

Ajuste de Parámetros Evolutivos para el Método Paralelo de Reducción de Incertidumbre ESSIM-DE

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

¹ Laboratorio de Investigación en Cómputo Paralelo/Distribuido (LICPaD), Departamento de Ingeniería en Sistemas de Información (UTN-FRM), 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.

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

Abstract. Los incendios forestales son uno de los fenómenos naturales más perjudiciales del planeta. Año tras año devastan miles de hectáreas y causan cambios irreversibles en las zonas afectadas. Por tal motivo, surge el interés de contar con herramientas que puedan realizar pronósticos con antelación al desarrollo de los incendios. Sin embargo, los sistemas de predicción suelen presentar restricciones, no solo por las limitaciones computacionales de representación, sino también por la existencia de incertidumbre en los datos de entrada, debido a la dificultad de determinar sus valores con exactitud en tiempo real. Una adecuada determinación de los parámetros de entrada puede mejorar significativamente la calidad de predicción del método. En este trabajo se presenta un estudio de sintonización estática de los parámetros evolutivos del Sistema Estadístico Evolutivo con Modelo de Islas y Evolución Diferencial, con el fin de mejorar la calidad de la predicción.

Keywords: Reducción de Incertidumbre, Paralelismo, Análisis Estadístico, Sintonización Estática, Incendios Forestales.

1 Introducción

Los incendios forestales son el resultado de interacciones complejas entre las condiciones del medio ambiente, la topografía del terreno, los focos de ignición y el tipo de combustible presente en el terreno. Si bien son un componente necesario para mantener el equilibrio de los ecosistemas, se pueden convertir en una gran amenaza para la población bajo ciertas condiciones ambientales, como sequía prolongada y temperaturas altas. En la actualidad se realiza un gran esfuerzo a nivel científico para desarrollar técnicas y estrategias que logren reducir los efectos causados por los

incendios. En particular, el desarrollo de métodos de predicción puede colaborar de manera significativa en el proceso de lucha contra el fuego. La predicción de cualquier fenómeno natural implica la construcción de modelos que permitan describir su comportamiento, a fin de representar de la mejor manera posible la complejidad inherente al fenómeno. Generalmente, los modelos reciben un conjunto de parámetros de entrada representando las condiciones particulares del fenómeno, y proveen una salida que refleja la evolución del mismo. En el caso de los incendios forestales, los parámetros pueden representar la dirección y velocidad del viento, la pendiente del terreno, la humedad y tipo de vegetación, etc. Sin embargo, alguno de estos parámetros poseen valores que cambian dinámicamente durante el desarrollo del incendio, y además presentan dificultades para ser medidos en tiempo real. Esta falta de precisión se conoce como incertidumbre, y para que el modelo se aproxime de la mejor manera posible a la realidad, se hace necesario contar con estrategias de reducción de incertidumbre en los parámetros de entrada.

El Sistema Estadístico Evolutivo con Modelo de Islas y Evolución Diferencial (ESSIM-DE, por sus siglas en inglés) es un método de simulación y reducción de incertidumbre que ha sido aplicado satisfactoriamente al problema de la predicción de incendios forestales [8]. ESSIM-DE utiliza Análisis Estadístico, Computación de Alto Desempeño y la metaheurística Evolución Diferencial como método de optimización. ESSIM-DE posee dos clases de parámetros de entrada. Por un lado, incluye los parámetros que se utilizan para representar las condiciones inherentes al incendio forestal. Entre ellos encontramos las condiciones climáticas del entorno (velocidad y dirección del viento) y las condiciones del terreno donde se desarrolla el incendio (pendiente del terreno, tipo de vegetación, humedad de la vegetación, etc). Por otro lado, posee parámetros de control relativos a los métodos de cálculo que utiliza en su esquema de procesamiento. Una adecuada elección de los parámetros de control implica obtener una mejor caracterización de las posibles zonas afectadas por el fuego, brindando una mejor representación del fenómeno real. En este trabajo presentamos un estudio de calibración estática sobre los parámetros evolutivos de ESSIM-DE. Estos parámetros son necesarios para establecer la operatividad del método de manera tal de orientar la búsqueda hacia mejores soluciones.

