

ESS-IM: INCREMENTO EN CALIDAD DE PREDICCIÓN MEDIANTE SINTONIZACIÓN DE PARÁMETROS EVOLUTIVOS

Méndez-Garabetti M.A.^{a,b,c}, Bianchini G.^a, Caymes-Scutari P.^{a,b}
y Tardivo M.L.^{a,b,d}

^aLaboratorio de Investigación en Cómputo Paralelo/Distribuido (LICPaD). Departamento de Ingeniería en Sistemas de Información. Facultad Regional Mendoza. Universidad Tecnológica Nacional,

Rodríguez 273, Mendoza, Argentina.

^bConsejo Nacional de Investigaciones Científicas y Técnicas (CONICET), Argentina.

^cInstituto Tecnológico Universitario, Universidad Nacional de Cuyo,

Centro Universitario, Mendoza, Argentina

^dDepartamento de Computación, Universidad Nacional de Río Cuarto. Ruta Nac. 36, Km. 601, Córdoba, Argentina.

e-mail: mmendez@itu.uncu.edu.ar

RESUMEN

Anualmente, los incendios forestales consumen aproximadamente dos millones de hectáreas de forestación alrededor del mundo, causando diversas pérdidas desde el punto de vista ambiental, económico y humano. Sin duda, esto convierte a los incendios forestales en uno de los fenómenos naturales más perjudiciales de la actualidad. Con el objetivo de reducir los efectos negativos causados por este tipo de fenómenos, continuamente se desarrollan estrategias y herramientas para la prevención, monitoreo y/o predicción de incendios. Los sistemas de predicción suelen ver afectada su calidad de predicción debido a la existencia de incertidumbre en los datos de entrada (generalmente por dificultades para cuantificar los valores en tiempo real). Ante esta situación los métodos de reducción de incertidumbre permiten contrarrestar dichos efectos mejorando la calidad de predicción por medio de diferentes técnicas y estrategias. Tal es el caso del Sistema Estadístico Evolutivo con Modelo de Islas (ESS-IM), el cual es un método 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 (AEP). Los AEP pertenecen al conjunto de técnicas de optimización conocidas como Metaheurísticas, las cuales poseen ciertos parámetros de configuración inicial, que determinan el modo de operar del algoritmo. Es importante realizar una correcta elección de los valores de estos parámetros ya que de ellos depende el comportamiento de la estrategia para la búsqueda de nuevas soluciones, lo que impacta drásticamente en la calidad de los resultados del método (en este caso, la calidad de predicción). Por lo tanto, el objetivo del presente trabajo consiste en desarrollar un análisis de sintonización de sus parámetros evolutivos que permitan incrementar la calidad de predicción de ESS-IM.

Palabras Clave: Incendios Forestales, Predicción, Sintonización, Algoritmos Evolutivos, Modelo de Islas.

INTRODUCCIÓN

Los incendios forestales son uno de los fenómenos que más perjudican a los ecosistemas alrededor de todo el mundo, éstos causan importantes pérdidas económicas y materiales. Si bien ciertas condiciones naturales como: la deshidratación en la vegetación, largos periodos de sequía, bajos índices de humedad y altos valores de temperatura, favorecen la generación de incendios, la mayoría ocurren debido a accidentes humanos o deliberadamente planificados. A modo de ejemplo, se puede mencionar el incendio forestal ocurrido en enero de 2016, en el Parque Nacional Los Alerces provincia de Chubut, Argentina (Figura 1), donde se consumieron más de 1600 hectáreas de bosques nativos [1]. Dicho incendio provocó daños irreversibles en la flora y fauna autóctona del lugar.

Si bien es importante identificar las causas que originan los incendios, también es de interés conocer los factores que propician su propagación, como la velocidad del viento, el combustible, el tipo de vegetación, la topografía del terreno, entre otros. En este contexto, no solo importa trabajar en campañas de prevención, sino también en el desarrollo de herramientas o métodos que ayuden en la toma de decisiones a la hora de combatir los incendios forestales. Tal es el caso de las técnicas que permiten pronosticar el comportamiento del fuego una vez iniciado el incendio.

