

OPTIMIZACIÓN DE LA CALIDAD DE PREDICCIÓN PARA UN MODELO DE SIMULACIÓN DE INCENDIOS FORESTALES

María Laura Tardivo^{a,b,c}, Miguel Méndez Garabetti^{a,b},
Paola Caymes Scutari^{a,b}, Germán Bianchini^a

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

^b Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

^c Departamento de Computación, FCEFQyN, Universidad Nacional de Río Cuarto,
(X5804BYA) Río Cuarto, Córdoba, Argentina

e-mail: lauratardivo@dc.exa.unrc.edu.ar

RESUMEN

Año a año los incendios forestales devastan miles de hectáreas en diferentes regiones del planeta, arrasando no sólo con la flora y la fauna, sino también poniendo en riesgo a la población y los recursos regionales de los sectores turísticos y productivos. El estudio de modelos y métodos matemático-computacionales que ayuden a predecir su comportamiento puede ser de gran utilidad tanto para poder combatirlos, como para realizar planes de evacuación en aquellas zonas potencialmente afectadas por el fuego. Sin embargo, los modelos suelen presentar limitaciones por la cantidad de parámetros que son necesarios para representar las características del entorno ambiental en las cuales se desarrolla el incendio, y sobre todo por la imposibilidad de cuantificarlos en tiempo real. En consecuencia, los parámetros son representados por valores estimativos, obtenidos por muestreo o por mediciones indirectas, lo que disminuye la precisión de las predicciones y genera una incertidumbre sobre dichos valores. Por este motivo, se hace necesario el uso de estrategias de reducción de incertidumbre sobre los valores de los parámetros de entrada de los modelos. El Sistema Estadístico Evolutivo (ESS) es un método de simulación y predicción computacional que utiliza la estadística para determinar la tendencia del fenómeno, en conjunto con Algoritmos Evolutivos de única población y evaluación en paralelo para orientar la búsqueda hacia una predicción más precisa. Ha sido utilizado como método de reducción de incertidumbre para predecir la línea de fuego de incendios forestales y ha demostrado muy buenos resultados en cuanto a la calidad de la predicción. En este trabajo se propone la utilización de Evolución Diferencial como metaheurística alternativa para orientar la búsqueda, la cual provee al modelo ESS múltiples poblaciones y esquema de migración grupal bajo un Modelo de Islas. En su operador de mutación y cruzamiento esta metaheurística utiliza diferencia de vectores para guiar la búsqueda hacia mejores soluciones. Los resultados obtenidos demuestran que la nueva propuesta logra una predicción más efectiva que ESS.

Palabras Clave: Evolución Diferencial, Predicción, Computación Paralela, Incendios forestales, Modelo de Islas

INTRODUCCIÓN

Los incendios forestales son un componente natural de muchos ecosistemas y son, por lo tanto, un elemento necesario para el mantenimiento del equilibrio de estos complejos sistemas. Sin embargo, bajo ciertas condiciones ambientales, como altas temperaturas y sequía, pueden convertirse en una gran amenaza para la población y para el medio ambiente. En Marzo de 2015 un devastador incendio forestal se desató en Chubut, en la zona de Cholila, propiciado por intensos vientos que contribuyeron a que las llamas avancen rápidamente sobre las plantaciones de pino, y devastando alrededor de 34 mil hectáreas (Figura 1).

Ya sea de origen natural o antropogénicos, los efectos de los grandes incendios forestales pueden ser catastróficos y devastadores. Los gobiernos deben invertir mucho dinero en recursos humanos y materiales, tanto para lograr combatirlos como para reconstruir aquellas zonas afectadas por la quema. Los incendios alteran la disponibilidad de los recursos naturales, con la consecuente repercusión sobre la vida cotidiana de las comunidades afectadas.

En el proceso de lucha contra el fuego se complementa e informa las acciones de las fuerzas de seguridad con herramientas, sistemas y/o estrategias como simuladores de incendios, cortafuegos, estrategias de evacuación, tecnología para la extinción del fuego, etc., que se utilizan en diferentes etapas del proceso: prevención, predicción, detección y monitorización de incendios. La etapa de predicción de los incendios forestales es una tarea esencial para permitir un buen manejo del fuego y para mitigar el riesgo sobre las posibles zonas afectadas. La predicción consiste en intentar pronosticar el comportamiento de la propagación de un incendio forestal ya iniciado, de manera tal de conocer con antelación las zonas que presentarán mayor riesgo de ser alcanzadas por el fuego, lo que posibilita la toma de decisiones respecto de las acciones a llevar a cabo para contrarrestarlo.

