

Sintonización Estática de ESSIM-DE(lr) para Acelerar y Mejorar la Predicción de Incendios Forestales

María Laura Tardivo (*,+,\dagger), Paola Caymes Scutari (*,+),
Germán Bianchini (*), Miguel Méndez Garabetti (*,+)

(*) *Laboratorio de Investigación en Cómputo Paralelo/Distribuido (LICPaD), UTN-FRM, Mendoza.*

(+) *Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)*

(\dagger) *Departamento de Computación, UNRC, Río Cuarto, Córdoba.*

*lauratardivo@dc.exa.unrc.edu.ar, {pcaymesscutari, gbianchini}@frm.utn.edu.ar,
miguelmendezgarabetti@gmail.com*

Abstract

Los sistemas de predicción constituyen en nuestros días una gran herramienta computacional que puede brindar soporte en los planes de lucha contra el fuego y en la prevención de incendios forestales. ESSIM-DE es un método de predicción paralelo, el cual permite obtener predicciones de la línea de fuego utilizando Análisis Estadístico, la estrategia evolutiva Evolución Diferencial y Cómputo de Alto Desempeño. El Análisis Estadístico permite obtener la tendencia de la propagación de las llamas a lo largo del desarrollo del incendio. El Cómputo de Alto Desempeño se utiliza para mejorar los tiempos de respuesta bajo un esquema de procesamiento en paralelo. Finalmente, la estrategia evolutiva Evolución Diferencial guía el proceso de búsqueda hacia soluciones de calidad. ESSIM-DE ha sido estudiado durante los últimos años, con el fin de mejorar su rendimiento. Recientemente se ha incorporado un operador de reinicio de poblaciones, y la evaluación de un modelo de rendimiento para el componente evolutivo del método. En este trabajo se presenta un estudio de calibración estática sobre dos métricas asociadas a dicho modelo de rendimiento, con el fin de mejorar tanto la calidad como el tiempo de respuesta en la obtención de las predicciones.

1. Introducción

Los incendios forestales son uno de los fenómenos naturales que provocan enormes pérdidas materiales y vidas humanas alrededor del mundo. Si bien son un

eslabón necesario en el mantenimiento del ecosistema, las consecuencias de un incendio forestal fuera de control pueden ser catastróficas, generando un impacto en la biodiversidad y los recursos naturales de las zonas afectadas. En Julio de 2018 el fuego sin control se llevó la vida de al menos 82 personas, con más de 150 heridos e incalculables pérdidas materiales en la zona costera de Ática, a las afueras de Atenas, Grecia [1].

En tales situaciones, contar con herramientas de predicción que brinden una estimación de la propagación del fuego, puede resultar de gran utilidad a la hora de definir acciones y tomar decisiones anticipadas al avance del incendio. Este tipo de herramientas generalmente implementa modelos matemáticos que describen el comportamiento del fenómeno natural. Los modelos son alimentados con parámetros de entrada, representando las condiciones iniciales del sistema que se quiere modelar. En el caso de los incendios forestales, los factores o variables que afectan la velocidad de propagación y la morfología del frente de fuego son el tipo de material combustible, la humedad, la dirección y velocidad del viento, la topografía del terreno (pendiente y barreras naturales), la densidad del combustible, etc. [2]. Algunas de estas variables poseen valores que cambian dinámicamente durante el desarrollo del incendio, mientras que otras poseen valores que suelen ser desconocidos o difíciles de cuantificar. Esta falta de precisión sobre el valor de las variables se denomina incertidumbre, e impacta negativamente sobre las predicciones.

En los últimos años se han desarrollado, estudiado y mejorado una serie de métodos que se enfocan en reducir este impacto negativo que provoca la incertidumbre. Tal es el caso del método *Evolutionary Statistical System with Island Model and Differential Evolution*, ESSIM-DE, el cual utiliza Estadística para obtener el patrón de comportamiento de la línea de fuego, el algoritmo evolutivo denominado Evolución Diferencial, para orientar la búsqueda hacia mejores soluciones, y Computación de Alto Desempeño con un esquema de procesos de doble jerarquía, lo que permite explorar un amplio espacio de búsqueda y a la vez acelerar el proceso de predicción. ESSIM-DE pertenece a la clase de métodos denominados Métodos Conducidos por Datos con Múltiples Soluciones Solapadas (*Data Driven Methods with Multiple Overlapped Solutions*, DDM-MOS), los cuales obtienen predicciones de la línea de fuego en base a la agregación de múltiples soluciones. Para lograrlo, el incendio se divide en diferentes instantes de tiempo, denominados pasos de predicción. Para cada uno de ellos, ESSIM-DE obtiene un mapa cuyas celdas indican la porción del terreno alcanzada por el fuego. El método ESSIM-DE ha sido aplicado satisfactoriamente en la predicción de incendios forestales, y ha logrado una importante reducción del tiempo de ejecución comparado respecto de otros DDM-MOS [9].

Durante el último tiempo, ESSIM-DE ha sido estudiado con el fin de mejorar aquellos aspectos que pueden ser limitantes de mejor rendimiento, tanto en términos de calidad de predicción como en el tiempo requerido para la obtención de predicciones. La primera mejora consistió en la incorporación de un nuevo operador de reinicio de la población al inicio de cada paso de predicción, con el fin de mejorar el estancamiento global del proceso de búsqueda. La nomenclatura establecida para el método con dicho operador ha sido **ESSIM-DE(r)**, y se ha logrado mejorar la calidad de las predicciones [10]. Sin embargo, estamos interesados en identificar y mejorar otros factores que afecten de manera negativa el rendimiento del método. En ese mismo sentido, nos hemos enfocado en la definición de estrategias de sintonización que permitan mejorar el rendimiento en conjunto con el operador de reinicio de poblaciones.

Las estrategias de sintonización pueden ser clasificadas en dos grandes grupos [6]: estáticas o dinámicas. Las primeras se representan en la Figura 1. La aplicación es **instrumentada** para registrar ciertas métricas de interés. Dichas métricas corresponden a un modelo de rendimiento de la aplicación, el cual encapsula el conocimiento experto respecto de los posibles aspectos críticos que afectan el rendimiento. Durante la ejecución, se **monitorizan** y registran dichas métricas, por ejemplo, en archivos de traza. Posteriormente, se visualiza la información registrada (mediante herramientas de visualización, o de modo manual) y el usuario es el responsable de **analizar** los resultados, a fin de tomar decisiones respecto de acciones que puedan ajustar el comportamiento, denominadas acciones de **sintonización**. Posteriormente, el programa es modificado, re-compilado y re-enlazado para ser vuelto a ejecutar y analizar si dichas decisiones tendientes a mejorar los aspectos críticos son efectivas. Este enfoque es apropiado para obtener una primera aproximación al comportamiento del programa bajo la arquitectura de ejecución.