El comportamiento de un incendio forestal depende de diversos factores, desde el clima, la topografía del terreno, el tipo de vegetación (combustible), entre otros. Por lo general, al momento de realizar la predicción de un incendio forestal, se presenta cierta dificultad para determinar los valores de las variables que determinan el comportamiento del mismo. Debido a esto, las predicciones realizadas mediante técnicas clásicas, no suelen brindar resultados de calidad, por lo que es necesario recurrir a métodos que permitan minimizar la falta de precisión o incertidumbre en la entrada del sistema. Tal es el caso del Sistema Estadístico Evolutivo con Modelo de Islas (ESS-IM) [2,3], el cual es un método general de reducción de incertidumbre, que ha sido aplicado con éxito en la predicción del comportamiento de incendios forestales. ESS-IM utiliza Algoritmos Evolutivos Paralelos [4] (AEPs), como herramienta de optimización, con un esquema de paralelización multipoblacional basado en islas y técnicas de sintonización estática [5].

Los AEPs poseen diferentes parámetros de configuración que determinan el modo en que el algoritmo operará en busca de buenas soluciones. En el presente trabajo se presenta un estudio de optimización de los parámetros evolutivos de migración de ESS-IM, ya que al operar el método con una configuración óptima de parámetros, es posible alcanzar resultados de mejor calidad, lo que equivale a obtener predicciones más cercanas a la realidad. Además, es importante mencionar que ESS-IM opera en un ambiente de computación de alto rendimiento, donde una configuración óptima de parámetros puede permitir realizar una utilización de recursos más eficiente.

En la siguiente sección se provee una breve explicación de los EAs y los AEPs. Posteriormente se comenta la técnica de sintonización utilizada, junto con los parámetros evolutivos evaluados. A continuación se proporciona una descripción del funcionamiento del método ESS-IM. Seguidamente se brindan los detalles de los experimentos realizados, se describe el entorno de trabajo, y a continuación se exponen los resultados obtenidos. Finalmente, se presentan las conclusiones y el trabajo futuro.



Figura 1: Incendio forestal en Parque Nacional los Alerces, Chubut, Argentina (enero de 2016).

ALGORITMOS EVOLUTIVOS

La metaheurística conocida como Algoritmos Evolutivos (EAs), es un método búsqueda inspirado en la teoría de la evolución biológica de Darwin [6], para la resolución de problemas de optimización [7]. El algoritmo consiste en un proceso basado en iteraciones, las cuales se denominan generaciones evolutivas. Esta metaheurística agrupa las posibles soluciones en un conjunto llamado población, donde cada solución se representa por un individuo. Dicha población evoluciona, de generación en generación, imitando los principios de selección natural y supervivencia, esperando que se llegue a una solución aceptable para el problema tratado. Es importante mencionar que cada individuo posee un valor de aptitud, el cual determina la calidad de dicha solución para el problema tratado. Este valor es calculado mediante la función matemática que describe el problema, y juega un rol fundamental ya que permite caracterizar a los individuos según sus capacidades. De esta manera, aquellos individuos con mejor aptitud, deben tener mayor probabilidad de sobrevivir, de no ser reemplazados, de reproducirse, y así dejar sus rasgos hereditarios a las generaciones futuras [8].

En la Figura 2, se puede observar un esquema básico de un AE, donde g identifica el número de generaciones y $Pob(g)$ representa la población de individuos en la g -ésima generación. Para cada iteración g , se selecciona un grupo de individuos de la población actual $Pob(g)$, donde se garantiza que las buenas soluciones tengan mayor probabilidad de ser elegidas. Posteriormente, sobre este subconjunto de individuos, se aplican los operadores evolutivos (cruzamiento, mutación y reemplazo), que imitan el proceso de adaptación natural.

