

REDUCCIÓN DE INCERTIDUMBRE CON EVOLUCIÓN DIFERENCIAL EN LA PREDICCIÓN DE INCENDIOS FORESTALES: SINTONIZACIÓN Y ANÁLISIS DE PARÁMETROS

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

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

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

^cDepartamento de Computación, Universidad Nacional de Río Cuarto, Río Cuarto, Córdoba, Argentina. lauratardivo@dc.exa.unrc.edu.ar.

Palabras clave: Reducción de Incertidumbre, Algoritmos Evolutivos, Predicción, Evolución Diferencial, Cómputo Paralelo/Distribuido

Resumen. El modelado de cualquier fenómeno natural representa un gran desafío desde el punto de vista matemático y computacional. Pronosticar el comportamiento de los incendios forestales no es la excepción. Los modelos de predicción de incendios forestales generalmente son alimentados por parámetros de entrada que representan el estado del terreno en el instante previo a la predicción, así como también las condiciones de las variables que intervienen en el desarrollo del incendio (velocidad y dirección del viento, humedad del terreno, tipo de vegetación). Sin embargo, para lograr cierto grado de precisión al momento de la predicción se hace necesario contar con el valor real de cada parámetro de entrada. La falta de exactitud o incertidumbre sobre el valor de los parámetros de entrada es un problema crucial que puede producir graves consecuencias si la salida del modelo proporciona predicciones erróneas. Los métodos de reducción de incertidumbre permiten mejorar la calidad de predicción contrarrestando los efectos negativos que produce la imposibilidad de cuantificar los valores de los parámetros en tiempo real. Tal es el caso del método ESSIM-DE (Evolutionary Statistical System with Island Model and Differential Evolution), el cual ha sido aplicado al problema de predicción del comportamiento de incendios forestales. ESSIM-DE utiliza análisis estadístico, cómputo paralelo/distribuido y la metaheurística Evolución Diferencial como estrategia para la búsqueda de nuevas soluciones. En el uso de toda metaheurística, es importante realizar una correcta elección de los parámetros de entrada propios de la metaheurística, ya que de ellos depende el comportamiento de la estrategia, y en consecuencia también condiciona la calidad de la predicción. En este trabajo se desarrolla un análisis de sintonización estática de los parámetros evolutivos de ESSIM-DE a fin de encontrar mejor calidad de predicción.

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. Por este motivo, se hace necesario contar con herramientas de predicción que puedan pronosticar con antelación la tendencia de la línea de fuego. Este tipo de herramientas generalmente implementa modelos matemáticos que describen el comportamiento del fenómeno natural. Los modelos generalmente son alimentados con parámetros de entrada, que representan las condiciones iniciales del sistema que se quiere modelar. En el caso de los incendios forestales, los factores que afectan la velocidad de propagación y la morfología del frente de fuego son el tipo de combustible (tipo de vegetación), la humedad, la dirección y velocidad del viento, la topografía del terreno (pendiente y barreras naturales) y la densidad del combustible (Fons, 1946). Por lo tanto, el conocimiento del entorno y de las condiciones en las cuales se desarrolla el incendio puede ser complementado con el uso de herramientas de predicción; esto permitiría tener una estimación del desplazamiento del fuego, sirviendo de gran utilidad a la hora de definir acciones y tomar decisiones anticipadas al avance del incendio.