La propagación de un incendio forestal está determinada por varios factores, ya sean estáticos (pendiente del terreno, tipo de vegetación, cantidad de combustible) o dinámicos (velocidad y dirección del viento, humedad de la vegetación) [1]. El principal objetivo de los investigadores de incendios forestales es proveer modelos que expliquen y predigan el comportamiento o la propagación del fuego sobre el terreno. Estos modelos pueden ser utilizados para desarrollar simuladores y herramientas de toma de decisiones [2,3,4,5]. Sin embargo, modelar el comportamiento del fuego no es una tarea sencilla. Los modelos deben ser alimentados por parámetros de entrada que se utilizan para representar los diferentes factores dinámicos que determinan el comportamiento del incendio. Al momento de llevar a cabo una predicción resulta muy poco probable conocer con exactitud el valor de todos estos factores. Evidentemente no conocer el valor de un factor dinámico afecta de forma negativa a la calidad de predicción del método, debido a la falta de precisión o incertidumbre en el valor utilizado por el modelo. Por esta razón resulta fundamental mejorar la certeza acerca de los valores de los parámetros del modelo para llevar a cabo predicciones más realistas.

Afortunadamente, la incertidumbre puede reducirse a través de la utilización de diversos métodos que analicen la tendencia del comportamiento del sistema bajo ciertas condiciones. Dentro de la taxonomía, cabe destacar la rama de métodos conducidos por datos de solución múltiple solapada, los cuales involucran la estadística, y cuyo principal antecedente lo constituye el método S²F²M [2]. Combinando la estadística con el uso de metaheurísticas, el método ESS (Evolutionary Statistical System) es un método de simulación y predicción computacional que combina estrategias estadísticas en conjunto con computación evolutiva para orientar la predicción hacia una mejor aproximación [6]. Además, ESS utiliza herramientas de computación de alto desempeño para acelerar el proceso de predicción, de manera tal de obtener buenas soluciones en un tiempo de cómputo razonable.

Durante los últimos años, el método ESS ha sido estudiado en profundidad y se han propuesto diferentes mejoras con el objetivo de lograr una mejor calidad de aproximación.



Figura 1: Incendio forestal en la zona de Cholila, Chubut. Las llamas alcanzaron más de 10 metros de altura. Fuente de la imagen: www.infobae.com.

En la línea de investigación actual se pretende no sólo mejorar la calidad de la aproximación, sino también reducir el costo computacional que implica ejecutar la simulación en un entorno paralelo. Este último objetivo se desagrega en reducir la cantidad de unidades computacionales necesarias para lograr una buena predicción, y/o en lograr una reducción del tiempo de ejecución. Estos objetivos son importantes puesto que al reducir la cantidad de unidades de procesamiento (manteniendo la calidad de la aproximación) es posible hacer un uso más responsable de los recursos computacionales (a la vez que se ahorra energía), y se puede mejorar el tiempo de respuesta de la aplicación, obteniendo soluciones a más corto plazo, dando la posibilidad de aplicar acciones de manera anticipada sobre el avance del incendio.

Bajo este marco, presentamos el modelo ESSIM-DE (Evolutionary Statistical System with Island Model and Differential Evolution). En este modelo se utiliza una estrategia evolutiva alternativa a la utilizada por ESS, denominada Evolución Diferencial, y se incorpora un diseño paralelo basado en islas con migración grupal para obtener un espectro más amplio de posibilidades en la búsqueda de soluciones que conduzcan a una mejor aproximación, utilizando un entorno de ejecución con menor cantidad de unidades de cómputo.

El trabajo se organiza de la siguiente manera. La sección “Algoritmos Evolutivos” presenta una descripción de la componente evolutiva de ESS, describe brevemente la metaheurística Evolución Diferencial utilizada en ESSIM-DE y presenta las principales estrategias de paralelización para los Algoritmos Evolutivos. La sección “Sistema Estadístico Evolutivo” describe el modelo ESS, del cual toma sus bases el nuevo modelo desarrollado. La sección “Sistema Estadístico Evolutivo con Modelo de Islas y Evolución Diferencial” desarrolla las características del nuevo modelo ESSIM-DE. La sección “Experimentación y Análisis de Resultados” detalla cada caso de prueba utilizado, el entorno de ejecución y las métricas consideradas. Además, se incluyen diversos gráficos con los principales resultados obtenidos de la experimentación incluyendo un análisis de los mismos. Finalmente se expresan las conclusiones generales.

ALGORITMOS EVOLUTIVOS

Los Algoritmos Evolutivos (AEs) son considerados métodos eficientes de búsqueda que pueden ser aplicados a problemas de optimización y están inspirados en las teorías de Charles Darwin acerca de la evolución de las especies [7]. En general, el método consiste en una serie de iteraciones, denominadas generaciones evolutivas, en las cuales un grupo de posibles soluciones al problema, denominados individuos, conforman una población. La población evoluciona a través de las generaciones imitando principios de selección natural y supervivencia. Cada individuo tiene asociado un determinado desempeño o aptitud frente al problema de optimización que se considere; este desempeño es calculado a través de la función que describe matemáticamente el problema a optimizar. La premisa subyacente en la evolución es que los

individuos más aptos sobrevivan a la siguiente generación, es decir, permanecerán aquellos individuos cuyo desempeño represente un mejor valor como solución posible del problema.

