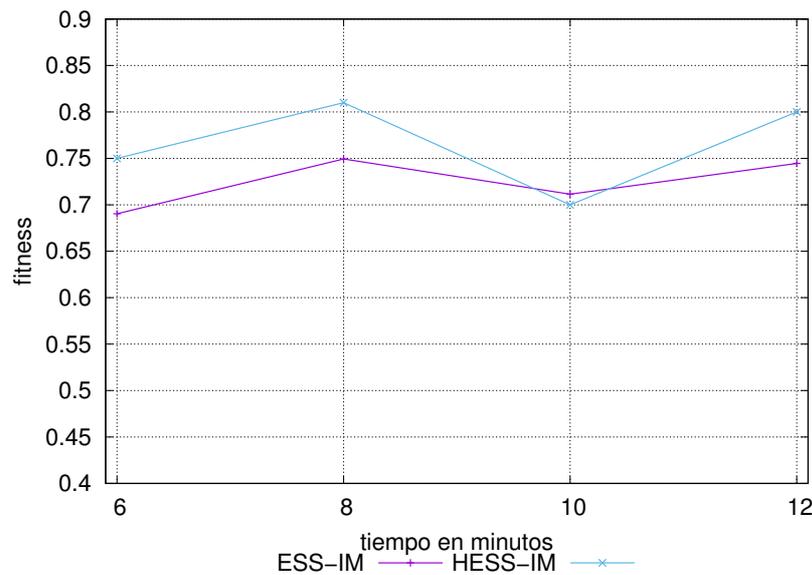


Figura 7: Experimento A: Calidad de predicción obtenida por HESS-IM y ESS-IM para cada paso de predicción.

métrica para determinar, de forma rápida y sencilla, que método ha obtenido mejor calidad de predicción. También se ha marcado con asterisco (*), el mejor registro de calidad de predicción de todo el experimento, el cual ha sido obtenido por HESS-IM en el minuto 8.

Intervalo (min.)	ESS-IM	HESS-IM
2 a 4	-	-
4 a 6	0,6904118	0,75054
6 a 8	0,749375	0,81025*
8 a 10	0,7114272	0,7054
10 a 12	0,744569	0,80584
Promedio	0,72394575	0,7680075

Tabla 3: Caso A: Calidad de predicción y promedio general.

4.2 Caso B

Este incendio tiene una duración menor al caso anterior y presenta algunas características similares, tanto en la forma del foco de ignición, como en las dimensiones del terreno. Como se puede observar en la Fig. 6, el área alcanzada por el fuego es un tanto menor a la del caso A. Para este incendio, el inicio de la simulación se ha fijado en el minuto 3 con incrementos de 1 minuto. Observe que en la Tabla 4, en el primer paso (i.e., intervalo comprendido entre el minuto 3 y 4) ambos métodos no generan predicciones por encontrarse calculando el primer K_{ign} . Al igual que en el caso anterior, la calidad de predicción ha sido representada en la Fig. 8 y la Tabla 4. Si observamos los resultados en la Tabla 4, podemos observar que ESS-IM obtiene el mejor registro de predicción para este incendio en el minuto 8 y además obtiene mejor calidad, en dos de los cinco instantes de predicción. Sin embargo, HESS-IM, obtiene un valor de calidad promedio levemente superior al de ESS-IM, y si observamos las líneas de predicción (Fig. 8), se distingue que HESS-IM ofrece un comportamiento más estable.

Resulta importante mencionar que debido a que ambos métodos poseen un comportamiento

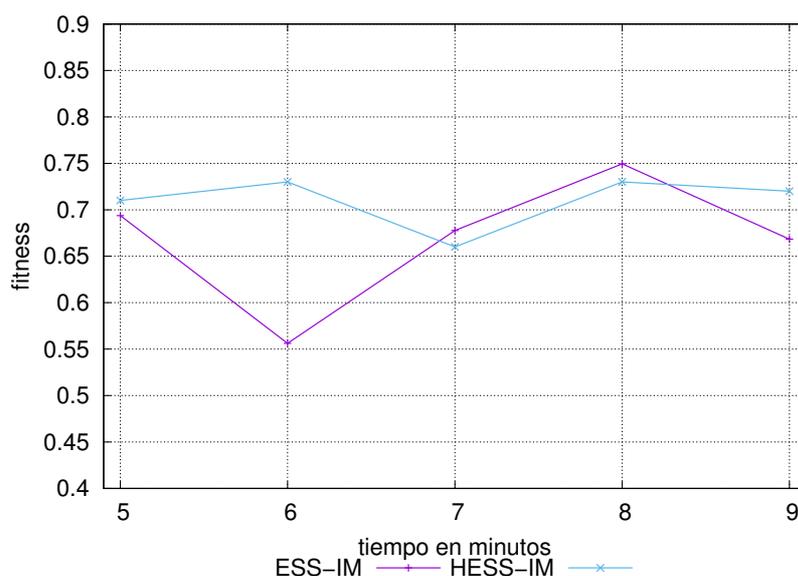


Figura 8: Experimento B: Calidad de predicción obtenida por HESS-IM y ESS-IM para cada paso de predicción.

estocástico, los resultados obtenidos fueron generados a partir del promedio de 20 ejecuciones (i.e., utilizando el mismo conjunto de 20 semillas para ambos métodos). Además, todas las pruebas fueron desarrolladas en un clúster Linux, con 44 núcleos de cómputo distribuidos en 10 CPUs quad-core, con 4 GB de RAM, bajo un entorno MPI (Gropp et al., 2014) y una red Gigabit Ethernet.