Los modelos de propagación del fuego pueden ser agrupados en tres categorías: empíricos, semi-empíricos y modelos físicos (Bodrožić *et al.*, 2006). En los modelos empíricos, la predicción del posible comportamiento del fuego se realiza en base a mediciones obtenidas en laboratorio, en experimentos realizados en entornos controlados, o a partir del conocimiento que se obtiene de datos históricos de incendios. Los modelos semi-empíricos (modelos semi-físicos) son aquellos basados en un balance de energía global y en el supuesto de que la energía transferida al combustible no quemado es proporcional a la energía liberada por la combustión del combustible; uno de los más importantes de estos modelos es el trabajo realizado por Rothermel (1972, 1983). Por último, los modelos físicos (teóricos o analíticos) están basados en principios físicos y tienen el potencial de predecir con precisión los parámetros de interés de un rango más amplio de variables de entrada que los modelos empíricos. Todos estos modelos pueden ser utilizados para desarrollar simuladores y herramientas para prevenir y luchar contra los incendios forestales. Algunos ejemplos son Behave-Plus (Andrews *et al.*, 2003), FARSITE (Finney, 1998), FIREMAP (Ball y Guertin, 1991), FireStation (Lopes *et al.*, 2002), WRF-Fire (Mandel *et al.*, 2011), Xfire (Jorba *et al.*, 1999), etc.

En general, la aplicación directa de un simulador obtiene resultados que usualmente difieren de la realidad. Esto se debe a que la mayoría de los modelos presentan limitaciones a la hora de representar con precisión los valores de los parámetros de entrada. Este problema, conocido como incertidumbre, puede provocar consecuencias graves si la salida del modelo provee soluciones erróneas. En los últimos años se han propuesto diversas técnicas de reducción de incertidumbre. Entre ellas, encontramos al método ESSIM-DE (Evolutionary Statistical System with Island Model and Differential Evolution), el cual utiliza el algoritmo evolutivo Evolución Diferencial (DE, por sus siglas en inglés), Computación de Alto Desempeño y Análisis Estadístico. El algoritmo evolutivo DE, permite orientar la búsqueda hacia mejores soluciones. El cómputo de Alto Desempeño brinda la posibilidad de reducir los tiempos de respuesta de las etapas predictivas, obteniendo soluciones a corto plazo.

Finalmente, el Análisis Estadístico permite obtener patrones de comportamiento para analizar la tendencia de la línea de fuego.

El método ESSIM-DE ha demostrado obtener muy buenos tiempos de respuesta (Tardivo *et al.*, 2016). Sin embargo, la calidad de las soluciones encontradas puede ser aún mejorada. La utilización de algoritmos evolutivos requiere una adecuada configuración de los parámetros que guían su esquema de procesamiento. La sintonización (ajuste o calibración) de los mismos puede mejorar significativamente el desempeño global del método, lo cual implica, en el contexto de ESSIM-DE, obtener mayor exactitud en las predicciones. En particular, en este trabajo se presta especial interés en la sintonización de la etapa de migración de individuos entre las diferentes islas. Dicha etapa es crucial a la hora de incorporar nuevas soluciones provenientes de otros espacios de búsqueda, lo cual permite diversificar la población y evitar la convergencia prematura. El objetivo principal de este estudio es mejorar las capacidades de búsqueda de ESSIM-DE y obtener el mejor desempeño posible en términos de calidad de predicción.

2 ALGORITMOS EVOLUTIVOS PARALELOS

Los Algoritmos Evolutivos Paralelos (PEAs) son considerados métodos eficientes de búsqueda que pueden ser aplicados a problemas de optimización y están inspirados en las teorías de Charles Darwin (1959) acerca de la evolución de las especies. Los PEAs pertenecen al conjunto de Metaheurísticas Poblacionales y están diseñados para operar en ambientes de Cómputo de Alto Desempeño. En general, cada PEA consiste en una serie de iteraciones, denominadas generaciones evolutivas, en las cuales un grupo de posibles soluciones del problema, llamados *individuos*, conforman una población. 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 población evoluciona a través de las generaciones imitando principios de selección natural y supervivencia. La premisa subyacente en la evolución es que los individuos más aptos sobrevivan a la siguiente generación, es decir, permanecerán solo aquellos cuyo desempeño signifique un mejor valor como solución posible del problema.

Cada PEA 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 posee mejor desempeño. Los PEAs permiten que los mejores individuos tengan mayor probabilidad de reproducirse, de manera tal de generar nuevas soluciones de calidad. Esto lo logran a través de tres operadores: cruzamiento, mutación y selección; los PEAs se diferencian entre sí de acuerdo a cómo se definen en cada uno estos tres operadores.