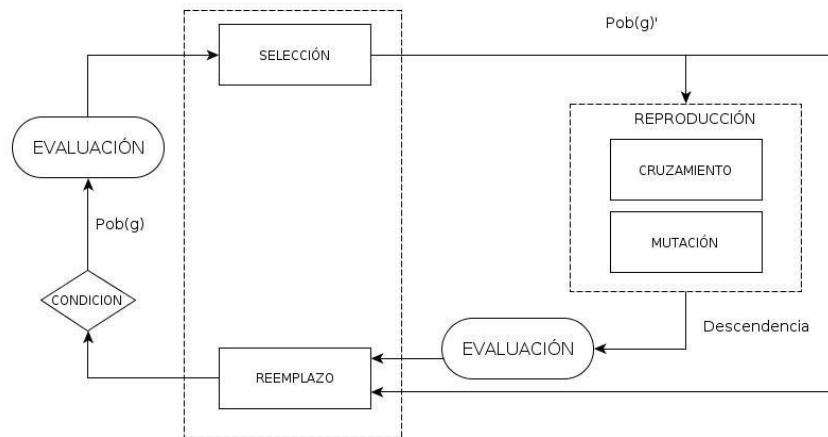


Figura 2: Esquema general del funcionamiento de un AE.

El operador de selección elige cierta cantidad de individuos, los cuales serán los progenitores de la nueva generación. Posteriormente éstos son sometidos al proceso de reproducción, para generar los nuevos individuos. Existen dos operadores de reproducción, por un lado el operador de cruzamiento, el cual actúa sobre pares de individuos creando otro par de individuos descendientes. Y por otro, el operador de mutación, el cual actúa sobre un solo individuo. La mutación introduce cierto grado de diversidad, con el objetivo explorar de forma más eficiente el espacio de búsqueda. Por último, se realiza el reemplazo, proceso que consiste en sobrescribir ciertos individuos de la población actual en con la descendencia. Una estrategia consiste en reemplazar de forma inmediata los progenitores con los descendientes, otra opción puede ser reemplazar aquellos individuos de la población que posean características más similares a los descendientes, o reemplazar aquellos individuos que posean los peores valores de fitness.

Algoritmos Evolutivos Paralelos

Cuando un AE es utilizado para resolver problemas de alta complejidad, i.e., muy demandantes de tiempo o recursos, éstos suelen ser implementados de forma paralela para ser ejecutados en sistemas de computación de alto desempeño o HPC [9]. La paralelización divide la carga de trabajo en N unidades de cómputo, reduciendo el tiempo de procesamiento. Al igual que los AE, los AEP se basan en el concepto de supervivencia, el cual permite eliminar de la población aquellos rasgos perjudiciales y garantizar la permanencia de las mejores características en las futuras generaciones.

Los AEP pueden ser clasificados en función de diferentes criterios: según la cantidad de poblaciones involucradas, el tratamiento de los operadores, la relación cómputo/comunicación, entre otros. En [10], los AEPs se dividen en: paralelismo automático a nivel del compilador, master/worker con única población y evaluación en paralelo, paralelismo de grano grueso, distribuido o basado en islas (múltiples poblaciones) y de grano fino o masivamente paralelo. En [11], la clasificación de los

mismos se divide en: modelo master-slave, modelo de islas, modelo celular y modelo jerárquico.

En ESS-IM, se utiliza un esquema de paralelización híbrido basado en islas con doble jerarquía master-worker (Figura 3). En esta estrategia de paralelización se opera con múltiples poblaciones, también llamadas islas. Aquí los operadores evolutivos son aplicados entre individuos de la misma isla. Con el objetivo de que las islas no evolucionen de forma independiente, se introduce un operador de migración. La migración agrega diversidad y disminuye la probabilidad de convergencia prematura mediante el intercambio de individuos entre las diferentes islas.