El trabajo se organiza de la siguiente manera. La sección 2 describe brevemente los diferentes métodos de predicción. La sección 3 detalla el método ESSIM-DE, incluyendo las diferentes etapas de su modo de operación y su diseño computacional. La sección 4 presenta los experimentos realizados para calibrar los parámetros evolutivos de ESSIM-DE, incluyendo los resultados obtenidos. Finalmente, la sección 5 enuncia las principales conclusiones y trabajos a futuro.

2 Métodos de predicción

En términos generales, los métodos de Predicción Clásica consisten en evaluar la posición del fuego luego de cierto período inicial, utilizando algún tipo de simulador del comportamiento de incendios. Un esquema general de este tipo de métodos se

describe en la Figura 1. El Simulador de Incendios (**SI**) es alimentado por dos conjunto de datos: la línea de fuego real del incendio en el tiempo t_n (**LFR_n**), y la información que describe el entorno en el cual se desarrolla el incendio.




Fig. 1. Predicción Clásica (**SI**: Simulador de Incendios, **LFR**: Línea de Fuego Real, **LFP**: Línea de Fuego de Predicción, **LFR_n**: Línea de Fuego Real en el instante n , **VP**: vector de parámetros).

Generalmente la línea de fuego real es representada por un mapa que describe el área en donde el fuego se ha iniciado para un instante de tiempo determinado. Cada parámetro de entrada tiene un valor asignado, y el conjunto de parámetros es utilizado junto con la **LFR_n** por el **SI** para realizar la predicción de la línea de fuego (**LFP**) para el siguiente instante de tiempo (t_{n+1}), a través de una única simulación. Ejemplos de predicción clásica aplicados a incendios forestales son [1] y [2]. Dadas la complejidad del modelo, la incertidumbre sobre los parámetros de entrada y debido a que la predicción está basada en una única simulación, esta metodología de predicción generalmente provee predicciones que son lejanas a la realidad.

Otro tipo de estrategias de predicción son los Métodos Conducidos por Datos con Múltiples Soluciones Solapadas (Data Driven Methods with Multiple Overlapped Solutions- DDM-MOS). Los DDM-MOS consideran un mayor número de valores para cada parámetro, en vez de considerar un solo valor como los métodos clásicos. Los DDM-MOS realizan un proceso de búsqueda utilizando algún algoritmo o heurística para encontrar el conjunto de parámetros que mejor describe el comportamiento previo del incendio, de manera tal que pueda ser utilizado para predecir el comportamiento futuro cercano de la evolución del incendio, basado en el principio de localidad espacial y temporal. Finalmente los DDM-MOS generan un conjunto de posibles soluciones con casos solapados y combinaciones de parámetros para realizar predicciones. Ejemplos de DDM-MOS son [3] [4] y [5]. La operatividad de estos métodos se basa en la utilización de Análisis Estadístico, Computación de Alto Desempeño y Algoritmos Evolutivos Paralelos.

3 Sistema Estadístico Evolutivo con Modelo de Islas y Evolución Diferencial (ESSIM-DE)

El Sistema Estadístico Evolutivo con Modelo de Islas y Evolución Diferencial (ESSIM-DE) es un método de reducción de incertidumbre que se enmarca dentro de

los DDM-MOS y que ha sido aplicado satisfactoriamente a la predicción de incendios forestales. ESSIM-DE utiliza como metaheurística principal a Evolución Diferencial para orientar la búsqueda hacia mejores soluciones en cada paso de simulación y además utiliza una doble jerarquía Master/Worker en su esquema de comunicación.

3.1 Evolución Diferencial

El algoritmo Evolución Diferencial (DE) se clasifica dentro de los Algoritmos Evolutivos y ha sido utilizado con éxito en diferentes problemas de optimización de funciones [6]. En su operador de mutación, utiliza diferencias de vectores para orientar la búsqueda hacia soluciones de mejor calidad. DE comienza generando una población inicial de individuos con valores aleatorios dentro de los rangos del problema. En cada generación g se recorre la población y por cada individuo $X_{i,g}$ el proceso de mutación consiste en seleccionar al azar tres individuos de la población diferentes entre sí ($X_{r1,g}$, $X_{r2,g}$ y $X_{r3,g}$). Estos tres individuos son utilizados en un operador de recombinación basado en la diferencia de vectores y en un factor de mutación F para generar un nuevo vector $V_{i,g}$, denominado *vector mutante*.