Como mencionamos anteriormente, los PEAs están diseñados para operar en entornos paralelos. Esto permite reducir los tiempos de procesamiento, resolver instancias del problema de mayores dimensiones y también, según como se defina el tratamiento de las soluciones, incrementar la capacidad de búsqueda del algoritmo (Talbi, 2009). Existen

diferentes estrategias de paralelización. Los modelos paralelos/distribuidos existentes en general consisten en un esquema *Master-Worker* (Mattson, 2004), en donde un proceso denominado *Master* es el encargado de realizar tareas principales y/o globales. Por su parte, los procesos *workers* están destinados a realizar diferentes acciones, dependiendo del tipo de paralelización. ESSIM-DE sigue un esquema de paralelización de Múltiples Poblaciones y Migración, también conocido como *Modelo de Islas* (Cantú Paz, 1998). Esta estrategia de paralelización consiste en trabajar con diferentes poblaciones o sub-poblaciones, donde cada una de éstas es considerada una isla. De esta manera, los operadores de cruzamiento, mutación y reemplazo, son aplicados entre individuos de la misma isla.

Con el objetivo de que las islas no evolucionen de manera completamente independiente, se introduce un operador para intercambiar individuos entre las diferentes islas, el cual es llamado *migración*. La migración tiene el objetivo de incorporar mayor diversidad y disminuir la probabilidad de convergencia prematura o estancamiento en óptimos locales.

Para poder configurar el proceso de migración se hace necesario definir los parámetros que controlan cuántos individuos viajarán de una isla hacia la otra (porcentaje de individuos a migrar) y cuántas veces migrarán durante toda la simulación (frecuencia de migración). Estos valores están estrechamente relacionados con la cantidad total de individuos en la población y con la cantidad total de iteraciones evolutivas. La sección 4 describe con profundidad el método ESSIM-DE, detallando las etapas que lleva a cabo cada una de las entidades que lo componen, y focalizando en el proceso de *migración*. Para poder comprender aún más el método, se reseña a continuación el Algoritmo Evolutivo utilizado en ESSIM-DE.

2.1 Evolución Diferencial

El algoritmo Evolución Diferencial (DE) se clasifica dentro de los Algoritmos Evolutivos (EA) y ha sido utilizado con éxito en diferentes problemas de optimización de funciones (Price, 2005). 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 1 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 1: 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 descriptos anteriormente. DE tiene un gran potencial y ha sido utilizado en una gran variedad de problemas de optimización concretos. Sin embargo, su desempeño puede ser mejorado a través de estrategias de paralelismo (Tardivo *et al.*, 2013).

3 SISTEMA ESTADÍSTICO EVOLUTIVO CON MODELO DE ISLAS Y EVOLUCIÓN DIFERENCIAL (ESSIM-DE)

ESSIM-DE es un método general de reducción de incertidumbre que nace a partir de dos métodos de predicción denominados ESS (Evolutionary Statistical System) (Bianchini *et al.*, 2015) y ESSIM (Evolutionary Statistical System with Island Model) (Méndez Garabetti *et al.*, 2016). En particular, ESSIM-DE ha sido diseñado para operar en un ambiente paralelo/distribuido y utiliza como método de búsqueda al algoritmo Evolución Diferencial. El método ESSIM-DE ha demostrado obtener muy buenos tiempos de respuesta (Tardivo *et al.*, 2016). Sin embargo, la calidad de las predicciones puede ser mejorada a través de la sintonización estática de sus parámetros operacionales. Para poder comprender el funcionamiento del método, a continuación se describirán sus principales componentes y la interacción entre ellos.

Como se mencionó en la sección 2, ESSIM-DE sigue un esquema paralelo de Múltiples Poblaciones y Migración, o Modelo de Islas. Desde una visión jerárquica, los procesos están organizados en dos niveles. En una jerarquía superior se dispone de un proceso denominado **Monitor**, que es el encargado de enviar información de inicialización a cada isla, recolectar los datos procesados en la etapa final de la simulación y determinar los valores de salida, identificando cuál es la isla que ha resultado con mejor aptitud.