En las estrategias de sintonización dinámica, el programa es instrumentado para registrar las métricas de interés durante la etapa de monitorización, pero a

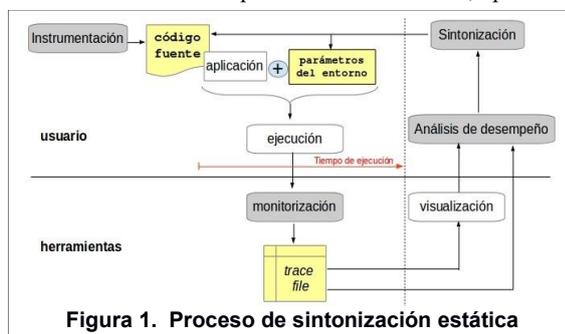


Figura 1. Proceso de sintonización estática

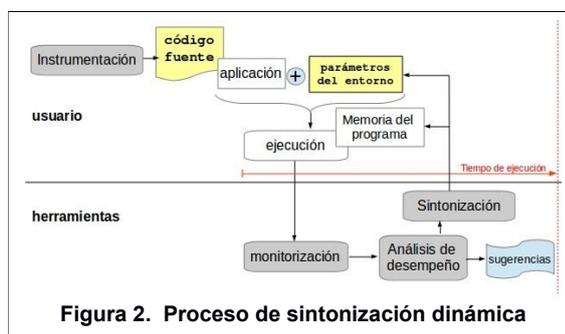


Figura 2. Proceso de sintonización dinámica

diferencia de las estrategias estáticas, las etapas de análisis y sintonización se aplican durante la ejecución del programa. La Figura 2 describe este enfoque. De esta manera, el proceso de sintonización es automatizado, por lo tanto, resulta apropiado para facilitar la ardua tarea de la sintonización a usuarios no expertos, puesto que todo el proceso se realiza en tiempo de ejecución y con una intervención nula o baja del usuario final. Además, debido a que la sintonización se realiza de acuerdo con las condiciones particulares de la ejecución, este enfoque es adecuado para aplicaciones con dependencia en los parámetros de entrada y en aquellos casos en los cuales el entorno de ejecución es compartido y/o heterogéneo, ya que el escenario de ejecución es difícilmente reproducible. Si bien este enfoque posee ciertas ventajas respecto de los enfoques clásicos, requiere de la utilización de conocimiento experto sobre la aplicación, que permita definir el modelo de rendimiento a ser evaluado durante la ejecución en las diferentes etapas. Ambas estrategias pueden resultar de utilidad para mejorar los aspectos que afectan de manera negativa el rendimiento de métodos como ESSIM-DE. En relación a las estrategias dinámicas, nos hemos focalizado en definir un modelo de rendimiento que permita calibrar dinámicamente ciertos parámetros relevantes para el funcionamiento del método ESSIM-DE(r), y así incrementar las mejoras ya alcanzadas con la incorporación del operador de reinicio poblacional.

En tal sentido, hemos prestado especial interés en una de las etapas más destacadas de ESSIM-DE(r), constituida por el proceso evolutivo llevado a cabo por el algoritmo Evolución Diferencial [8] (presentado en la sección 2.1). Esta metaheurística es un optimizador poblacional y consiste en un proceso iterativo en el cual se evoluciona una población de individuos, en la que cada uno constituye una posible solución al problema. En el caso particular de los incendios forestales, cada individuo representa una combinación de valores para las variables utilizadas como parámetros de entrada del modelo de incendio, como la velocidad de viento, la dirección y pendiente del terreno, el tipo de material combustible, la humedad del material combustible vivo, etc. Un posible problema de rendimiento asociado a Evolución Diferencial lo constituye el estancamiento en óptimos locales y/o la convergencia prematura hacia un

óptimo local [13]. Recientemente hemos incorporado conocimiento a ESSIM-DE, a través de un modelo de rendimiento mediante el cual es posible detectar una tendencia al estancamiento y/o a la convergencia prematura, con el fin de evitar que estos dos fenómenos afecten de manera negativa el rendimiento del método, tanto en la calidad de las predicciones como en el tiempo de ejecución [11]. Para ello, hemos definido dos métricas que cuantifican la dispersión de la población y los movimientos efectivos del optimizador Evolución Diferencial. La dispersión de la población es medida en base a la distribución de la aptitud de los individuos que constituyen los diferentes escenarios de quema. Por su parte, los movimientos efectivos cuantifican la cantidad de escenarios que, luego de un ciclo evolutivo, hubieran sido mejorados por el proceso evolutivo, es decir, constituyen nuevas y mejores soluciones del espacio de búsqueda. El modelo de rendimiento permite evaluar en cada paso de predicción el comportamiento de las métricas para la detección de un posible estancamiento o convergencia, y así determinar en qué momento es preciso finalizar el proceso evolutivo, para realizar la predicción y proseguir con el siguiente paso de simulación. Dado que cada decisión de parada es independiente y sólo obedece a haber alcanzado los valores estipulados para las métricas, es que el límite máximo de iteraciones de cada paso evolutivo se dice que está sintonizado dinámicamente. Los valores considerados para las métricas en la condición de fin de ciclo evolutivo actualmente son fijos y se establecen estáticamente. Su calibración constituye el objeto de estudio y análisis de este trabajo. Retomando la estrategia de sintonización dinámica utilizada para determinar el límite de iteraciones de un paso de predicción, tal estrategia consiste en monitorizar dichas métricas para determinar una tendencia a estos problemas en una etapa de análisis, y así dar por finalizado el ciclo evolutivo del paso de predicción considerado, en una etapa de sintonización. Posteriormente se procede con las siguientes etapas del proceso de predicción, y en el siguiente paso, se aplica el operador de reinicio de poblaciones. La nomenclatura utilizada para el método con la incorporación de la sintonización dinámica y el operador de reinicio poblacional fue **ESSIM-DE(lr)**.

Hasta el momento, y como ya adelantamos, se ha utilizado una única configuración para los valores de estas métricas, dichos valores fueron establecidos de manera empírica, en base a la observación de las curvas que determinan sus tendencias a lo largo de las generaciones evolutivas. En este trabajo se presenta un estudio de calibración estática realizada sobre estas métricas con el cual se persiguen diferentes fines. Por un lado, se intenta detectar si los resultados obtenidos con la configuración por defecto pueden ser mejorados respecto a la calidad de las predicciones. Por otro lado, y dado que el proceso evolutivo en ESSIM-DE(r) es uno de los aspectos claves que determinan el tiempo de ejecución total, se pretende también establecer si existe una relación entre las magnitudes de los valores de estas métricas, respecto del tiempo de ejecución total del método. Finalmente, este estudio de sintonización estática de las métricas utilizadas en el modelo de rendimiento constituye la base experimental para avanzar hacia la definición de un criterio que permita ajustar el valor de dichas métricas en tiempo de ejecución, de acuerdo con las características particulares del incendio considerado, y del contexto de ejecución.

El trabajo se estructura de la siguiente forma. La sección 2 introduce el método ESSIM-DE(r), describiendo las diferentes etapas y cómo se obtienen las predicciones para los diferentes instantes de tiempo en el avance de un incendio forestal. También se incluye una breve descripción al algoritmo Evolución Diferencial, y del operador de reinicio de poblaciones. La sección 3 describe a ESSIM-DE(lr). Se incluye la descripción de los problemas del estancamiento y la convergencia prematura, se describen dos métricas definidas para identificar si la población posee una tendencia hacia dichos problemas y se describe la integración de las nuevas etapas que concretan la sintonización dinámica, y que han sido incorporadas en el proceso de predicción de ESSIM-DE(lr). La sección 4 presenta el estudio de sintonización estática, se definen cuatro configuraciones diferentes para los valores de las métricas que han sido utilizadas en la experimentación, y se presentan los resultados comprando los resultados obtenidos con tres casos de quemas controladas reales. Los resultados son analizados desde el punto de vista de la calidad de la predicción y respecto del tiempo de ejecución del método. Finalmente, la sección 5 presenta las