Cada EA puede representar las soluciones de diferentes maneras: permutaciones, cadenas binarias, números enteros, números reales, matrices de números de punto flotante, etc. Ante un problema de optimización, los individuos codifican las diferentes variables involucradas en el sistema. Por ejemplo, si consideramos el problema de aproximar la línea de fuego en un simulador de incendios forestales, cada individuo puede representar un escenario que describa las características del terreno y de las condiciones ambientales (pendiente, tipo de vegetación, humedad, velocidad del viento, dirección del viento). Encontrar aquella combinación de características que determine un mejor comportamiento respecto de la línea de fuego actual significa determinar cuál es el individuo que mejor se desempeña en la generación actual.

Los EAs permiten que los mejores individuos tengan mayor probabilidad de reproducirse para poder generar nuevas soluciones de buena calidad. Esto lo logran a través de tres operadores: cruzamiento, mutación y selección. Los EAs se diferencian entre sí de acuerdo a cómo se definen en cada uno estos tres operadores. A continuación describiremos el EA utilizado en este trabajo: Evolución Diferencial.

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 [8]. En su esquema 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. Cada individuo está representado por un vector de números reales y codifica una posible solución del problema. Como en todo EA, los individuos evolucionan a través de las generaciones por medio de los operadores de mutación, cruzamiento y selección. El objetivo del operador de mutación y cruzamiento es generar nuevos individuos a partir de individuos existentes. Luego, la etapa de selección determinará si los nuevos individuos generados son mejores que el individuo corriente. La gráfica de la Figura 2 describe en rasgos generales la entrada y la salida de cada etapa evolutiva de DE.

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 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. 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.



Figura 2: Etapas evolutivas de Evolución Diferencial.

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 descritos anteriormente. 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 [9]. A continuación se describen las principales estrategias de paralelización para los EAs y posteriormente se describe el modelo desarrollado para Evolución Diferencial.

Algoritmos Evolutivos Paralelos

Existen diferentes alternativas de paralelización para los EAs [10]. En general, consisten en un esquema Master-Worker [11], en donde un proceso denominado Master es el encargado de realizar tareas principales y/o globales y los procesos workers están destinados a realizar diferentes tareas, dependiendo del tipo de paralelización. Podemos clasificar las estrategias de paralelización en tres grandes grupos:

Única población, evaluación en paralelo: Este esquema consiste de una única población administrada por el proceso Master, quien aplica los operadores evolutivos a los individuos, pero la evaluación de la función objetivo es delegada a los procesos workers. La Figura 3 (a) describe esta estrategia.

Múltiples subpoblaciones, modelo de islas: Consiste en múltiples subpoblaciones organizadas en “islas” que son evolucionadas de manera individual e intercambian individuos ocasionalmente. Este intercambio de individuos es denominado “migración”, y favorece la diversidad en cada una de las islas. El Master puede inicializar la población y distribuirla entre los procesos workers, o bien cada proceso Worker puede inicializar su propia población y aplicar sobre ella los operadores evolutivos. Dependiendo de la implementación, esta estrategia de paralelización puede reducir el tiempo de ejecución o propiciar la búsqueda de mejores soluciones comparado a la versión secuencial del EA. En la Figura 3 (b) se describe esta estrategia.

Modelos híbridos, jerarquía de procesos: Las dos estrategias anteriores pueden combinarse para lograr un modelo jerárquico en el cual, en un nivel superior múltiples islas cooperan entre sí realizando el proceso evolutivo sobre sus poblaciones e intercambiando individuos; y en un nivel inferior, dentro de cada isla se puede distribuir cada individuo para que los procesos Worker evalúen la función objetivo. Esta estrategia jerárquica pretende combinar los beneficios de cada una de las estrategias que lo componen. La Figura 3 (c) describe esta estrategia.

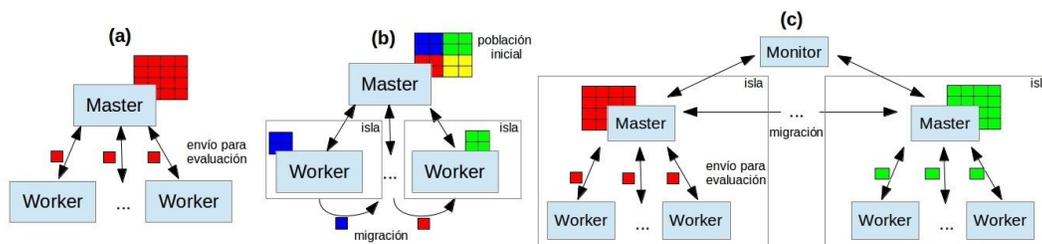


Figura 3: (a) Estrategia de única población (b) Estrategia de múltiple población y modelo de isla (c) Estrategia Jerárquica.