La Figura 2 describe el diagrama general de ESSIM-DE. Se puede observar que el componente **Monitor** está relacionado con cada componente **Isla** a través de la comunicación antes mencionada. Por su parte, el nivel inferior de jerarquía responde a un esquema de isla. El proceso **Master** de cada isla es el encargado de inicializar la población y aplicar los operadores de mutación y cruzamiento para generar nuevos individuos (etapa **EO-Master**). Para determinar si los nuevos individuos generados permanecerán en la generación siguiente, el **Master** distribuye los individuos entre ciertos procesos workers, quienes evalúan el desempeño de cada uno aplicando la función de aptitud y retornando al **Master** la evaluación obtenida. En la Figura 2, la comunicación entre el Master y los workers está representada por flechas de doble dirección que unen los componentes **Master** y **EO-Worker**.

La Etapa de Optimización (**EO-Worker**) es llevada a cabo por los procesos workers. En esta etapa se realiza la evaluación de la aptitud de los individuos mediante dos subetapas internas denominadas Simulación de Incendios (**SI**) y Evolución Diferencial (**DEA**). **SI** debe ser alimentada con la línea de fuego real del incendio en el instante de tiempo t_{i-1} (**LFR_{i-1}**), junto con el vector de parámetros de entrada (**VP**). Cuando **SI** concluye con la simulación de los individuos, cada resultado es introducido en la etapa **DEA** para comparar el mapa simulado contra el mapa real del instante de tiempo t_i (**LFR_i**). Aquí, según la diferencia entre el mapa simulado y el mapa real, se calcula el valor de aptitud para cada individuo. A medida que los workers van obteniendo los resultados de la etapa **EO-Worker**, envían estos valores al Master, quien determina si los individuos generados en el proceso de mutación y cruzamiento sobrevivirán a la siguiente generación. Para ello, verifica si la aptitud calculada por los workers es mayor a la aptitud del individuo corriente, en cuyo caso, el nuevo individuo generado reemplaza al individuo corriente. Este proceso se realiza para cada individuo de la población.

El Master también se encarga de efectuar la migración grupal de individuos hacia otra isla. 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 cantidad de individuos totales que son seleccionados para emigrar hacia otra isla es controlada por un parámetro del algoritmo (**PM**: porcentaje de individuos a migrar). Por su parte, el proceso de migración se realiza con cierta frecuencia respecto de las generaciones evolutivas (**IE**: Iteraciones Evolutivas). Esta frecuencia de migraciones es configurada por el usuario (**FM**: frecuencia de migración), e implica el grado de comunicación entre las islas involucradas. Por lo tanto, el proceso de migración influirá en los costos totales de comunicación del método: el tamaño de los mensajes dependerá del porcentaje de individuos a migrar y del tamaño de la población (**TP**: tamaño de la población), mientras que la frecuencia de migraciones determinará la cantidad total de envíos. La comunicación entre islas sigue un orden topológico de anillo, es decir, las islas son numeradas en orden creciente y cada una envía información a la isla sucesora, y recibe datos desde la isla predecesora. Los individuos que arriban a una isla reemplazan a los peores individuos de la población destino. Esta migración grupal permite incrementar la diversidad poblacional en cada isla, a partir de la incorporación de nuevos individuos que han evolucionado con las características de la población de la isla de partida, y que se incorporarán, evolucionarán y desarrollarán en la población destino.

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

Tal como puede observarse en la Figura 2, 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**).