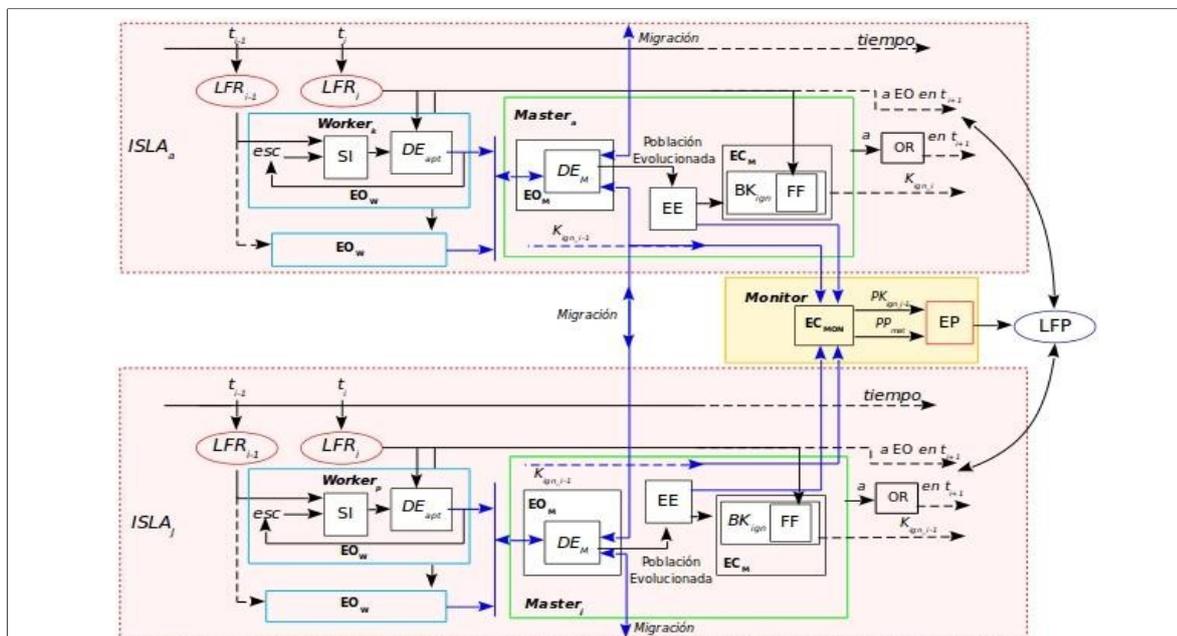


Figura 3. Diagrama general de ESSIM-DE(r). SI: Simulador de Incendios, DE_{apt}: Evolución Diferencial (evaluación de aptitud). EO_M: Etapa de Optimización (Master), EO_w: Etapa de Optimización (Worker), esc: escenario, LFR_t: línea de fuego Real del instante t, EE: Etapa Estadística, BK_{ign}: Búsqueda del valor clave de ignición, FF: Función de Fitness, Kign_t: Valor clave de ignición del instante t, EC_{MON}: Etapa de Calibración (Monitor), EP: Etapa de Predicción, OR: Operador de Reinicio de población, LFP: Línea de fuego predicha.

conclusiones obtenidas con este proceso de calibración estática y la proyección del trabajo a futuro.

2. Predicción de Incendios con ESSIM-DE(r)

Para realizar la predicción de la propagación del fuego en ESSIM-DE(r) el desarrollo total del incendio es dividido en diferentes instantes de tiempo discretos, denominados pasos de simulación. En cada uno de estos instantes operan en ESSIM-DE(r) cuatro etapas principales: la **Etapas de Optimización**, la **Etapas Estadística**, la **Etapas de Calibración**, y la **Etapas de Predicción**. ESSIM-DE(r) es un método general de reducción de incertidumbre con un esquema paralelo de Múltiples Poblaciones y Migración, o Modelo de Islas. Por lo tanto, cada una de estas etapas es llevada a cabo por un grupo de procesos, organizados en dos niveles, como se puede observar en el diagrama general de ESSIM-DE(r) de la Figura 3. 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 con mejor aproximación al incendio real. Se puede observar que el componente **Monitor** está relacionado con cada componente **Isla** con flechas azules que describen la comunicación entre las entidades. Por su parte, el nivel inferior de jerarquía responde a una isla. El proceso **Master** de cada isla coordina las acciones llevadas a cabo con la población de su isla y delega cierto cómputo a procesos **workers**. Además, las islas intercambian individuos entre sí, en una etapa de migración llevada a cabo por los **Masters** de cada isla. La **Etapas de Optimización** se concreta en el **Master** y los **workers** de cada isla mediante dos sub-etapas: **EO_M** (Etapas de Optimización en **Master**) y **EO_w** (Etapas de Optimización en **workers**). Estas etapas permiten evolucionar una población de individuos en base al optimizador Evolución Diferencial.

2.1. Evolución Diferencial

El algoritmo Evolución Diferencial (*Differential Evolution, DE*) [8] es un optimizador estocástico basado en múltiples soluciones, denominadas individuos, los cuales están organizados en una población. Cada individuo está representado por un vector de números

reales y codifica una posible solución. Los individuos evolucionan a través de las generaciones (o iteraciones) por medio de los operadores de mutación, cruzamiento y selección. En cada generación g se recorre la población, y por cada individuo $X_{i,g}$, los operadores de mutación y cruzamiento generan un individuo denominado *vector mutante*, utilizando diferencias de vectores para orientar la búsqueda hacia soluciones de mejor calidad.

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. La herencia es regulada por un parámetro del algoritmo denominado probabilidad de cruzamiento y por un tipo de cruzamiento, el cual determina qué porciones del progenitor serán heredadas. Dependiendo de la selección de los individuos que participan en la mutación y del tipo de cruzamiento, en DE se definen diferentes estrategias de mutación. Una de las más utilizadas se denomina '*DE/rand/1/bin*', indicando que uno de los individuos participantes en la mutación se seleccionará de manera aleatoria y el tipo de cruzamiento es binomial (para mayor detalle en las estrategias de mutación y los tipos de cruzamiento puede consultar [8]). 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.

2.2. Etapas de ESSIM-DE(r)

El proceso **Master** es el encargado de inicializar la población y aplicar los operadores evolutivos de mutación y cruzamiento de DE para generar nuevos individuos (etapas **EO_M**). Para determinar si los nuevos individuos generados permanecerán en la generación siguiente, el **Master** distribuye los individuos entre ciertos procesos **workers**, quienes evalúan el desempeño de cada uno. En la Etapas de Optimización llevada a cabo por los procesos **workers** (**EO_w**) se realiza la evaluación de la aptitud de los individuos mediante dos subetapas internas denominadas Simulación de Incendios (**SI**) y Evaluación de aptitud con Evolución Diferencial (**DE_{apt}**).

SI debe ser alimentado con la línea de fuego real del incendio en el instante de tiempo t_{i-1} (LFR_{i-1}), junto con un escenario de quema, o combinación de las variables que describen el contexto del incendio (escenario, **esc**).

Cuando SI concluye con la simulación del individuo, el mapa de quema resultante de la simulación es introducido en la etapa DE_{apt} para comparar el mapa obtenido de la simulación contra el mapa real del instante de tiempo t_i (LFR_i). Aquí se computa la diferencia entre el mapa obtenido por la simulación y el mapa real, y se calcula el valor de aptitud para cada individuo. La comparación entre dos mapas se realiza mediante una función denominada función de *fitness*, la cual se basa en el índice Jaccard [7] y determina la coincidencia de celdas entre ambos mapas, computada como lo indica la expresión (1), en donde A representa el conjunto de celdas en el mapa real sin el subconjunto de celdas quemadas antes de iniciar el proceso de predicción, y B representa el conjunto de celdas en el mapa predicho sin el subconjunto de celdas quemadas antes de iniciar la predicción. Por lo tanto, el valor de *fitness* estará comprendido en el rango [0,1], donde un valor igual a 1 representa una predicción perfecta, y un valor igual a cero indica el máximo error.

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

La función de *fitness* en ESSIM-DE(r) se utiliza con dos propósitos principales. Como hemos mencionado, por un lado, se utiliza a nivel EO_W para evaluar la aptitud de cada individuo, comparando el mapa obtenido por la simulación de cada uno de ellos respecto de la línea de fuego real del instante considerado t_i (LFR_i). Por otro lado, se utiliza a nivel de EC_M y EC_{MON} , como función para evaluar la calidad de una predicción: una vez que ESSIM-DE(r) obtiene la predicción de la línea de fuego en base a la agregación de todos los mapas de quema generados en la isla y una vez que se conoce el estado real del incendio, se pueden comparar ambos mapas para analizar la calidad de la predicción utilizando la función de *fitness* de la expresión (1).