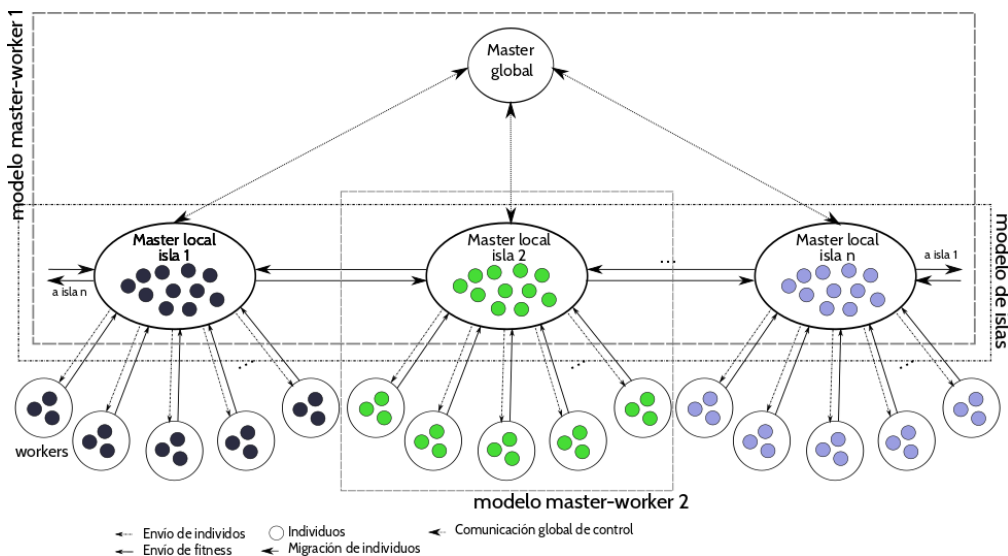


Figura 3: Esquema de paralelización híbrido basado en islas con doble jerarquía master-worker.

SINTONIZACIÓN DE PARÁMETROS

Toda metaheurística posee ciertos parámetros de configuración inicial, los cuales determinan aspectos fundamentales sobre el funcionamiento interno del algoritmo. Seleccionar de forma correcta dichos valores no es una tarea sencilla, ya que no existe una configuración óptima y universal de parámetros, y además, éstos suelen ser dependientes de las características del problema. Para obtener una configuración óptima de éstos parámetros, se necesita someter el algoritmo a un proceso de análisis y ajuste denominado calibración o sintonización [5].

La calibración de parámetros puede realizarse de forma off-line u online. La primera, consiste en determinar valores fijos para cada parámetro antes de ejecutar la metaheurística. Para relevar los resultados, se define un conjunto de experimentos a realizar con diferentes configuraciones de parámetros, se analizan los resultados obtenidos y se obtiene la mejor configuración. La segunda técnica consiste en

determinar los valores de los parámetros de manera dinámica, mientras la metaheurística se encuentra en funcionamiento [5]. En este trabajo se ha realizado una calibración de parámetros off-line o estática.

Parámetros Evolutivos

Si bien los AEPs poseen diferentes parámetros que configuran su funcionamiento, la calibración debe ser limitada sólo a aquellos sobre los que se tenga interés de optimizar. En este trabajo, se ha seleccionado un subconjunto de parámetros, los cuales están relacionados con la función de migración de individuos:

1. **Criterio migración:** Este parámetro indica la forma en que serán seleccionados los individuos que migrarán, también indica qué va a ocurrir con los nuevos individuos que se incorporen de otras poblaciones.
Elitista: los mejores individuos reemplazan los peores, semi-elitista: el 50% de los individuos enviados corresponden a los mejores y el otro 50% se escoge de forma aleatoria –el reemplazo sigue el mismo criterio–, aleatorio: los individuos son seleccionados y reemplazados al azar).
2. **Cantidad de individuos a migrar:** Determina el número de individuos que deben ser migrados hacia las islas vecinas al producirse una migración.
3. **Frecuencia de migración:** Establece cuando ocurre la migración, una configuración habitual suele ser en función del número de iteraciones. Es importante tener en cuenta que la migración introduce una sobrecarga de comunicación, por lo que éste parámetro se debe determinar cuidadosamente.