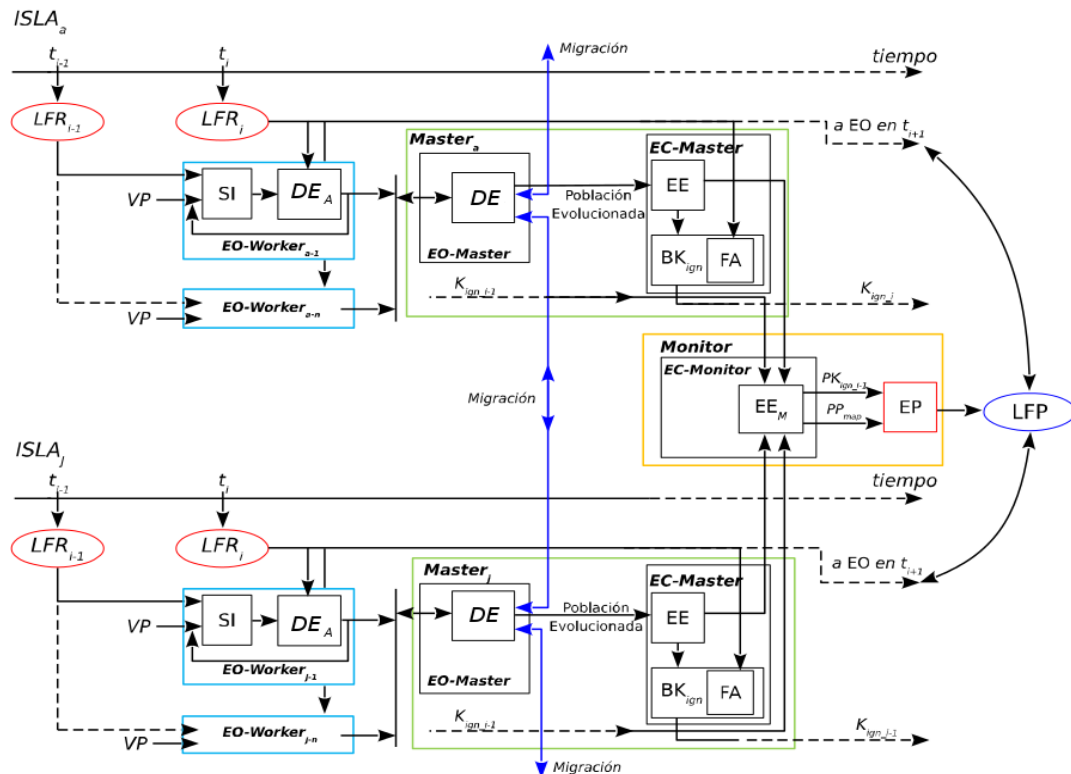


Figura 2: Diagrama General de ESSIM-DE. **SI**: Simulador de Incendios, **DE**: Evolución Diferencial; **DE_A**: Evolución Diferencial (evaluación de aptitud); **EO**: Etapa de Optimización; **EE**: Etapa Estadística; **BK**: Búsqueda de K-ign; **K-ign**: valor clave de ignición; **FA**: Función de Aptitud;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

Finalmente, 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}).

4 EXPERIMENTACIÓN

Para realizar los experimentos con el método ESSIM-DE se han utilizado dos casos reales de estudio correspondientes a incendios controlados realizados en diferentes terrenos ubicados en Portugal (precisamente en Serra de Lousã, Gestosa), todos pertenecientes al proyecto SPREAD (Viegas, 2004). 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 1 puede observarse la información detallada para cada caso de prueba considerado.

Caso	Ancho (mts)	Largo (mts)	Pendiente (grados)	Inicio (min.)	Fin (min.)	Incremento (min.)
A	89	109	21	2.0	14.0	2.0
B	95	123	21	4.0	12.0	2.0

Tabla 1: Dimensiones, pendiente, tiempos e incremento de cada caso de prueba.