A medida que los *workers* van obteniendo los resultados de la etapa EO_W , envían los mapas de quema obtenidos y su respectivo valor de aptitud al *Master*, quien determina si los individuos que han evolucionado sobrevivirán a la siguiente generación. Para ello, verifica

si la aptitud calculada por los *workers* es mayor a la aptitud del individuo original, en cuyo caso, el nuevo individuo generado reemplaza al individuo original. Este proceso se realiza para cada individuo de la población, en todas las islas. El *Master* también se encarga de efectuar la migración grupal de individuos hacia otra isla, seleccionando un conjunto de individuos de la población actual para ser enviados a otra isla. La comunicación entre islas sigue un orden topológico de anillo. Los individuos que arriban a una isla reemplazan a los peores individuos de la población destino.

En ESSIM-DE(r) el ciclo evolutivo está regido por un límite máximo de generaciones, que estipula la cantidad de iteraciones por las cuales ha de evolucionar la población, parámetro definido por el usuario. Este parámetro es un aspecto importante que será retomado con profundidad en la sección 3. Una vez que la población completa las diferentes generaciones evolutivas, es introducida en la Etapa Estadística (EE). En esta etapa se construye una matriz de probabilidades, cuyas celdas indican la probabilidad de ignición, es decir, la probabilidad de que cada celda sea alcanzada por el fuego respecto de todos los posibles escenarios de la población. Dicha probabilidad se calcula utilizando la expresión (2), donde n es el número total de escenarios y n_c es el número de escenarios en el cual la celda c fue alcanzada por el fuego.

$$P_{ign}(c) = \frac{n_c}{c} \quad (2)$$

Cada escenario es introducido al simulador de incendios y se obtiene un mapa de quema. Todos ellos son combinados en una matriz que incluye la probabilidad de ignición para cada celda y, por lo tanto, considera la contribución de cada escenario respecto del número total de escenarios. A partir del análisis de la matriz de probabilidades es posible identificar cuál es la tendencia de la línea de fuego en una Etapa de Calibración (EC_M). Esto se puede lograr seleccionando el conjunto de celdas con una probabilidad menor o igual a cierto valor. Para ello, se define un mapa de probabilidad P_K como conjunto de celdas cuyo valor P_{ign} es mayor o igual que K . El siguiente paso consiste en comparar el mapa real con cada mapa de probabilidades P_K . El objetivo es encontrar un valor particular de P_{ign} , cuyo mapa de probabilidad asociado sea el que mejor represente el avance real del fuego. Para ello se realiza la

búsqueda de lo que se denomina valor clave de ignición K_{ign} (BK_{ign}). Este valor será utilizado para realizar las predicciones en el siguiente instante de tiempo. La evaluación de la aptitud de cada mapa de probabilidad se lleva a cabo en la etapa que implementa la Función de *Fitness* (**FF**), en EC_M .

La Etapa de Predicción (**EP**) se lleva a cabo en el *Monitor*, en la etapa EC_{MON} . Para ello, la salida de **EE** se envía a EC_{MON} junto con los j valores de $K_{ign_{i-1}}$ calculados en el instante de tiempo anterior por las j islas. En la Etapa EC_{MON} el proceso *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 (**LFP**). Como se puede observar, para obtener la línea de fuego de predicción se hace necesario contar con el valor clave de ignición del instante de tiempo anterior. Por este motivo, en ESSIM-DE(r), así como en todos los DDM-MOS, no se pueden realizar predicciones en el primer instante de tiempo, puesto que en el primer paso se requiere calcular el primer valor de K_{ign} a ser usado en el segundo paso. El funcionamiento detallado de los niveles de ESSIM-DE(r) se resume en dos Etapas de Optimización (EO_W y EO_M), una Etapa Estadística (**EE**), dos etapas de calibración (EC_M y EC_{MON}) y una Etapa de Predicción (**EP**).

2.3. Operador de reinicio poblacional

Una vez que se obtuvo la predicción para el paso de simulación considerado, se procede hacia el siguiente paso de predicción. Dependiendo de la cantidad de iteraciones por las cuales haya evolucionado la población y de acuerdo a las características de exploración de Evolución Diferencial, se puede producir pérdida de distribución de la población. Por lo tanto, en el siguiente paso de predicción puede que no se generen mejores soluciones. Este comportamiento fue evidenciado en ESSIM-DE y por lo tanto se propuso la incorporación de un nuevo operador denominado **reinicio poblacional**. Este operador genera un nuevo espacio de soluciones independientes de las anteriores al inicio de cada paso de simulación. En la Figura 3 se representa este operador con la etapa **OR**. Por lo tanto, el proceso de predicción comienza con una población con alta distribución en los valores de aptitud, al inicio de cada instante de tiempo en los cuales se divide la duración del incendio total. Con el

operador de reinicio de poblaciones se permite perfeccionar los individuos de acuerdo al paso de predicción considerado, es decir, a las características particulares del incendio en el instante de tiempo considerado, y se ha logrado mejorar la calidad de las predicciones para la mayoría de los casos de prueba utilizados en la experimentación [10].

3. Sintonización aplicada a ESSIM-DE(r)

Para mejorar aquellos aspectos limitantes de mejor rendimiento ya hemos mencionado la incorporación del operador de reinicio de población (ESSIM-DE(r)), el cual fue descrito en la sección 2.3. Por otro lado, hemos incorporado el proceso de sintonización dinámica de la cantidad máxima de generaciones de cada paso de predicción de acuerdo a lo introducido en la sección 1 (ESSIM-DE(lr)), por lo que dicho ajuste se realiza mediante las etapas de instrumentación, monitorización, análisis y sintonización. El problema de rendimiento a sintonizar está asociado a la Etapa de Optimización llevada a cabo por el *Master* de cada isla (EO_M) y se describe a continuación.

3.1. Métricas del modelo de rendimiento

En ESSIM-DE(r) la condición de fin del ciclo evolutivo está determinada por un parámetro del método, el cual regula la cantidad máxima de iteraciones evolutivas que debe realizar el *Master* en la EO_M . Este parámetro (también denominado **límite de iteraciones** o cota máxima de iteraciones) tiene una doble influencia en el proceso de optimización, puesto que limita la cantidad de generaciones evolutivas por las cuales evolucionará cada población y, en consecuencia, determina el tiempo de ejecución del proceso evolutivo.

En ESSIM-DE(r), la configuración de este parámetro tiene el mismo valor para todos los pasos de simulación, y es establecido *a priori* de la ejecución. Sin embargo, esta configuración presenta varias desventajas. En general, no es factible conocer anticipadamente cuántas generaciones deben ser consideradas adecuadas como cota máxima de iteraciones. Si se utiliza un valor bajo como cota, puede suceder que no se logre evolucionar suficientemente la población, quedando zonas potencialmente significativas del espacio de búsqueda sin explorar y, en consecuencia, perjudicando la calidad de

las predicciones. De manera opuesta, si se utiliza un valor muy alto la población evoluciona demasiadas iteraciones, provocando pérdida de la diversidad de la población, la consecuente pérdida de la capacidad del optimizador para producir mejores individuos, y un incremento significativo del tiempo de cómputo total. En el contexto de la predicción de incendios, este último problema es crucial, puesto que se pretende obtener predicciones a corto plazo.