Dentro de las ventajas de utilizar estrategias de paralelización para algoritmos evolutivos encontramos las siguientes [12]:

Acelerar la búsqueda: Uno de los principales objetivos es reducir el tiempo de ejecución, sobre todo en aquellos escenarios en donde el problema a optimizar requiere demasiado tiempo para encontrar soluciones de calidad aceptable.

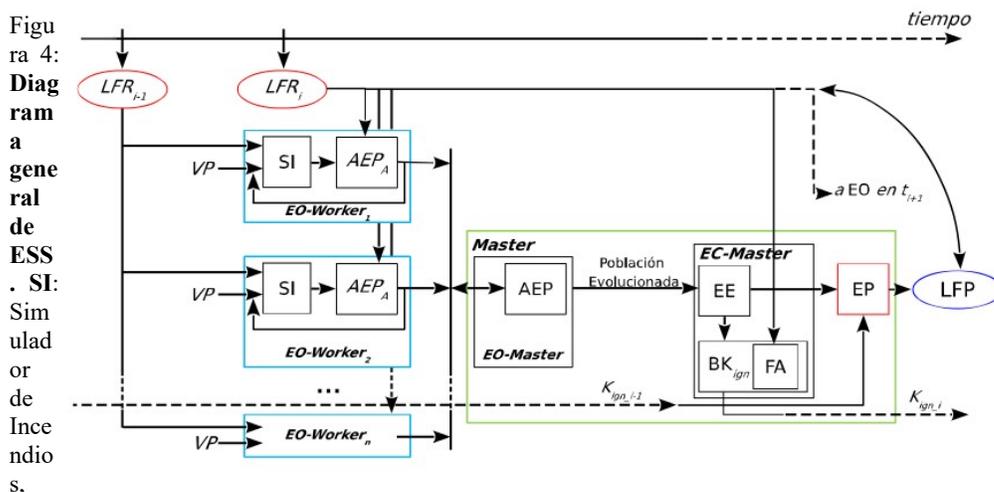
_Mejorar la calidad de las soluciones encontradas: La utilización de metaheurísticas cooperativas altera el comportamiento del algoritmo original, logrando recorrer sectores del espacio de búsqueda aún no visitados.

_Resolver instancias del problema mayores: Gracias a la posibilidad de reducir el tiempo de ejecución, es factible ampliar la instancia del problema a una mayor dimensión y obtener soluciones que no podrían lograrse con un procesamiento secuencial.

A continuación se describe el Sistema Estadístico Evolutivo, un modelo de predicción que utiliza Algoritmos Evolutivos y que se encuentra enmarcado dentro de la estrategia de única población y evaluación en paralelo. Posteriormente, se describe el nuevo modelo desarrollado, denominado Sistema Estadístico Evolutivo con Modelo de Islas y Evolución Diferencial (ESSIM-DE, por sus siglas en inglés), el cual se enmarca dentro de la estrategia de paralelización jerárquica, con múltiples poblaciones y modelo de islas.

SISTEMA ESTADÍSTICO EVOLUTIVO

ESS es un método de reducción de incertidumbre que utiliza Algoritmos Evolutivos Paralelos (AEPs) en su esquema de única población, el cual aplica evaluación en paralelo para optimizar la búsqueda de los parámetros que alimentan al modelo. Los parámetros de entrada en ESS están representados por individuos de una población determinada. Cada individuo está formado por un conjunto de valores que representan a cada uno de los parámetros de entrada del modelo.



AEP: Algoritmo Evolutivo Paralelo; **AEP_A:** Algoritmo Evolutivo Paralelo (evaluación de aptitud); **EO:** Etapa de Optimización; **EE:** Etapa Estadística; **BK:** Búsqueda de K-ign; **K-ign:** 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.

Tal como puede observarse en la Figura 4, 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 sub-etapas internas denominadas Simulación de Incendios (SI) y Evaluación de Aptitud del AEP (**AEP_A**). **SI** debe ser alimentada con la línea de fuego real del incendio en el instante de tiempo $t-1$ (**LFR_{t-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 **AEP_A** para comparar el mapa simulado con el mapa real para el instante de tiempo t (**LFR_t**). Aquí, según la diferencia entre el mapa simulado y el mapa real, se calcula el valor de aptitud para cada individuo. Evidentemente, el tiempo de ejecución del método dependerá de la

cantidad de n instancias **EO-Worker** que puedan llevarse a cabo en paralelo. Es importante notar que todo individuo procesado por **EO-Worker** debe haber sido enviado de forma explícita desde el proceso Master a los respectivos workers. En el proceso Master también se lleva a cabo el resto del procesamiento del AEP (es decir, la generación de la población, la selección de individuos, el cruzamiento y la mutación) y las funciones de comunicación con cada uno de los workers. Una vez que la población alcanza cierto nivel de aptitud, es introducida en la Etapa de Calibración (**EC-Master**). En esta etapa la población que ha evolucionado alimenta a una sub-etapa denominada Etapa Estadística (**EE**). La salida de **EE** es un mapa de probabilidad que es utilizado en la sub-etapa **BK-ign** (búsqueda del valor clave de ignición **K-ign**) para calcular el patrón de comportamiento del incendio. El valor hallado, **K-ign**, 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 **BK-ign** se combina con el mapa de probabilidad proporcionado por **EE** para generar la predicción (**LFP**) en la Etapa de Predicción (**EP**).