En la etapa de cruzamiento, el vector mutante es combinado con el individuo $X_{i,g}$ para generar un nuevo vector $U_{i,g}$, denominado *vector trial*. Este vector posee características de ambos progenitores y la herencia es regulada por un parámetro del algoritmo denominado *probabilidad de cruzamiento (CR)*. Finalmente, en la etapa de selección se determina el mejor candidato entre el individuo corriente $X_{i,g}$ y el vector trial $U_{i,g}$. Aquel que tenga mejor valor respecto de la función a optimizar será el que sobrevivirá a la generación siguiente, es decir, siendo f la función a optimizar, $U_{i,g}$ reemplaza a $X_{i,g}$ si y solo si $f(U_{i,g}) < f(X_{i,g})$ (para problemas de minimización), caso contrario, no ocurre reemplazo o selección.

Como puede observarse, el algoritmo DE sigue un esquema de procesamiento secuencial, iterando sobre la población a través de las generaciones y aplicando los operadores evolutivos. Si bien DE tiene un gran potencial y ha sido utilizado en una gran variedad de problemas de optimización concretos, su desempeño puede ser mejorado agregando modificaciones a la estructura de procesamiento original con el fin de obtener mejoras significativas [7]. En este trabajo se utiliza un esquema de paralelización de doble jerarquía y modelo de islas.

3.2 ESSIM-DE: Descripción operativa

El Modelo de Islas consiste en organizar los procesos en grupos, cada uno con una población diferente. Las islas intercambian individuos de manera periódica a través del proceso de migración. Desde una visión jerárquica, los procesos están organizados en dos niveles. En una jerarquía superior se dispone de un proceso denominado **Monitor**, que es el encargado de enviar información de inicialización a cada isla, recolectar los datos procesados en la etapa final de la simulación y determinar los valores de salida, identificando cuál es la isla que ha resultado con mejor aptitud. La Figura 2 describe el diagrama general de ESSIM-DE. Se puede observar que el

componente **Monitor** está relacionado con cada componente **Isla** a través de la comunicación antes mencionada. Por su parte, el nivel inferior de jerarquía responde a un esquema de isla. En cada isla un proceso Master es el encargado de inicializar la población inicial y aplicar los operadores de mutación y cruzamiento para generar nuevos individuos (etapa **EO-Master**). Para determinar si los nuevos individuos generados permanecerán en la generación siguiente, el Master distribuye cada individuo generado entre ciertos procesos workers, quienes evalúan el desempeño de cada uno aplicando la función de aptitud y retornando al Master la evaluación obtenida. En la Figura 2, la comunicación entre el Master y los workers está representada por flechas de doble dirección que unen los componentes **Master** y **EO-Worker**. La Etapa de Optimización (**EO-Worker**) es llevada a cabo por los procesos workers. Esta etapa realiza la evaluación de la aptitud de los individuos mediante dos subetapas internas denominadas Simulación de Incendios (**SI**) y Evolución Diferencial (**DEA**). **SI** debe ser alimentada con la línea de fuego real del incendio en el instante de tiempo t_{i-1} (**LFRi-1**) junto con el vector de parámetros de entrada (**VP**). Cuando **SI** concluye con la simulación de los individuos, el resultado de cada simulación es introducido en la etapa **DEA** para comparar el mapa simulado con el mapa real para el instante de tiempo t_i (**LFRi**). Aquí, según la diferencia entre el mapa simulado y el mapa real, se calcula el valor de aptitud para cada individuo.