Por todos estos motivos, las métricas de monitorización para el modelo de rendimiento definidas están asociadas a esta condición de fin de ciclo evolutivo que fuera definida para ESSIM-DE(r). Se propuso que el valor de cota máxima de iteraciones pueda ser computado dinámicamente para cada paso de predicción. Esta hipótesis se fundamenta principalmente debido a que el proceso de optimización está condicionado por múltiples factores: depende de la velocidad de convergencia del método (condicionada por la probabilidad de cruzamiento y el factor de mutación), de la diversidad de la población en los diferentes pasos de simulación, de la frecuencia de migración (debido a su influencia en la diversidad de la población), del tipo de reemplazo, entre otros. En consecuencia, es una ventaja contar con un mecanismo de sintonización dinámica para la condición del fin de ciclo del proceso evolutivo, de manera tal que en tiempo de ejecución se determine la cantidad de iteraciones que se deben realizar en cada paso de predicción

Las métricas pretenden determinar algún criterio por el cual se pueda detectar en la Etapa de Optimización cuándo la población ha evolucionado por suficientes generaciones, sin llegar a un estado de estancamiento o de convergencia prematura. El estancamiento es la situación en la cual el optimizador no es capaz de generar nunca más una nueva solución mejor que la anterior, aún cuando la población no hubiese convergido. Esto significa que, aún cuando la población presente cierta diversidad, el optimizador es incapaz de encontrar mejores soluciones. Por su parte, la convergencia prematura es la situación en la cual la población converge a un óptimo local, debido a la pérdida de diversidad [5]. El problema del estancamiento de la población depende de los movimientos efectivos del optimizador Evolución Diferencial. Cuando se genera un nuevo individuo se

produce un movimiento en el espacio de búsqueda que representan los individuos de la población. Este movimiento se considera efectivo si el nuevo individuo generado posee mejor valor de aptitud respecto de su antecesor. De todos los posibles movimientos que se realizan en la población, algunos son efectivos, mientras que otros no lo son, y por lo tanto estos últimos implican un esfuerzo computacional en vano.

Como es posible notar, estos problemas son determinantes para lograr efectividad del optimizador. Por lo tanto, la detección anticipada de una tendencia hacia estos problemas puede ser una buena medida para determinar el momento en que la población ya ha evolucionado por suficientes generaciones como para pasar a la siguiente etapa.

3.2. Diversidad de la población y movimientos efectivos.

Para abordar los problemas del estancamiento de la población y de la convergencia prematura se propuso cuantificar dos métricas diferentes para la población. Las métricas son:

- Movimientos efectivos (métrica **ME**): cuantifica el porcentaje de individuos que luego de un ciclo evolutivo han sido mejorados, es decir, cuyo valor de aptitud es mejor que el de su predecesor.
- Diversidad poblacional (métrica **DP**): cuantifica la dispersión de la población, es decir, la variabilidad de la distribución de la población.

Los movimientos efectivos, o métrica **ME**, pueden ser computados de manera sencilla, contabilizando aquellos individuos que mejoran a sus antecesores. Respecto de la métrica **DP**, existen diferentes enfoques que han sido utilizados en la literatura como medida de la distribución en Estrategias Evolutivas. Uno ellos es el enfoque basado en la cuantificación genotípica, es decir, la medición de la dispersión respecto de las variables de los individuos (dimensión, o genotipo) que codifican a cada individuo. Dentro de esta categoría encontramos las mediciones de distancia en el espacio. En [12] se analiza cada dimensión de los individuos, y se computa el promedio de los valores de cada dimensión. La dispersión está asociada a la distancia euclidiana de un individuo respecto a este valor promedio. En [4] se utiliza la

distancia relativa a cada dimensión respecto del mejor individuo de la población. En otro enfoque se utiliza la desviación estándar como métrica estadística, computada a nivel de las dimensiones del individuo, e identifican que una dimensión está estancada cuando el valor de desviación estándar computado alcanza un cierto valor de umbral [13].

Los trabajos antes mencionados realizan el cómputo de la distribución poblacional con un enfoque basado en el genotipo, es decir, en los valores de las variables representando las dimensiones del problema considerado. ESSIM-DE(r) es un DDM-MOS, y como tal basa sus predicciones en la contribución de múltiples escenarios, sin la existencia de requisito alguno respecto de las características particulares de las dimensiones o variables que componen a los individuos. Por lo tanto, el enfoque que hemos elegido fue el cómputo de la distribución poblacional considerando la aptitud de los individuos de la población, es decir, en base al fenotipo de los individuos. La métrica estadística que hemos elegido es el Rango Intercuartil (*Inter Quartile Range, IQR*) [3] de los valores de aptitud de todos los individuos de la población, el cual representa una métrica de dispersión, y se define como la distancia desde el tercer al primer cuartil, como indica la expresión (3).

$$IQR = Q_3 - Q_1 \quad (3)$$

Como es posible notar, el cómputo del Rango Intercuartil es una medida que considera la distribución del 50% de los datos. A diferencia del cómputo de otras métricas, como el promedio de valores de aptitud, o la desviación estándar de los valores de aptitud, el cómputo de *IQR* es menos sensible a los valores atípicos (denominados *outlayers*). Por lo tanto, es considerado un estimador más robusto que los antes mencionados y, como tal, una buena medida para considerar la distribución de los datos [3].

3.3. Detección de pérdida de la distribución poblacional.

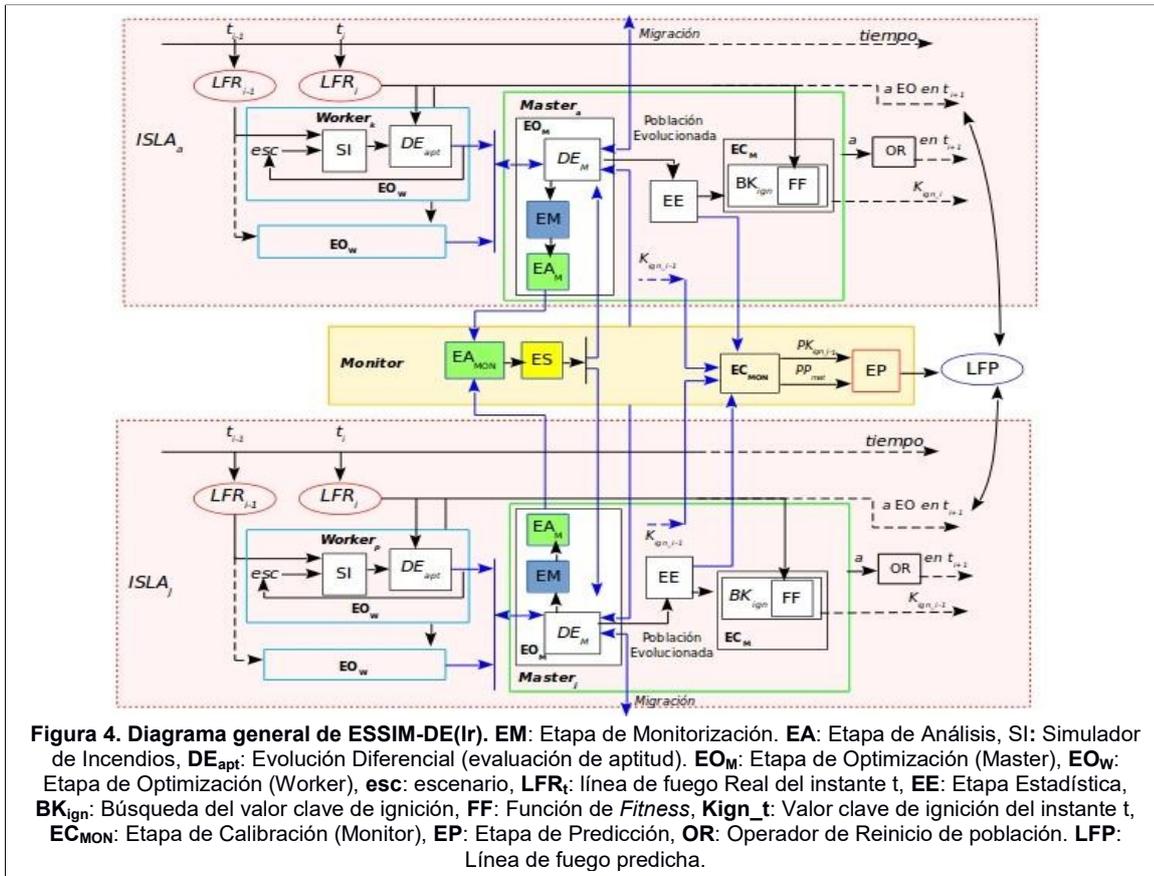
La métrica *IQR* permite cuantificar la distribución fenotípica de la población en base a la medición de la dispersión de los valores de aptitud de los individuos, y por lo tanto puede servir como indicador de convergencia. En este punto, cabe recordar que la