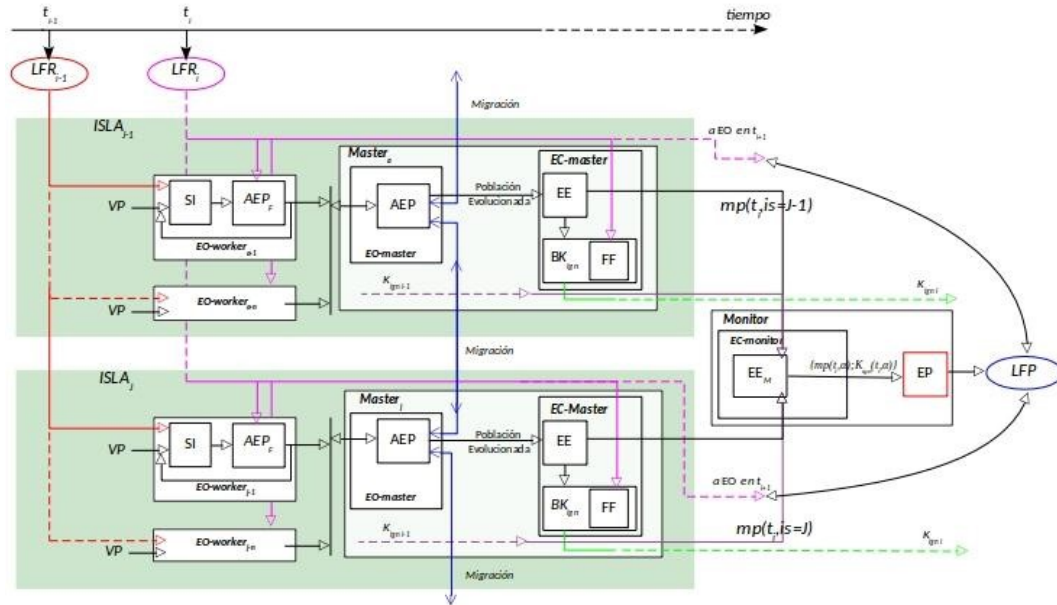
METODOLOGÍA DE FUNCIONAMIENTO DE ESS-IM

Tal como se comentó anteriormente, ESS-IM es un método de reducción de incertidumbre basado en Algoritmos Evolutivos Paralelos, bajo un esquema de paralelización basado en islas. ESS-IM ha sido aplicado en la predicción del comportamiento de incendios forestales de forma satisfactoria, mediante su aplicación a casos reales de quemas controladas.

Un esquema general del funcionamiento de ESS-IM se observa en la Figura 4. El proceso monitor, es el encargado de iniciar el funcionamiento del método, mediante el envío de la información del incendio a los masters de cada isla. Dicha información contiene el mapa real del incendio (LFR_x), los rangos de valores para cada uno de los parámetros de entrada y los valores de configuración de los parámetros evolutivos del AEP.

Posteriormente, se da inicio al proceso evolutivo en la Etapa de Optimización del proceso master (EO_{Master}), puntualmente en la subetapa AEP. Esta etapa se encarga de inicializar la población, aplicar los operadores evolutivos, enviar los individuos a los workers para ser evaluados, y finalmente avanzar hacia la siguiente generación. Cada proceso Worker, recibe un individuo por vez, los cuales son simulados en la etapa Simulación de Incendios (SI). Para ello se utiliza el frente de fuego real del incendio en

t_{i-1} (LFR_{i-1}) y los valores de cada individuo (VP). La etapa AEP_F es la encargada de realizar la evaluación de la aptitud de cada individuo. Finalmente, EO_{Worker} devuelve cada individuo evaluado a su respectivo master de isla, donde la etapa AEP , se encarga de almacenar los resultados parciales, evolucionar la población y migrar los individuos hacia las islas vecinas. Este procedimiento se repite hasta que se cumpla alguna condición de finalización.