Como se puede observar, ESS está basado en un modelo Master-Worker, donde en cada iteración el proceso Master distribuye los individuos entre los procesos workers, los cuales son encargados de realizar la evaluación de la aptitud de los individuos en forma paralela para luego retomar los resultados al Master. Luego de que toda la población ha sido evaluada, el Master evoluciona la población, incluye los resultados parciales y realiza la predicción para el siguiente instante de tiempo.

SISTEMA ESTADÍSTICO EVOLUTIVO CON MODELO DE ISLAS Y EVOLUCIÓN DIFERENCIAL

ESSIM-DE fue desarrollado con dos objetivos principales. Por un lado, se diseñó con el objetivo de mejorar la calidad de la predicción de ESS mediante el incremento en la diversidad de los individuos generados por la componente evolutiva diferencial del método y por el modelo de migración grupal entre las islas que componen el modelo. Por otro lado, se pretende reducir la cantidad de unidades de procesamiento para lograr una buena calidad de aproximación a un costo computacional y/o temporal menor respecto de ESS.

Tomando como base al sistema ESS, el Sistema Estadístico Evolutivo con Modelo de Islas y Evolución Diferencial (ESSIM-DE) utiliza como metaheurística principal a Evolución Diferencial para orientar la búsqueda hacia mejores soluciones en cada paso de simulación.

El concepto de isla está asociado al esquema de procesamiento *Master-Worker*, en donde un proceso Master es el encargado de administrar una población de individuos y delegar ciertos cálculos a los procesos workers. El Modelo de Islas consiste organizar los procesos en islas, cada una con una población diferente, las cuales 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 un proceso denominado Monitor es el encargado de administrar las diferentes islas, a través de la comunicación con cada una de ellas.

El Monitor se encarga de enviar información de inicialización a cada isla, de recolectar los datos procesados en la etapa final de la simulación y de determinar los valores de salida, identificando cuál es la isla que ha resultado con mejor aptitud.

La Figura 5 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 del proceso evolutivo para generar nuevos individuos. 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 individual de cada uno aplicando la función de *fitness* y retornando al Master la evaluación obtenida.

En la Figura 5, la comunicación entre el Master y los workers está representada por flechas de doble dirección que unen los componentes “**Master**” y “**EO-Worker**”. Luego, el proceso Master recibe los resultados de la evaluación realizada por los workers y determina si los individuos generados en el proceso de mutación y cruzamiento sobrevivirán a la siguiente generación, verificando si el *fitness* calculado por los workers es mayor al *fitness* del individuo corriente, en cuyo caso, el nuevo individuo generado reemplaza al individuo corriente. Este proceso se realiza para cada individuo de la población. Tal como puede observarse en la Figura 5, la Etapa de Calibración (**EC-Master**) realiza funciones de comunicación con el nodo monitor en la jerarquía superior, y la Etapa de Optimización (**EO-Master**) realiza lo mismo con los workers en la jerarquía inferior. El funcionamiento detallado de los niveles de ESSIM-DE se resume en dos Etapas de Optimización (**EO-Worker** y **EO-Master**), dos de calibración (**EC-Master** y **EC-Monitor**) y una Etapa de Predicción (**EP**).