4.1 Pasos de simulación y predicción

Es importante resaltar la diferencia entre un pasos de simulación y un paso de predicción para el método ESSIM-DE. En la Figura 3 se observa que, para un incendio forestal determinado, se cuenta con t_s muestras representativas de la progresión del fuego, y por ende $s-1$ pasos de simulación y $s-2$ pasos de predicción. Esto es debido a que el método requiere una fase de inicialización o calibración, por lo cual no es posible realizar predicciones de manera inmediata (es decir, durante el primer paso de simulación, comprendido entre t_1 y t_2). En el caso A, la fase de inicialización está comprendida entre el minuto 2 y el minuto 4, y en el caso B, está comprendida entre el minuto 4 y el minuto 6. Luego de llevar a cabo la calibración, el sistema es capaz de realizar la primera predicción, para el segundo paso de simulación, lo que es equivalente al primer paso de predicción (entre t_2 y t_3). Por lo tanto, para cada caso de prueba se obtienen $s-2$ valores de predicción, uno para cada paso de predicción. El caso A cuenta con cinco pasos de predicción: entre los minutos 4-6 (1er paso de predicción), 6-8 (2do paso de predicción), 8-10 (3er paso de predicción), 10-12 (4to paso de predicción), 12-14 (5to paso de predicción). El caso B cuenta con tres pasos de predicción: entre los minutos 6-8, 8-10 y 10-12.




Figura 3: a) Representación del progreso de un incendio forestal, b) pasos de simulación, c) pasos de predicción.

4.2 Función de aptitud para la evaluación de calidad de predicción

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

$$Aptitud = \frac{(X \cap Y)}{(X \cup Y)} \quad (1)$$

donde X representa el conjunto de celdas en el mapa real sin el subconjunto de celdas quemadas antes de iniciar las simulaciones, y Y representa el conjunto de celdas en el mapa simulado sin el subconjunto de celdas quemadas antes de comenzar la simulación. La corrección que se realiza 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.

4.3 Técnica de muestreo y configuración del entorno

Para realizar la sintonización estática de los parámetros de entrada se utilizó la técnica de Muestreo por Hipercubo Latino (Latin Hipercube Sampling – LHS) (Mckay *et al.*, 1979) sobre un subconjunto de parámetros de ESSIM-DE, los cuales controlan el proceso de migración entre las islas. LHS utiliza un esquema de muestreo estratificado, permitiendo mejorar la cobertura del espacio muestral. Los parámetros que se eligieron para aplicar esta técnica de muestreo fueron el tamaño de la población, es decir, la cantidad de individuos en total de cada isla ($50 \text{ ind.} \leq TP \leq 500 \text{ ind.}$), el porcentaje de individuos a migrar ($5\% < PM < 40\%$), la frecuencia o tasa de migración en cantidad de iteraciones ($1 \text{ it.} \leq FM \leq 15 \text{ it.}$) y la cantidad de iteraciones evolutivas ($30 \text{ it.} \leq IE \leq 200 \text{ it.}$).

Para cada parámetro se definieron los rangos entre los cuales se realizó el muestreo estratificado y se generaron 20 vectores con dicha técnica. El resto de los parámetros utilizados por ESSIM-DE también fueron calibrados estáticamente en experimentaciones previas. Estos parámetros son el factor de mutación, la probabilidad de cruzamiento y el umbral de aptitud. La Tabla 2 describe los valores utilizados.

Los diferentes vectores de entrada, en conjunto con el resto de los parámetros del método, se aplicaron en los experimentos utilizando diferentes semillas, bajo un entorno de ejecución paralelo que fue configurado con 3 islas y 7 workers por isla. Las pruebas fueron realizadas en el cluster del Laboratorio de Investigación y Desarrollo en Inteligencia Computacional (LIDIC), perteneciente a la Universidad Nacional de San Luis.

Es importante remarcar que dependiendo de los valores que utilice cada una de las 20 configuraciones definidas por la técnica LHS, el tiempo total de ejecución se verá afectado en mayor o menor medida, puesto que los parámetros que se han considerado en el presente trabajo influyen directamente sobre la capacidad de búsqueda de cada isla y, por ende, del tiempo de ejecución total del método.

Caso	Factor de Mutación	Probabilidad de Cruzamiento	Umbral de Aptitud
A	0.88	0.76	0.65
B	0.93	0.29	0.69

Tabla 2: Parámetros evolutivos utilizados en la experimentación.