A medida que los workers van obteniendo resultados, envían estos valores al Master, quien determina si los individuos generados en el proceso de mutación y cruzamiento sobrevivirán a la siguiente generación. Para ello, verifica si la aptitud calculada por los workers es mayor a la aptitud del individuo corriente, en cuyo caso, el nuevo individuo generado reemplaza al individuo corriente. Este proceso se realiza para cada individuo de la población. El Master también se encarga de efectuar la migración grupal de individuos hacia otra isla. En la etapa de **migración** se selecciona un conjunto de individuos de la población actual para ser enviados a otra isla. Entre los individuos seleccionados se incluyen los dos mejores de la población (aquellos dos que tengan los mejores valores de aptitud) y el resto del conjunto es seleccionado al azar. Los individuos que arriban reemplazan a los peores individuos de la población destino. Esta migración grupal permite incrementar la diversidad poblacional en cada isla, a partir de la incorporación de nuevos individuos que han evolucionado con las características de la población de la isla de partida, y que se incorporarán, evolucionarán y desarrollarán en la población destino.

Una vez que la población alcanza cierto nivel de aptitud (o umbral de aptitud U), es introducida en la Etapa de Calibración (**EC-Master**). En esta etapa la población que ha evolucionado alimenta a una subetapa denominada Etapa Estadística (**EE**). La salida de **EE** es un mapa de probabilidad que es utilizado en la subetapa **BKign** (búsqueda del valor clave de ignición **Kign**) para calcular el patrón de comportamiento del incendio. El valor hallado, **Kign**, es utilizado para realizar la predicción para el próximo instante de tiempo (t_{i+1}). La evaluación de la aptitud del mapa de probabilidad se lleva a cabo en la etapa que implementa la Función de Aptitud (**FA**).

Además, la salida **BKign** se combina con el mapa de probabilidad proporcionado por **EE** para generar la predicción (**LFP**) en la Etapa de Predicción (**EP**).

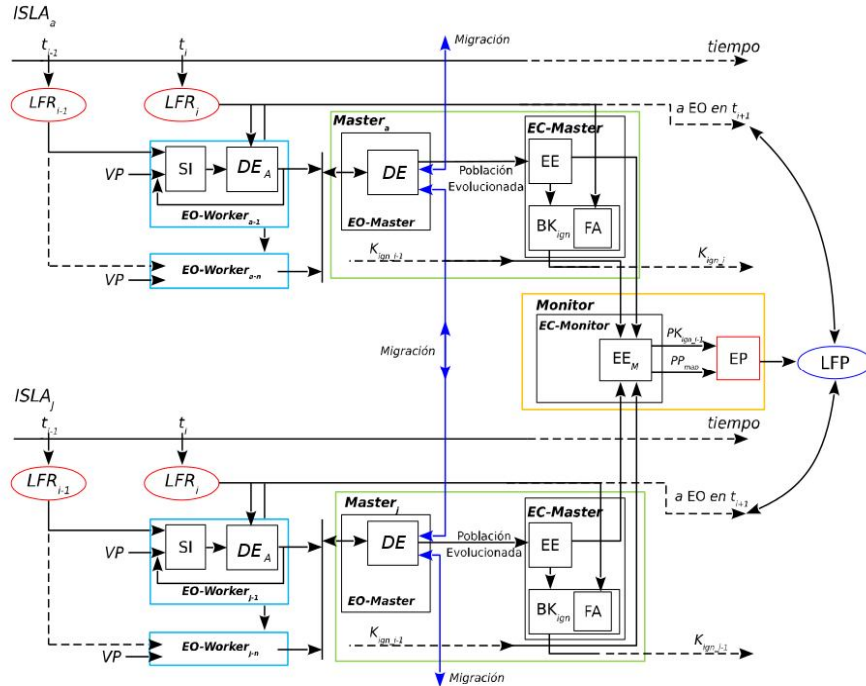


Fig. 2. Diagrama General de ESSIM-DE. **SI**: Simulador de Incendios, **DE**: Evolución Diferencial; **DEA**: Evolución Diferencial (evaluación de aptitud); **EO**: Etapa de Optimización; **EE**: Etapa Estadística; **BKign**: Búsqueda de Kign; **Kign**: valor clave de ignición; **FA**: Función de Aptitud; **EC**: Etapa de Calibración; **EP**: Etapa de Predicción; **LFP**: Línea de Fuego Propuesta; **LFR_x**: Línea de Fuego Real en el instante x; **VP**: Vector de Parámetros de entrada; **EE_M**: Etapa Estadística Monitor; **PKign**: Valor clave de ignición pre-calculado; **PP**: Mapa de Probabilidad pre-calculado.