convergencia prematura es la situación en la cual la población converge a un óptimo local, debido a la pérdida de diversidad. Sin embargo, la métrica *IQR* no es suficiente para cuantificar el estancamiento debido a que el estancamiento es la situación en la cual, aun existiendo diversidad en la población, el optimizador es incapaz de encontrar mejores soluciones. Por lo tanto, para detectar este problema se incluye la medición de los movimientos efectivos del optimizador a través de la métrica *ME*. En consecuencia, se puede considerar que la población está estancada y/o converge a un óptimo local si se cumple la condición de la expresión (4).

$$IQR \leq \text{umbral_IQR} \wedge M \leq \text{umbral_M} \quad (4)$$

En caso de que la condición de la expresión (4) se cumpla en alguna isla, se considera que la población debe finalizar el ciclo evolutivo, y se puede proceder con el resto de las etapas de ESSIM-DE(r). Como es posible notar, el valor *umbral_IQR* pertenece al rango [0,1], puesto que se computa como diferencia de elementos de la muestra, es decir, valores de aptitud. Por su parte, el *umbral_M* pertenece al rango [0, NP], siendo NP el tamaño de la población. Los valores de umbral a establecer serán considerados como porcentaje, de manera tal que el valor *umbral_IQR* es ponderado al porcentaje respecto del máximo valor de aptitud (valor igual a 1), y el valor *umbral_M* representa el porcentaje de los individuos de la población que han sido efectivamente mejorados en una determinada generación.

También es posible observar que la condición de la expresión (4) considera dos valores *umbral_IQR* y *umbral_M*, los cuales deben ser establecidos en base a la experimentación, motivo principal del presente trabajo. Desde la literatura [13] se afirma, y hemos corroborado empíricamente, que identificar total estancamiento y/o convergencia requiere un tiempo de cómputo elevado. Las primeras pruebas piloto utilizaron dos valores de umbral que fueron establecidos en base a la observación durante la ejecución de la tendencia de ambas métricas. En este trabajo está orientado a analizar si dichos valores pueden ser calibrados estáticamente, con dos fines principales. Por un lado, se pretende determinar si los resultados obtenidos con los valores de referencia pueden ser mejorados, tanto en calidad de predicción como en tiempo de ejecución total. Por otro lado, se requiere



establecer la relación existente entre aquellas variaciones de los valores de umbral y el tiempo de cómputo requerido para alcanzar dichos valores.

Finalmente, la calibración estática sobre las métricas permitirá evaluar el impacto de las diferentes combinaciones de los valores para las métricas IQR y ME, gracias a la experimentación con diferentes configuraciones que permitan evidenciar el desempeño del método en la obtención de predicciones, y así vislumbrar la utilidad y ventaja que constituiría la automatización dinámica del ajuste de dichos parámetros del método.

3.4. Monitorización, análisis y sintonización.

El gráfico general del método con la estrategia de sintonización dinámica para determinar el fin del ciclo evolutivo, y con la aplicación del operador de reinicio de poblaciones se presenta en la Figura 4. Utilizaremos la sigla ESSIM-DE(ir) para diferenciar a ESSIM-DE(r) de

la propuesta que incorpora, además del operador de reinicio de poblaciones (r), el proceso de sintonización dinámica aplicada al límite (l) de iteraciones evolutivas. La monitorización de las métricas es llevada a cabo en el Master, en una nueva sub-etapa de la EO_M, denominada **Etapa de Monitorización (EM)**, y se concreta en dos fases:

- Métrica ME: El proceso Master actualiza la métrica ME cada vez que los procesos worker envíen la evaluación de la aptitud de un individuo. En la etapa EO_M, el Master analiza si el nuevo individuo generado es mejor que su ancestro. El resultado de dicho análisis es introducido a la etapa EM en la cual se incrementa un contador local para la métrica ME.
- Métrica DP (cómputo de IQR): Una vez que finaliza una generación evolutiva, se envían los valores de aptitud de todos los individuos a la EM para que se calcule la métrica IQR, computando la expresión (3).

Como el cómputo de ambas métricas (ME y DP) se realiza en cada isla, la **Etapa de Análisis** requiere de la asistencia de los *Masters* de cada isla y del *Monitor*. Los valores registrados son enviados desde EM hacia la Etapa de Análisis llevada a cabo en el *Master* (EA_M). Al finalizar cada iteración, cada *Master* envía las métricas de su isla computadas en la EA_M hacia el proceso *Monitor*, quien realiza una agregación de todas las métricas de las islas en su Etapa de Análisis (EA_{MON}). Los valores recopilados en la EA_{MON} son enviados a la Etapa de Sintonización (ES), en la cual se determina si existe alguna isla con tendencia a estancamiento y/o convergencia prematura. Si se evalúa como verdadera la expresión (4) con los valores computados de alguna de las islas, el *Monitor* determina que la población ha evolucionado lo suficiente como para frenar la evolución, realizar la predicción e iniciar con el siguiente paso. Luego, se aplicará el operador de reinicio poblacional (OR) para comenzar el proceso evolutivo del siguiente paso con una nueva población (nuevo espacio de búsqueda).

4. Experimentación y Resultados Obtenidos

Para realizar los experimentos se han utilizado tres 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 [14]. Cada caso posee una determinada duración expresada en minutos, una pendiente en grados y una superficie específica en metros cuadrados. Dado que se trata de quemas controladas, la duración de cada incendio es de cierta cantidad de minutos. A su vez, a efectos de poder aplicar los métodos de predicción, el período de duración total de cada incendio ha sido dividido en lapsos de tiempo denominados pasos de simulación. Los tres casos de quema considerados se describen en la Tabla 1. Para cada uno de ellos se computaron los valores de *fitness* y de tiempos, para un promedio de 10 semillas. Los experimentos fueron realizados en un *cluster* de computadoras, utilizando un total de 41 unidades de procesamiento Intel Q9550 2.83GHz, con memoria RAM de 4GB DDR3 1333Mz.