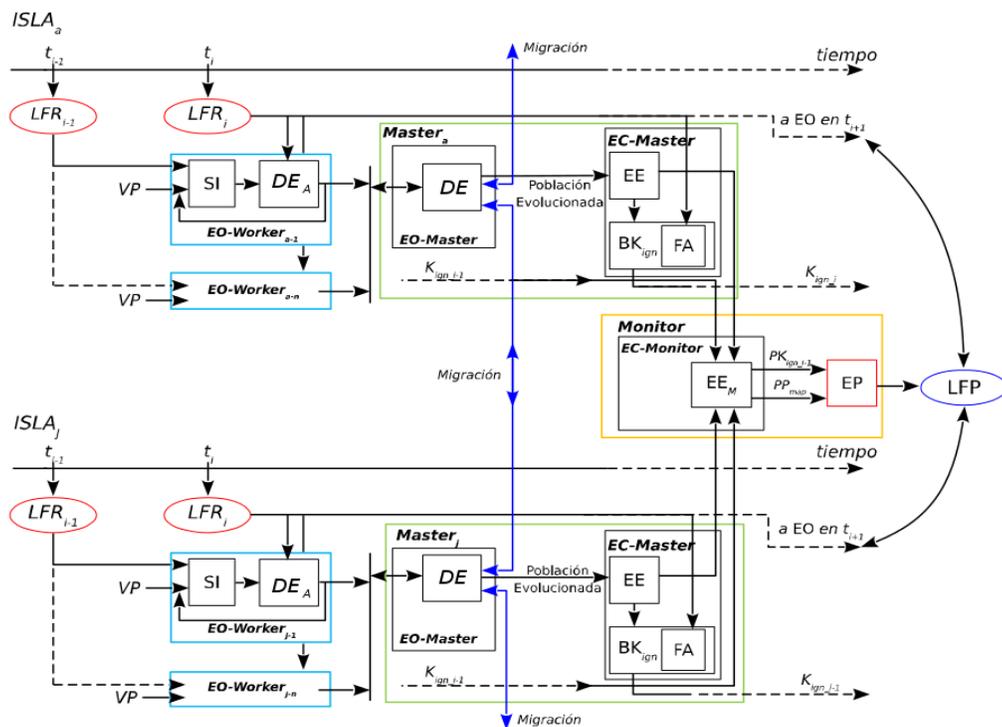


Figura 5: Diagrama General de ESSIM-DE. **SI**: Simulador de Incendios, **DE**: Evolución Diferencial; **DEA**: Evolución Diferencial (evaluación de aptitud); **EO**: Etapa de Optimización; **EE**: Etapa Estadística; **BK**: Búsqueda de K-ign; **K-ign**: valor clave de ignición; **FA**: Función de Aptitud; **EC**: Etapa de Calibración; **EP**: Etapa de Predicción; **LFP**: Línea de Fuego Propuesta; **LFRx**: Línea de Fuego Real en el instante x; **VP**: Vector de Parámetros de entrada; **EE_M**: Etapa Estadística Monitor; **PK-ign**: Valor clave de ignición pre-calculado; **PP**: Mapa de Probabilidad pre-calculado.

La etapa **EO-Worker** efectúa la evaluación de la población mediante la función de aptitud. En cada isla opera una **EO-Master**, que es responsable de llevar a cabo la evolución de la población utilizando el algoritmo Evolución Diferencial (**DE**) y de efectuar la migración grupal de individuos hacia otra isla. Es importante remarcar que 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. La comunicación entre islas sigue un orden topológico de anillo, es decir, las islas son numeradas en orden creciente y cada una envía a la isla sucesora y recibe datos desde la isla predecesora. Los individuos que arriban reemplazan a los peores individuos de la población destino. La cantidad total de individuos que migran hacia otra isla es un parámetro del algoritmo. 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.

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

Resaltando las diferencias entre ESS y ESSIM-DE tenemos, por un lado, que ESS posee un esquema de única población, a diferencia de ESSIM-DE, el cual posee múltiples poblaciones organizadas en islas, que se comunican entre sí a través del operador de migración grupal permitiendo explorar un espacio de búsqueda mayor. Por otro lado, ESS utiliza como metaheurística Algoritmos Evolutivos, mientras que ESSIM-DE utiliza Evolución Diferencial en su componente evolutiva. Finalmente, cabe enfatizar que ESSIM-DE posee dos jerarquías de procesos: en cada isla un proceso Master administra los individuos y los envía a los procesos workers, (quienes calculan la función de aptitud para cada uno), y un proceso Monitor es el encargado de recolectar la información de cada isla, y determinar cuál es la isla con mejor aptitud para predecir el valor de ignición del siguiente paso de simulación. En contraste, ESS solo posee un nivel de jerarquía (Master-Worker).

EXPERIMENTACIÓN Y ANÁLISIS DE RESULTADOS

A continuación se describe detalladamente la experimentación llevada a cabo con ESS y ESSIM-DE, incluyendo los casos de prueba considerados, las características del entorno de ejecución y la función de aptitud considerada en la evaluación.

Casos de prueba

Para analizar la calidad de predicción de los modelos ESS y 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 [13]. 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.

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.)
520	89	109	21	2.0	14.0	2.0
533	95	123	21	4.0	12.0	2.0

Configuración del entorno de ejecución paralelo

La experimentación ha sido diseñada para evaluar la calidad de predicción alcanzada por cada método bajo un entorno de ejecución paralelo. Los resultados obtenidos con ESS fueron ejecutados utilizando un proceso monitor y 40 procesos workers, haciendo un total de 41 procesos en ejecución. Por su parte, ESSIM-DE fue configurado con 3 islas y 7 workers por isla. Como cada isla es administrada por un proceso Master, y las islas coordinadas por un proceso monitor, ESSIM-DE fue entonces ejecutado utilizando 25 procesos, por lo tanto la configuración fue definida con una reducción de la cantidad de unidades de procesamiento en un 40% respecto de ESS.