En la etapa **EC-Master**, la salida de **EE** se envía a **EC-Monitor** junto con los j valores de **Kign** calculados por las j islas. En la Etapa **EC-Monitor** el nodo Monitor selecciona el mejor valor de **Kign** entre los obtenidos por cada isla. El valor hallado **Kign** es utilizado por el monitor para realizar la predicción para el próximo instante de tiempo (t_{i+1}).

4 Experimentación

Para analizar la calidad de predicción del método ESSIM-DE se han utilizado dos casos reales de estudio correspondientes a incendios controlados realizados en

diferentes terrenos ubicados en Portugal (precisamente en Serra de Lousã, Gestosa), todos pertenecientes al proyecto SPREAD [9]. Cada caso posee una determinada duración expresada en minutos, una pendiente en grados y una superficie específica en metros cuadrados. El período de duración total de cada incendio ha sido dividido en lapsos menores de tiempo denominados pasos de simulación. En la Tabla I puede observarse la información detallada para cada caso de prueba considerado.

4.1 Muestreo por Hipercubo Latino

Para realizar un ajuste estático sobre alguno de los parámetros de entrada se utilizó la técnica de Muestreo por Hipercubo Latino (Latin Hypercube Sampling – LHS) [10] sobre un subconjunto de parámetros de ESSIM-DE, los cuales determinan principalmente el desempeño del algoritmo evolutivo. LHS utiliza un esquema de muestreo estratificado, permitiendo mejorar la cobertura del espacio muestral. Los parámetros que se eligieron para aplicar esta técnica de muestreo fueron la probabilidad de cruzamiento ($0 < CR < 1$), el factor de mutación ($0 < F < 1$), el umbral de aptitud ($0.55 \leq U \leq 0.85$) y la cantidad de iteraciones evolutivas ($30 \leq I \leq 100$).

Tabla I: Dimensiones, pendiente, tiempos e incremento de cada caso de prueba

Caso	Ancho (mts)	Largo (mts)	Pendiente (grados)	Inicio (min.)	Fin (min.)	Incremento (min.)
A	89	109	21	2.0	14.0	2.0
B	60	90	6	2.0	10.0	2.0

Para cada parámetro se definieron los rangos entre los cuales se realizó el muestreo estratificado y se generaron 20 vectores con dicha técnica. Cada uno de estos vectores se utilizó como conjunto de parámetros de control para ESSIM-DE, y se realizaron 10 ejecuciones con diferentes semillas para cada mapa, con cada uno de los 20 vectores.

Los diferentes vectores de entrada, en conjunto con el resto de los parámetros del método, se aplicaron en los experimentos bajo un entorno de ejecución paralelo, utilizando una configuración de 3 islas y 7 workers por isla.

4.2 Función de Aptitud

La calidad de predicción tanto de ESS como de ESSIM-DE es evaluada mediante una función de aptitud basada en el índice Jaccard. Conceptualmente se divide el terreno en celdas cuadradas debido a que el simulador utiliza una aproximación basada en celdas. La siguiente ecuación muestra la expresión:

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

donde A representa el conjunto de celdas en el mapa real sin el subconjunto de celdas quemadas antes de iniciar las simulaciones, y B representa el conjunto de celdas en el mapa simulado sin el subconjunto de celdas quemadas antes de comenzar la simulación. La corrección en el conjunto de celdas mediante la eliminación del subconjunto de celdas quemadas se utiliza para evitar resultados sesgados.

El valor de la Ec. 1 se encuentra en el rango $[0,1]$, una aptitud de 1 corresponde a una predicción perfecta, puesto que la superficie predicha en tal caso sería igual a la superficie real. Una aptitud igual a cero, indica el máximo error.