Línea de fuego real en i — Línea de fuego real en $i-1$ — Migración — $K_{ign} i-1$ — $K_{ign} i$ —

Figura 4: Esquema general del Sistema Estadístico Evolutivo con Modelo de Islas: SI: simulador de incendios; AEP: algoritmo evolutivo paralelo; AEP_F : algoritmo evolutivo paralelo (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.

Cuando el proceso evolutivo ha terminado, AEP envía la población a la Etapa de Calibración del proceso master (EC_{Master}), puntualmente en la Etapa Estadística (EE). EE se encarga de generar un mapa de probabilidad (m_p), que se crea al considerar la totalidad de los mapas simulados de cada individuo. El m_p generado en t_i por la isla is ($is = 1, 2, \dots, j$), i.e. $m_p(t_i, is)$, es utilizado para calcular el patrón de comportamiento del incendio (valor clave de ignición K_{ign}), en la sub-etapa BK_{ign} (búsqueda de K_{ign}). Es importante remarcar que cada isla is genera en t_i un $K_{ign}(t_i, is)$, y un $m_p(t_i, is)$, por lo que cada isla envía al proceso monitor un $m_p(t_i, is)$ y un $K_{ign}(t_{i-1}, is)$.

Cuando los resultados de todas las islas son recibidos en el proceso monitor ($EC_{Monitor}$), en la subetapa Estadística del Monitor ($EE_{Monitor}$), ésta genera en t_i un par $\{m_p(t_i, \alpha); K_{ign}(t_i, \alpha)\}$, donde α , representa la isla cuyo par de valores ha obtenido el

mejor valor de aptitud. Este conjunto de datos es enviado a la Etapa de Predicción (EP) para generar la línea el pronóstico de la línea de fuego en el instante t_i (i.e., LFP_i).

DESARROLLO EXPERIMENTAL

Para el análisis de sintonización se utilizó un incendio controlado realizado en Portugal bajo el proyecto Spread [15]. Dicho experimento cuenta con 4 pasos de simulación (minuto 4, 6, 8 y 10). La evaluación de la calidad de predicción se calcula mediante una función que determina entre 0 y 1, el grado de precisión. Donde un valor igual a 1 representa una predicción perfecta, y un valor igual a 0, indica una predicción completamente errónea.

Tabla I: Parámetros y rangos utilizados en el análisis de sintonización.

Nº	Parámetro	Rango
1	Criterio migración	elitista, semi-elitista, aleatorio
2	Cantidad de individuos a migrar	1 al 10 (%)
3	Frecuencia de migración	1 a 20 (%)

Tabla II: Casos más relevantes de la configuración de experimentos (LHD).

Exp.	Criterio migración	Cantidad de individuos a migrar	Frecuencia de migración
1	Elitista	8%	4%
2	Aleatorio	3%	14%
3	Semi-elitista	6%	2%
4	Semi-elitista	2%	14%
5	Aleatorio	4%	17%
6	Semi-elitista	3%	8%
7	Semi-elitista	1%	11%
8	Semi-elitista	8%	7%
9	Elitista	10%	19%
10	Aleatorio	9%	6%

Para cada uno de los parámetros incluidos en el análisis de calibración, se han fijado rangos de valores en función de experimentaciones previas, los cuales son detallados en la Tabla I. Para establecer la cantidad de experimentos y la configuración de parámetros de cada uno de ellos, se ha recurrido a un Diseño por Hipercubo Latino (DHL) [12,13]. El DHL ha sido conformado por un total de 10 experimentos, cada uno con diferente configuración de valores para cada parámetro. En la Tabla II, se puede observar la configuración de parámetros de cada experimento.