Función de aptitud para la evaluación de la calidad de predicción

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 particiona el terreno en celdas cuadradas debido a que el simulador utiliza una aproximación basada en celdas. La siguiente ecuación muestra la expresión:

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

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 es igual a la superficie real quemada. Una aptitud igual a cero, indica el máximo error, puesto que el área quemada del incendio real no coincide en absoluto con el área quemada obtenida en la simulación.

Resultados obtenidos

Los resultados obtenidos se resumen en los gráficos de la Figura 6. En cada gráfico se representa en el eje Y el valor de aptitud alcanzado por cada método, y en el eje X la línea de tiempo que se corresponde con el avance del incendio, representado por cada paso de simulación. Para poder analizar el desempeño de los modelos respecto del tiempo de ejecución y de las unidades de procesamiento utilizadas, se presentan el gráfico de la Figura 7, donde se describen los resultados temporales obtenidos con cada método respecto del tiempo de ejecución y se incluye la cantidad de procesos utilizados.

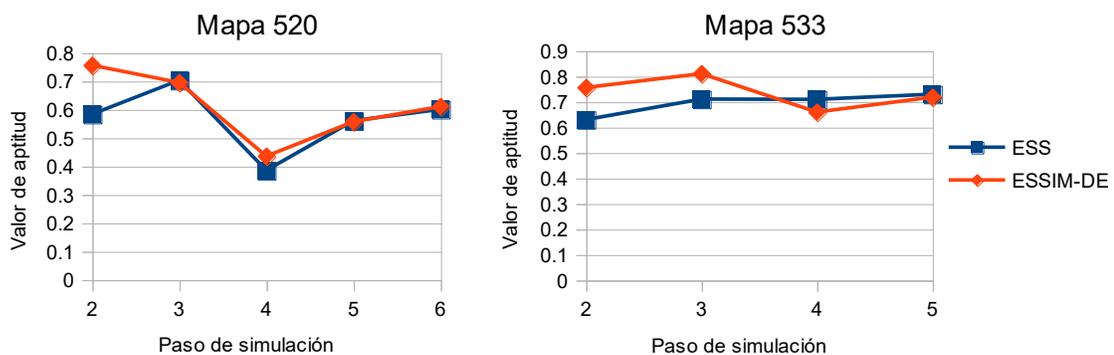


Figura 6: Comparación de calidad de predicción

obtenida por cada método, para los dos casos considerados.

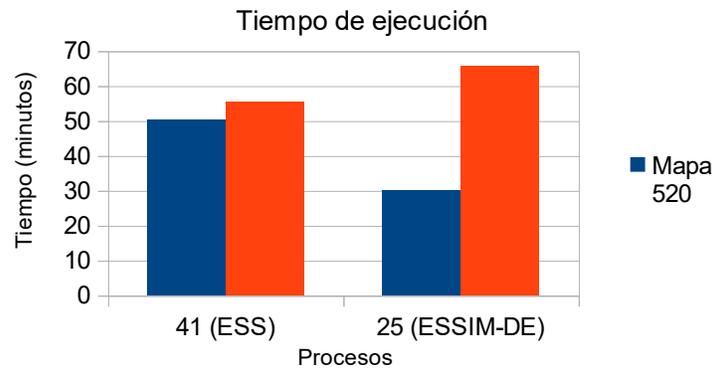


Figura 7: Comparación de tiempos de ejecución de cada método respecto de unidades de cómputo para los mapas considerados.

DISCUSIÓN

El desempeño del modelo ESSIM-DE puede ser analizado bajo tres diferentes métricas: evaluación de la calidad de la predicción, evaluación del tiempo de ejecución y evaluación de la cantidad de recursos computacionales utilizados.

La primera métrica de calidad refiere a cuál es el grado de precisión que el método ESSIM-DE alcanza respecto de la línea de fuego real del incendio. Para analizar esta métrica podemos observar los gráficos de la Figura 6. Es posible observar que ESSIM-DE obtiene mejoras en los valores de aptitud para ciertos pasos de simulación de ambos mapas. A excepción del paso de simulación 4 para el mapa 533, en general ESSIM-DE obtiene una mejora de hasta un 25%, sobre todo en los primeros pasos de simulación. Gracias a la incorporación de múltiples islas, el espacio de búsqueda se amplía de manera considerable, implicando mayor posibilidad de encontrar soluciones de calidad.