4.3 Resultados Obtenidos

En esta sección se muestran los resultados obtenidos de las ejecuciones con las diferentes configuraciones generadas por el muestreo LHS definido en la sección 4.1. Para una mejor claridad en el análisis, se seleccionaron los mejores cinco resultados obtenidos de las 20 configuraciones. La tabla II muestra las cinco mejores configuraciones para cada mapa. Los gráficos de las Figura 3 y 4 muestran los resultados obtenidos para los mapas A y B respectivamente. Se puede observar en la Figura 3 que la configuración 3 es la que mejores resultados obtiene, logrando un valor de aptitud cercano a 0.85 en el paso de simulación 2.

Los resultados obtenidos para el caso B son muy interesantes desde nuestro punto de vista. Observando la Figura 4, se puede visualizar que todas las configuraciones obtienen una calidad de predicción similar en el paso de simulación 4 (alrededor de 0.82), y si bien en general obtienen una calidad alta en el paso de simulación 6, se aprecia un descenso en la aptitud obtenida en el paso de simulación 8. Por ejemplo, la configuración 5 obtiene los mejores resultados de aptitud para los dos primeros pasos de simulación, pero obtiene una aptitud baja en el último paso de simulación. Por su parte, se observa que los resultados obtenidos con la configuración 3 son intermedios entre todas las configuraciones: en el paso de simulación 6 se obtiene una aptitud cercana a las más altas obtenidas, y en el último paso de simulación se obtiene la mejor predicción respecto del resto de las configuraciones.

De ambas gráficas se puede observar que una calibración realizada con un espectro muestral reducido permite obtener mejoras en los diferentes pasos de simulación. También es posible notar que la calibración de los parámetros es dependiente del problema que se esté considerando. Es importante remarcar que en el caso de los métodos de predicción, no siempre es posible encontrar mejoras en todos los pasos de simulación y para todos los escenarios de quema. Encontrar una mejor predicción en algún paso de simulación significa haber encontrado una mejor delimitación de la zona que se verá posiblemente afectada por el avance del fuego, en el instante de tiempo siguiente. Obtener mejoras parciales puede ayudar a reducir el impacto del fuego, pudiendo obtener a corto plazo medidas preventivas antes y durante el avance del incendio.

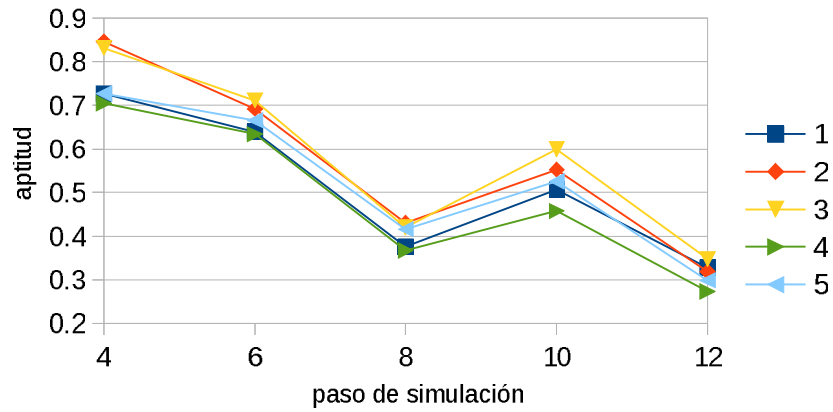


Fig. 3. Caso A: Resultados obtenidos con las 5 mejores combinaciones de parámetros.

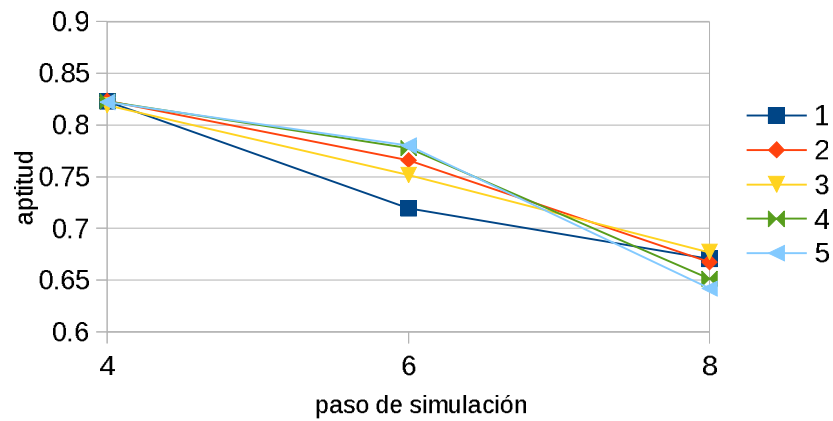


Fig. 4. Caso B: Resultados obtenidos con las 5 mejores combinaciones de parámetros.