La experimentación con los casos de quema controlada estuvo enfocada en la comparación de los

resultados computados con una configuración inicial para las métricas IQR y ME (denominada configuración de referencia), respecto de cuatro configuraciones adicionales, en las cuales se varían las métricas en una magnitud superior e inferior respecto de los valores de referencia, las cuales se enumeran en la Tabla 2. La configuración de referencia θ (ref.) que se estableciera en las primeras pruebas fue $umbral_IQR=2.5\%$ y $umbral_M=20\%$. Esto significa que, cuando la diferencia entre el tercer y el primer cuartil esté por debajo de 0.025 y cuando se generen menos del 20% de movimientos efectivos del optimizador, la población tendrá una tendencia al estancamiento y/o a la convergencia, por lo tanto, el ciclo evolutivo ha de finalizar. Como es posible notar, las nuevas configuraciones (1, 2, 3 y 4) contemplan dos valores para $umbral_IQR$ (1% y 5%) y dos valores para $umbral_M$ (10% y 20%), por lo tanto, la experimentación consistió en la utilización de las cuatro combinaciones de estos valores en contraste con la combinación de referencia. Como hipótesis se plantea que las dos configuraciones con valores de $umbral_IQR=5\%$ son las que requerirán menor tiempo de ejecución, debido a que es probable alcanzar dicho umbral en menor cantidad de iteraciones, y en contra parte, las que utilicen $umbral_IQR=1\%$ requerirán mayor tiempo de ejecución. Sin embargo, se intenta determinar el impacto respecto de la calidad de las predicciones, sobre la elección de un valor de umbral más alto o más bajo. La configuración del resto de los parámetros ha sido establecida en base a aquellos valores utilizados en computaciones previas con el método, y se incluyen en la Tabla 3. Para simplificar la nomenclatura, en los gráficos se utiliza la leyenda ESSIM-DE(lr_x), siendo x alguna de las configuraciones de sintonización estática de la Tabla 2. En los gráficos, se incluyen los resultados obtenidos con ESSIM-DE(r), utilizando un límite de cota fijo como condición de fin del ciclo evolutivo a 30 iteraciones.

4.1. Resultados

Los resultados obtenidos son presentados en las Figuras 5, 6 y 7 representando la experimentación con los casos A, B y C de la Tabla 1, respectivamente. En cada una se incluye un gráfico con los valores de *fitness* promedio obtenidos por cada experimento y en cada paso de predicción.

En primer lugar, se puede observar que los gráficos de las Figuras 5 a la 7 pueden o no seguir una tendencia creciente o decreciente, puesto que dependiendo del paso de predicción que se esté analizando se logra obtener valores más altos o más bajos de aptitud.

Tabla 1. Casos de quema: dimensión, pendiente y tiempo de inicio, fin e incremento.

Caso	Ancho (m)	Alto (m)	Pend. (gr)	T.ini (min)	T. fin (min)	Incr.(min)
A	89	109	21	2.0	14.0	2.0
B	89	91	21	2.5	12.5	2.5
C	60	90	6	2.0	10.0	2.0

Tabla 2. Configuraciones utilizadas en el proceso de sintonización estática para IQR y ME.

Configuración	IQR	ME
0 (ref)	2.5%	20%
1	1%	20%
2	1%	10%
3	5%	20%
4	5%	10%

Tabla 3. Configuración de los parámetros de ESSIM-DE(r) y ESSIM-DE(lr)

Parámetro	Valor
Tamaño de cada población	200 individuos
Porcentaje de individuos a migrar	20%
Frecuencia de migración	en cada iteración
Límite de iteraciones evolutivas (solo para ESSIM-DE(r))	30 iteraciones
Estrategia de mutación y cruzamiento	DE/rand/1/bin
Probabilidad de cruzamiento	0.45
Factor de mutación	0.9
Cantidad de islas	5
Cantidad de <i>workers</i> por isla	7

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 casos de quema. Obtener un incremento en la calidad de la predicción significa haber encontrado mayor precisión en

la delimitación de la zona que puede verse afectada por el avance del fuego. Las mejoras parciales representan un gran resultado desde el punto de vista de la predicción, puesto que brindan la posibilidad de generar medidas preventivas a corto plazo, antes y durante el avance del incendio, y por ende permiten dirigir las acciones a seguir con el objetivo de reducir el impacto del fuego.

Tabla 4. Tiempos de ejecución promedio (segundos).

Conf.	A	B	C
ESSIM-DE(r)	2898	4374	2709
ESSIM-DE(lr_0)	1642	3170	886
ESSIM-DE(lr_1)	2106	3501	1271
ESSIM-DE(lr_2)	2407	3695	1261
ESSIM-DE(lr_3)	1522	2885	734
ESSIM-DE(lr_4)	1306	2929	754

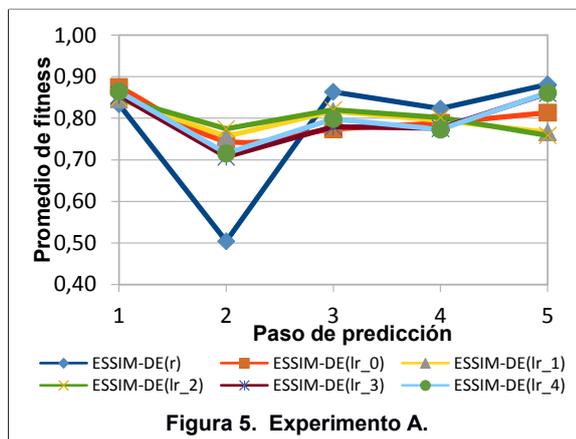


Figura 5. Experimento A.

En la Figura 5 se muestran los resultados obtenidos con el experimento A. El incendio real se inicia en el minuto 2 y finaliza en el minuto 14, con un incremento de 2 minutos (ver Tabla 1). Por lo tanto, cuenta con un paso de simulación (minuto 2 al minuto 4) y 5 pasos de predicción (minutos 4-6, 6-8, 8-10, 10-12 y 12-14). Como es posible observar del gráfico de la Figura 5, ESSIM-DE(r) comienza con un valor de aptitud cercano a 0,85 en el paso de predicción 1, decae en aptitud en el paso de predicción 2 con un valor promedio cercano a 0,5, posteriormente se mantiene en los pasos de predicción 3, 4 y 5 con valores superiores a 0,85 aproximadamente. Es posible observar que cualquiera de las configuraciones que utilizan las métricas IQR y ME

mejora significativamente los valores promedio de *fitness* del paso 2, con valores superiores a 0.7 (recordemos que un valor de *fitness* igual a 1.0 representa una predicción perfecta). También se puede notar que las configuraciones que utilizan *umbral_IQR=5%* (ESSIM-DE(lr_3) y ESSIM-DE(lr_4)) obtienen un valor de *fitness* cercano a 0.9 en el último paso de predicción, mejorando incluso a la configuración de referencia.

Analizando los tiempos de ejecución de la Tabla 4, columna A, se puede notar que las configuraciones con *umbral_IQR=5%* son además aquellas que insumen menor tiempo de ejecución, logrando una reducción de hasta un 20%, aproximadamente, respecto del valor de referencia. Por lo tanto, se corrobora la hipótesis acerca de la asociación entre la métrica *umbral_IQR* y el tiempo requerido para alcanzar dicho umbral.

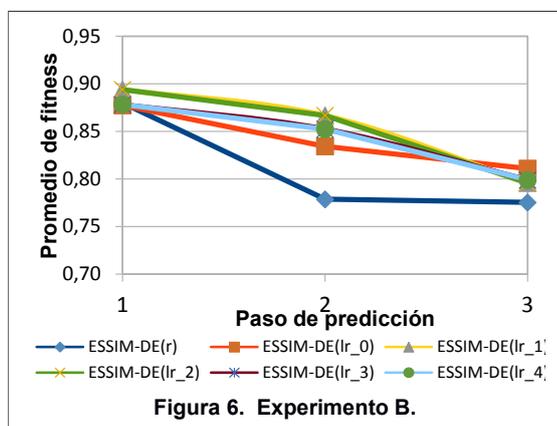


Figura 6. Experimento B.

En la Figura 6 se muestran los resultados obtenidos con el Experimento B. El incendio real se inicia en el minuto 2.5 y finaliza en el minuto 12.5, con un incremento de 2.5 minutos. Por lo tanto, cuenta con un paso de simulación (minuto 2.5 al minuto 5.0) y 3 pasos de predicción (minutos 5-7.5, 7.5-10.0 y 10.0-12.5). Como es posible observar de la Figura 6 los resultados de promedio de *fitness* son mejorados por cualquiera de las configuraciones utilizadas. En este experimento se puede notar que los valores promedio son muy similares para el mismo valor de la métrica *umbral_IQR*. Observando los tiempos de ejecución, la configuración *umbral_IQR=5%* y *umbral_M=20%* obtiene los menores tiempos de respuesta, logrando una reducción de un 8% respecto de la configuración de referencia.