Un aspecto importante a tener en cuenta en los modelos de simulación es el tiempo en el cual el modelo permite obtener resultados para poder ser utilizados en un entorno real. El gráfico de la Figura 8 muestra los resultados temporales de las ejecuciones de ambos modelos, para cada mapa considerado. Además, en leyenda del eje X se describe la cantidad de unidades de cómputo utilizadas para las pruebas. Podemos notar para el mapa 520 que ESSIM-DE obtiene una reducción de más del 40% del tiempo de ejecución. Mientras que para el mapa 533, ESSIM-DE presenta un leve incremento en el tiempo de ejecución. Sin embargo, todas las ejecuciones tanto para el mapa 520 como para el mapa 533, fueron realizadas con una reducción de aproximadamente un 40% menos de unidades de cómputo. Esto implica que el modelo ESSIM-DE no solo logra mejorar la calidad de la aproximación, sino que lo realiza a un costo computacional menor que ESS, alcanzando una reducción significativa del tiempo de ejecución para uno de los dos mapas considerados. Es importante remarcar que como cada mapa posee características particulares, los métodos deben ser calibrados de manera independiente para cada caso. Por este motivo, a futuro se pretende estudiar y desarrollar un modelo de ajuste dinámico de parámetros de control, a través de métodos de sintonización que logren calibrarlos dinámicamente.

CONCLUSIONES

Los incendios forestales representan una gran amenaza tanto para la población como para la biodiversidad de las zonas afectadas. Por tal motivo, se hace necesario el estudio de métodos que ayuden a predecir su comportamiento con el objetivo de minimizar pérdidas y/o generar planes de evacuación de las zonas potencialmente afectadas.

Como generalmente los modelos de simulación para este tipo de fenómenos presentan incertidumbre sobre los parámetros de entrada, se hace necesario el desarrollo de métodos que permitan reducir dicha incertidumbre para que las predicciones sean lo más cercanas posible a la realidad. Además, es esperable que los resultados de predicción sean obtenidos en un tiempo de respuesta aceptable. El uso de estrategias de computación en paralelo puede no sólo acelerar el proceso de predicción, sino también lograr obtener soluciones de mayor calidad.

En este trabajo se ha presentado ESSIM-DE (Evolutionary-Statistical System with Island Model and Differential Evolution), un modelo de simulación que utiliza el algoritmo evolutivo Evolución Diferencial y evaluación en paralelo bajo un Modelo de Islas con migración grupal. ESSIM-DE fue aplicado al problema de la predicción de la línea de fuego de incendios forestales, demostrando alcanzar resultados de calidad, a un costo temporal menor que su predecesor ESS (Evolutionary-Statistical System) para el mapa 520 y utilizando aproximadamente un 40% menos de recursos computacionales. Como trabajos futuros se planea trabajar en la sintonización estática y dinámica de los parámetros operacionales del modelo ESSIM-DE, con el objetivo de lograr un entorno auto-ajustable de ejecución que permita mejorar las diferentes métricas de calidad independientemente del mapa considerado. También se planea utilizar la estrategia de paralelización con sub-poblaciones, con el objetivo de mejorar aún más la calidad de la aproximación y/o lograr mejores tiempos de respuesta.

REFERENCIAS

- [1] E.A. Johnson, K. Miyanishi, *Forest Fires: Behavior and Ecological Effects*, Academic Press, Orlando, Florida, 2001.
- [2] G. Bianchini, A. Cortés, T. Margalef, E. Luque: *S2F2M-Statistical System for Forest Fire Management*, *LNCS 3514* (2005) 427-434.
- [3] P.L. Andrews, C.D. Bevins, Seli, Robert C, *BehavePlus fire model-ing system, version 2.0: User's Guide*. Tech. Rep. RMRS-GTR-106WWW. Ogden, Dept. of Agriculture, Forest Service, Rocky Mountain Research Station, 2003.
- [4] M.A Finney, *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.
- [5] ADAI Products: FIRESTATION <http://www.adai.pt/products/firestation/>
- [6] G. Bianchini, P. Caymes Scutari, M. Mendez Garabetti: Evolutionary-Statistical System: A parallel method for improving forest fire spread prediction. *Journal of Computational Science* **6** (2015) 58-66.
- [7] C. Darwin, *On the Origin of Species by Means of Natural Selection*, London, Murray, 1859.
- [8] Price, K., Stron R., Lampinen J., *Differential Evolution: A Practical Approach to Global Optimization*, Springer, New York, 2005.
- [9] M.L. Tardivo, P. Caymes Scutari, M. Méndez Garabetti, G. Bianchini, Sintonización Estática de Parámetros Operacionales para un Modelo Paralelo de Evolución Diferencial, 1er Congreso Nacional de Ingeniería Informática y Sistemas de Información, ISSN: 2346-9927. (2013) 770-779.
- [10] E. Cantú Paz, *A Survey of Parallel Genetic Algorithms*, *CALCULATEURS PARALLELES*, vol 10 (1998).

- [11] T. Matson, B. Sanders, B. Massingill, *Patterns for Parallel Programming*. Addison-Wesley, 2005.
- [12] E.G. Talbi, *Metaheuristics: from design to implementation*, John Wiley & Sons, Inc., 2009.
- [13] D. X. Viegas, *Project Spread – Forest Fire Spread Prevention and Mitigation*, <http://www.algosystems.gr/spread/> (2004).