Tabla II: Cinco mejores combinaciones de parámetros obtenidos en la calibración. Cr: probabilidad de cruzamiento, F: Factor de mutación, U: umbral de aptitud, I: cota de iteraciones en el ciclo evolutivo

Caso	A				B			
Nro	Cr	F	U	I	Cr	F	U	I
1	0.42	0.68	0.83	56	0.76	0.88	0.65	35
2	0.86	0.38	0.75	92	0.21	0.43	0.84	85
3	0.76	0.88	0.65	35	0.29	0.93	0.69	42
4	0.21	0.43	0.84	85	0.91	0.53	0.80	51
5	0.29	0.93	0.69	42	0.97	0.61	0.68	65

5 Conclusiones y trabajos futuros

En este trabajo se presentó una calibración estática de un subconjunto de parámetros del método ESSIM-DE, utilizando muestreo por Hipercubo Latino. Los resultados obtenidos evidencian que la calibración de los parámetros permite mejorar la calidad de las predicciones, lo que permite una mejor caracterización de la zona de riesgo a fin de reducir el impacto del avance del fuego. Como cada simulación representa un escenario de quema diferente, las características variables de cada problema (condiciones del terreno, del ambiente, morfología del foco de ignición) determinan escenarios muy dispares entre un mapa y otro. En el caso de los incendios forestales, se pudo corroborar que los valores de los parámetros obtenidos en la calibración varían de un mapa a otro. Por este motivo, se planea desarrollar como trabajo futuro un entorno de sintonización automática, de manera tal que la calibración se realice dinámicamente, con el objetivo de independizar la configuración de los parámetros de control relativos a la simulación respecto de las características inherentes al entorno de desarrollo del incendio.

Referencias

1. Finney, M.A: FARSITE: Fire Area Simulator-model development and evaluation. Res. Pap. RMRS-RP-4, Ogden, UT: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station, (1998)
2. ADAI Products: FIRESTATION <http://www.adai.pt/products/firestation/>
3. Bianchini, G., Cortés, A., Margalef, T., Luque, E.: S²F²M-Statistical System for Forest Fire Management. LNCS, vol. 3514, pp. 427--434 (2005)
4. Bianchini, G., Caymes Scutari, P., Méndez Garabetti, M.: Evolutionary-Statistical System: A parallel method for improving forest fire spread prediction. Journal of Computational Science, vol. 6, pp. 58--66 (2015)
5. 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, vol 82, pp. 49--62, (2016)
6. Price, K., Storn R., Lampinen J.: Differential Evolution: A Practical Approach to Global Optimization, Springer, New York, 2005.
7. Tardivo, M.L., Caymes Scutari, P., Méndez Garabetti, M., Bianchini, G.: Sintonización Estática de Parámetros Operacionales para un Modelo Paralelo de Evolución Diferencial. 1er Congreso Nacional de Ingeniería Informática y Sistemas de Información, pp. 770--779, ISSN: 2346-9927 (2013)
8. Tardivo, M.L., Caymes Scutari, P., Méndez Garabetti, M., Bianchini, G., Cortés, A.: Three Evolutionary Statistical Parallel Methods for Uncertainty Reduction in Wildland Fire Prediction. Proceedings of the 2016 International Conference on High Performance Computing & Simulation (IEEE HPCS 2016), Innsbruck, Austria, pp. 721--728 (2016)
9. Viegas, D.X. (Coordinator) et al.: Project Spread--Forest Fire Spread Prevention and Mitigation, <http://www.algosystems.gr/spread/> (2004)
10. McKay, M. D., Beckman, R. J., Conover, W.J.: A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output From a Computer Code. Technometrics, vol 21, pp. 239--246, (1979)