En la Figura 7 se muestran los resultados obtenidos con el Experimento C. El incendio real se inicia en el minuto 2 y finaliza en el minuto 10, con un incremento de 2 minutos. Por lo tanto, cuenta con un paso de simulación (minuto 2 al minuto 4) y 3 pasos de predicción (minutos 4-6, 6-8 y 8-10). Como es posible observar de la Figura 7, los valores de *fitness* obtenidos por ESSIM-DE(r) decaen en el paso de predicción 2 y 3, mientras que los valores obtenidos con las configuraciones alternativas utilizadas obtienen resultados cercanos o superiores a 0.7 en todos los pasos de predicción. Es importante remarcar que la configuración *umbral_IQR=5%* y *umbral_M=20%* (ESSIM-DE(lr_3)) logra una reducción de tiempo de un 17% aproximadamente, respecto de la configuración de referencia.

Del análisis general se puede observar que la calibración estática permite encontrar mejoras en los resultados de calidad de las soluciones encontradas para algunos pasos de predicción. Respecto a los tiempos de respuesta, aquellas configuraciones con *umbral_IQR=5%* son las que obtienen menor tiempo de respuesta. Por lo tanto, se pudo corroborar que el uso de este valor de umbral permite mejorar los tiempos de respuesta, a un costo computacional menor, y con una calidad de predicción similar a la de las otras configuraciones, las cuales requieren mayor tiempo de ejecución. Estos resultados sirven como soporte experimental para definir un criterio que permita automatizar el valor a utilizar para las métricas IQR y ME, evitando el uso de una configuración estática y simplificando así la configuración de ESSIM-DE(lr) al usuario final.

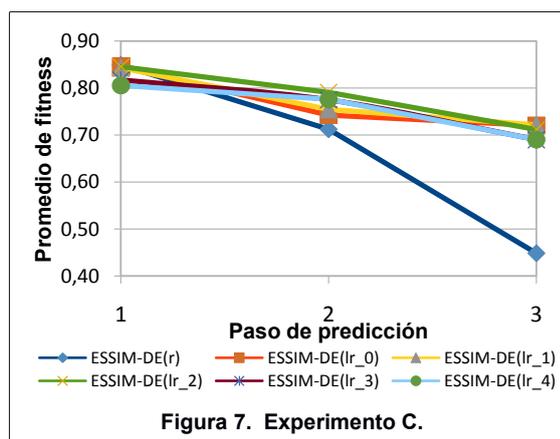


Figura 7. Experimento C.

5. Conclusiones

En este trabajo se presentó un estudio de calibración estática para dos métricas utilizadas para regular la evolución de las poblaciones administradas por el método ESSIM-DE(lr). Dichas métricas permiten cuantificar una tendencia al estancamiento y/o convergencia prematura de la población a fin de calibrar el límite máximo de generaciones a realizar en el proceso evolutivo. La experimentación fue realizada con tres casos de quemaduras reales controladas, cada mapa posee características diferentes entre sí. Los resultados obtenidos han demostrado que la calibración estática permite ajustar los valores de estos parámetros, logrando obtener mejoras en algunos pasos de predicción para los casos de quema considerados. Se lograron mejoras respecto de la configuración de referencia, obteniendo reducciones de hasta un 20% del tiempo de ejecución. Esta reducción de tiempos está asociada a una detección temprana de los problemas de estancamiento y convergencia, evitando que el optimizador continúe con el ciclo evolutivo y, por lo tanto, reduciendo el tiempo de ejecución global. En el contexto de la predicción de incendios forestales, estas reducciones de tiempo pueden resultar esenciales para obtener predicciones a corto plazo y, por ende, para aplicar medidas preventivas, de reducción de riesgos o de evacuación, con anticipación a la evolución del incendio.

Este trabajo constituye parte del estudio empírico realizado para dar el primer paso en la definición de una nueva estrategia de sintonización dinámica, la cual pueda mejorar el rendimiento de ESSIM-DE(lr) de un modo transparente al usuario final. Por lo tanto, como trabajo a futuro se plantea establecer un criterio para auto-ajustar ambas métricas en tiempo de ejecución, de manera tal de evitar la configuración *off-line* de estos valores de umbral, permitiendo que dicho ajuste sea realizado en cada paso de acuerdo a las características de la población, en lugar de la utilización de valores fijos. De esta forma, se pretende lograr mejoras en la calidad de las predicciones y en el tiempo de ejecución, y a la vez la simplificación de la configuración de ESSIM-DE(lr).

6. Agradecimientos

Este trabajo ha sido financiado mediante los proyectos SIUTIME0004736TC y SIUTNME0004819 de la UTN-

FRM. El primer autor agradece a CONICET por la beca doctoral otorgada para realizar este trabajo.

7. Referencias

- [1] <https://www.lanacion.com.ar/2156510-grecia-incendios-fuego-muerte-sobrevivientes-desaparecidos-calor>. Accedido el 1 de agosto de 2018.
- [2] Fons W. (1946) "Analysis of fire spread in light forest fuels", En: J. Agric. Res. vol 72. p. 93-121.
- [3] Healey, J. F., The Essentials of Statistics: A Tool for Social Research, Thomson/Wadsworth, 2007.
- [4] Herrera, F. y Lozano, M. "Adaptation of Genetic Algorithm Parameters Based on Fuzzy Logic Controllers", Genetic Alg. and Soft Computing, Physica-Verlag, 1996, p. 95-125.
- [5] Lampinen, J. y Zelinka, I., "On the Stagnation of the Differential Evolution algorithm", VI Int. Conf. Soft Computing (Mendel 2000), Rep. Checa, junio 2000, pp. 76-83.
- [6] Naono, K., Teranishi, K., Cavazos, J. y Suda, R., *Software Automatic Tuning: From Concepts to State-of-the-Art Results*, Springer, New York, 2010.
- [7] Real, R. y Vargas, J.M. "The Probabilistic Basis of Jaccard's Index of Similarity", J. Syst. Biology, 45, 3, 1996, pp. 380-385.
- [8] Storn, R., Price, K. y Lampinen J., *Differential Evolution: A Practical Approach to Global Optimization*, Springer, New York.
- [9] Tardivo M.L., Caymes-Scutari P., Bianchini G., Méndez-Garabetti M., Cortés, "Three evolutionary statistical parallel methods for uncertainty reduction in wildland fire prediction". Int. Conf. HPCS, Innsbruck, Austria, 2016, pp. 721-72
- [10] Tardivo, M.L., Caymes-Scutari, P., Méndez-Garabetti, M. y Bianchini, G., "Optimization for an Uncertainty Reduction Method Applied to Forest Fires Spread Prediction", Computer Science – Cacic 2017, Springer, 2018, pp. 13-23.
- [11] Tardivo, M.L., Caymes-Scutari P. Bianchini G. Méndez-Garabetti, M., "Monitorización y Análisis de Métricas Poblacionales en un Método de Predicción de Incendios Forestales". Artículo aprobado. VI Seminario Argentina Brasil de Tecnología de la Información y la Comunicación. 2018.
- [12] Ursem, R., "Diversity-Guided Evolutionary Algorithms", Parallel Problem Solving from Nature - PPSN VII, Springer Berlin Heidelberg, 2002, 462-471.
- [13] Yang, M., Li, C., Cai, Z., y Guan, J., "Differential Evolution with Auto-Enhanced Population Diversity", IEEE Transactions on Cybernetics, 45, 2, 2015, pp. 302-315.
- [14] Viegas, D. X., "Project Spread – Forest Fire Spread Prevention and Mitigation", <http://www.algosystems.gr/spread/>, 2004. Accedido el 10 de Julio de 2018