La experimentación consistió en lanzar las 10 configuraciones de parámetros del LHD, sobre el mismo incendio controlado y con las mismas poblaciones iniciales de indivi-

duos. Cada configuración de parámetros fue ejecutada 30 veces, y se tomó como resultado final el promedio de las mismas. Es importante resaltar, que se utilizaron poblaciones iniciales diferentes para cada uno de las 30 ejecuciones, pero dicho grupo de poblaciones fue el mismo para cada configuración de parámetros.

RESULTADOS

En la Tabla III, se observan los valores de calidad de predicción obtenidos para cada configuración de parámetros (fila 1 a 10). Los valores de la fila 0, corresponden a los mejores valores obtenidos en trabajos previos, mediante una calibración de parámetros evolutivos [16]. En dicha tabla se resaltan en negrita, las 3 configuraciones de parámetros que brindan la mejor calidad de predicción, se subraya la peor y se denota con “*” el mejor valor para cada paso de predicción.

Tabla III: Calidad de predicción en cada paso de simulación.

Experimentos	Pasos de predicción			
	4	6	8	10
0	0,73	0,7704*	0,7398	0,779*
1	0,7485*	0,7509	0,74080	0,76826
2	0,6382	0,4025	0,3508	0,5561
3	0,7053	0,6585	0,70856	0,652
4	0,468	0,785	0,6886	0,589
5	0,552	0,6245	0,4268	0,4095
6	0,7056	0,4652	0,665	0,6824
7	0,3606	0,4450	0,5654	0,5825
8	0,4595	0,5654	0,465	0,7066
9	0,7305	0,76784	0,7485*	0,7096
<u>10</u>	<u>0,39756</u>	<u>0,24456</u>	<u>0,30756</u>	<u>0,4459</u>

Como se puede observar, el peor valor de fitness es obtenido por la configuración que utiliza un esquema de migración aleatorio (experimento 10), junto con una alta frecuencia de migración (i.e., un valor de frecuencia de migración bajo en porcentaje equivale a una frecuencia de migración elevada). Respecto a las mejores configuraciones, se observa claramente que el criterio elitista es el que mejor calidad genera (experimentos 1 y 9), junto con valores moderados de frecuencia de migración y cantidad de individuos migrados. El esquema semi-elitista, también aparece en el ranking de los mejores resultados (experimento 3), con una alta frecuencia de migración y cantidad moderada de individuos migrados.

Al igual que [16], no es posible identificar la mejor configuración de parámetros, ya que puede observarse claramente que los mejores valores de cada paso, celdas marcadas con “*”, se encuentran en diferentes experimentos. Pero si podemos determinar, que un criterio elitista aporta positivamente al mecanismo de búsqueda, y que uno aleatorio genera el efecto contrario.

Además, es importante notar que el 50% de los mejores resultados han sido obtenidos por la configuración de la fila 0, i.e., la obtenida en [16], donde diferentes configuraciones de parámetros son utilizadas en cada paso de predicción.

CONCLUSIONES

En el presente trabajo se ha realizado un análisis de sintonización de los parámetros evolutivos del método ESS-IM, puntalmente de aquellos vinculados con el mecanismo de migración del AEP. Para efectuar dicho análisis, ESS-IM fue aplicado en la predicción del comportamiento de un incendio forestal controlado. Los rangos de valores, para cada parámetro bajo análisis, fueron tomados a partir de trabajos previos. Tras efectuar las experimentaciones se pudo determinar que un criterio de migración elitista brinda robustez al mecanismo de búsqueda, junto con valores moderados de cantidad de individuos a migrar y frecuencia de migración. Además, que un proceso de migración aleatorio, desestabiliza el funcionamiento del método haciendo decaer la calidad de predicción, posiblemente porque la aleatoriedad no garantiza mantener individuos de buenas características en las generaciones futuras. Al igual que en trabajos previos se sostiene que no es conveniente recomendar una configuración única de parámetros evolutivos, ya que los mejores resultados son obtenidos mediante diferentes configuraciones. Debido a esto se está trabajando en la implementación de una versión de ESS-IM donde las islas operan con una configuración heterogénea de parámetros. Finalmente, como trabajo futuro se pretende realizar mayor cantidad de experimentaciones que permitan determinar la interdependencia de parámetros.