Intervalo (min.)	ESS-IM	HESS-IM
3 a 4	-	-
4 a 5	0,6938044	0,71058
5 a 6	0,5562506	0,730468
6 a 7	0,6777686	0,66025
7 a 8	0,749407*	0,73036
8 a 9	0,6683746	0,71985
Promedio	0,66912104	0,7103016

Tabla 4: Caso B: Calidad de predicción y promedio general.

5 CONCLUSIONES

En este trabajo se ha tratado un fenómeno importante que requiere de predicciones precisas para minimizar sus efectos negativos: los incendios forestales. Debido a esto, se ha presentado HESS-IM, un nuevo método de reducción de incertidumbre basado en la cooperación de dos metaheurísticas poblacionales evolutivas: Algoritmos Evolutivos y Evolución Diferencial. HESS-IM ha sido diseñado para operar en ambientes computacionales de alto rendimiento utilizando un esquema de paralelización basado en islas con doble jerarquía master/worker. Dicho método ha sido evaluado mediante su aplicación en la predicción del comportamiento de incendios forestales. Para ello, se ha realizado una comparación de la calidad de predicción entre HESS-IM y una metodología previa (ESS-IM). La experimentación se realizó utilizando dos casos de quemas controladas reales llevadas a cabo en terreno. Los resultados obtenidos indi-

can que el enfoque colaborativo entre diferentes metaheurísticas puede ofrecer mejoras en el mecanismo de optimización global del método, esto se ve reflejado en el incremento de la calidad de los resultados en más del 50% de los pasos de predicción. En base a esto, se plantea como trabajo futuro: a) evaluar el método con incendios reales de grandes superficies, b) realizar un estudio de calibración de los parámetros evolutivos de cada metaheurística involucrada, y c) incorporar otras metaheurísticas poblacionales evolutivas, con el objetivo de incrementar la robustez del método de búsqueda y así obtener mejores resultados.

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

- Alba E. and Tomassini M. Parallelism and evolutionary algorithms. *IEEE Transactions on Evolutionary Computation*, 6, no. 5:443–462, 2002.
- Bui L., Abbass H., and Branke J. Multiobjective optimization for dynamic environments. *2005 IEEE Congress on Evolutionary Computation*, 3:2349–2356, 2005. doi:10.1109/CEC.2005.1554987.
- Buyya R. *High Performance Cluster Computing: Architectures and Systems*. Prentice Hall, PTR, NJ, USA, 1999.
- Collin D. Bevins. fireLib User Manual and Technical Reference. Technical Report, Intermountain Research Station, Forest Service, U.S. Department of Agriculture., 1996.
- Darwin C. *On the origins of species by means of natural selection*. 1859. ISBN 145381468X. doi:10.1126/science.146.3640.51-b.
- Das S., Mullick S., and Suganthan P. Recent advances in differential evolution – an updated survey. *Swarm and Evolutionary Computation*, 27:1–30, 2016. ISSN 2210-6502. doi:http://dx.doi.org/10.1016/j.swevo.2016.01.004.
- Diario La Nación . Tras 11 días, logran controlar el incendio forestal en San Luis. 2016.
- Glover F. Future paths for integer programming and artificial intelligence. *Computers & Operations Research*, 13(5):533–549, 1986.
- Gong Y.J., Chen W.N., Zhan Z.H., Zhang J., Li Y., Zhang Q., and Li J.J. Distributed evolutionary algorithms and their models: A survey of the state-of-the-art. *Applied Soft Computing*, 34(C):286–300, 2015. ISSN 15684946. doi:10.1016/j.asoc.2015.04.061.
- Gropp W., Lusk E., and Skjellum A. *Using MPI : portable parallel programming with the Message-Passing-Interface*. 2014. ISBN 9780262527392.
- Montgomery D. and Runger G. *Applied Statistics and Probability for Engineers*, volume 6th Edition. Limusa Wiley & Sons, New Jersey, 2014.
- Mühlenbein H. Parallel genetic algorithms, population genetics and combinatorial optimization. pages 398–406. Springer Berlin Heidelberg, 1991. doi:10.1007/3-540-55027-5_23.
- Méndez-Garabetti M., Bianchini G., Caymes-Scutari P., and Tardivo M. Increase in the quality of the prediction of a computational wildfire behavior method through the improvement of the internal metaheuristic. *Fire Safety Journal*, 82:49–62, 2016. ISSN 0379-7112. doi:http://dx.doi.org/10.1016/j.firesaf.2016.03.002.
- Real R. and Vargas J.M. The Probabilistic Basis of Jaccard’s Index of Similarity. *Systematic Biology*, 45(3):380–385, 1996. ISSN 1063-5157. doi:10.1093/sysbio/45.3.380.

- Rothermel R. *A mathematical model for predicting fire spread in wildland fuels*, volume II. Res. Pap. INT-115, US Dept. of Agric., Forest Service, Intermountain Forest and Range Experiment Station. (Ogden, UT.), 1972.
- Sitharama Iyengar S. and R.R. B. *Distributed Sensor Networks: Sensor Networking and Applications*, volume Second Edition. Chapman and Hall/CRC, Florida, 2013.
- Viegas D.X. *Project Spread - Forest Fire Spread Prevention and Mitigation*. 2004.
- Yu X. and Gen M. *Introduction to Evolutionary Algorithms*, volume 0 of *Decision Engineering*. Springer London, London, 2010. ISBN 978-1-84996-128-8. doi:10.1007/978-1-84996-129-5.