REFERENCIAS

- [1] Infobae, El incendio forestal en Chubut sigue sin control: ya se quemaron 1.600 hectáreas, <http://www.infobae.com/2016/01/24/1785121-el-incendio-forestal-chubut-sigue-control-ya-se-quemaron-1600-hectareas/>
- [2] M. Méndez-Garabetti, G. Bianchini, M. L. Tardivo, P. Caymes-Scutari: Comparative Analysis of Performance and Quality of Prediction Between ESS and ESS-IM, *Electronic Notes in Theoretical Computer Science*, Volume 314, ISSN 1571-0661, <http://dx.doi.org/10.1016/j.entcs.2015.05.004>. (2015) 45-60
- [3] M. Méndez-Garabetti, G. Bianchini, P. Caymes-Scutari, M. L. Tardivo: 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>. (2016) 49-62
- [4] E. Alba y M. Tomassini: Parallelism and evolutionary algorithms, *Evolutionary Computation*, *IEEE Transactions on*, vol. 6, no. 5, (2002) 443-462.
- [5] E. Talbi, *Metaheuristics: From Design to Implementation*, John Wiley and Sons, 2009.
- [6] C. Darwin: *On the Origin of Species by Means of Natural Selection*. Murray, London, 1859.
- [7] D. Goldberg: *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley Longman Publishing Co. Inc. Boston, 1989.

- [8] T. Mattson, B. Sanders y B. Massingill: Patterns for Parallel Programming. Addison-Wesley, 2005.
- [9] R. Buyya, High Performance Cluster Computing: Architectures and Systems, Prentice Hall, 1999.
- [10] E. Alba, J. M. Troya: A survey of parallel distributed genetic algorithms, Complexity 4 (4), DOI=[http://dx.doi.org/10.1002/\(SICI\)1099-0526\(199903/04\)4:4<31::AID-CPLX5>3.3.CO;2-W](http://dx.doi.org/10.1002/(SICI)1099-0526(199903/04)4:4<31::AID-CPLX5>3.3.CO;2-W). (1999) 31-52.
- [11] Y. Gong, W. Chen, Z. Zhan, J. Zhang, Y. L., Q. Z., J. L.: Distributed evolutionary algorithms and their models: A survey of the state-of-the-art, Applied Soft Computing, Volume 34, ISSN 1568-4946, <http://dx.doi.org/10.1016/j.asoc.2015.04.061>. (2015) 286-300
- [12] M.D. McKay, R.J. Beckman, W.J. Conover: A comparison of three methods for selecting values of input variables in the analysis of output from a computer code, Technometrics, 21(2), (1979) 239-245
- [13] R.L. Iman y W.J. Conover, Small sample sensitivity analysis techniques for computer models, with an application to risk assessment, Communications in Statistics, Part A. Theory and Methods, Vol. 17, (1980) 1749-1842.
- [14] R Core Team (2015). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>, 2015.
- [15] D. X. Viegas: Project Spread - Forest Fire Spread Prevention and Mitigation, <http://www.algosystems.gr/spread/>, 2004.
- [16] M. Méndez Garabetti, G. Bianchini, P. Caymes Scutari, M. L. Tardivo, Sistema Estadístico Evolutivo con Modelo de Islas: Calibración de parámetros evolutivos, 13 y 14 de Agosto de 2015, 6th International Symposium on Innovation and Technology, ISSN 2305-9958, ISBN 978-612-45917-9-2, IITEC, IITEC (International Institute of Innovation and Technology), Lima (Perú) (2015) 77-81