5 RESULTADOS OBTENIDOS Y DISCUSIÓN

A continuación se describen los principales resultados obtenidos en base a la experimentación realizada. Para mayor simplicidad del análisis, se seleccionaron los cuatro mejores resultados obtenidos de las 20 configuraciones descriptas en la sección 4.3. Los gráficos de las Figuras 4 y 6 muestran los valores de aptitud obtenidos para el caso A y B, respectivamente. Los gráficos de barra de las Figuras 5 y 7 muestran los tiempos de ejecución obtenidos con cada una de las configuraciones.

Caso	A				B			
	Nro	TP	PM	FM	IE	TP	PM	FM
1	222	40	6	164	426	29	5	130
2	382	21	13	31	456	17	10	176
3	438	8	8	100	326	11	2	149
4	237	5	4	56	360	27	5	186
ref	200	20	1	30	200	20	1	30

Tabla 3: Cuatro mejores configuraciones detectadas en la experimentación, para cada caso de prueba y parámetros de referencia (ref). TP: Tamaño de la Población, PM: Porcentaje de Migración, FM: Frecuencia de Migración, IE: Iteraciones Evolutivas.

La Tabla 3 describe las cuatro mejores combinaciones de parámetros, o configuraciones, obtenidas en la experimentación de cada caso. Además, se incluyen los parámetros utilizados como valores de referencia (ref), obtenidos a través de experimentación previa realizada sin sintonización estática de parámetros.

En primer lugar, se puede observar que los gráficos de las Figuras 4 y 6 no siguen una tendencia creciente o decreciente, puesto que dependiendo del paso de predicción que se esté analizando se logran obtener valores más altos o más bajos de aptitud. 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 quemas. 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, en el instante de tiempo siguiente. Las mejoras parciales representan un gran resultado desde el punto de vista predictivo, 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.

La Figura 4 muestra los resultados obtenidos para el caso de estudio A, el cual consta de cinco pasos de predicción. Podemos observar que en el primer paso de predicción se obtiene, en general, una aptitud muy alta con las configuraciones de sintonización, con valores

superiores a 0.79 y cercanos a 0.9. En este paso de predicción, las cuatro combinaciones de parámetros seleccionadas logran superar la aptitud obtenida por el caso de referencia (ref). Si se analiza el gráfico considerando la totalidad de los pasos de predicción, se puede observar que la aptitud obtenida con la configuración 3 comienza siendo la que logra mejores resultados, pero a medida que la simulación transcurre los valores obtenidos decaen en calidad. Por su parte, se observa que la configuración 1 obtiene valores de aptitud superiores a 0.7 en los pasos de predicción 4, 6 y 10, pero la aptitud decae los pasos de predicción 12 y 14. Sin embargo, es importante destacar que la configuración 1 supera la combinación de parámetros de referencia para la mayoría de los pasos de predicción.




Figura 4: **Caso A:** Resultados obtenidos con las cuatro mejores combinaciones de parámetros, y los valores de referencia (ref).




Figura 5: **Caso A:** Tiempos de ejecución (en segundos) obtenidos con las cuatro mejores combinaciones de parámetros, y los valores de referencia (ref).

La Figura 5 muestra los tiempos de ejecución (en segundos) obtenidos con cada una de las configuraciones seleccionadas para el caso A. Se puede observar que los tiempos de ejecución están directamente relacionados con la cantidad de individuos utilizada y con la cantidad de iteraciones del ciclo evolutivo. La configuración 3 obtiene el tiempo de ejecución más alto, y es la configuración con mayor cantidad de individuos en la población de cada isla.

La Figura 6 muestra los resultados obtenidos para el caso de estudio B, el cual posee tres pasos de predicción. Analizando la configuración 2 se puede observar que, si bien obtiene el mejor resultado en el primer paso de predicción, la tendencia de la aptitud es decreciente. Por su parte, la configuración 4 obtiene una aptitud superior a 0.8 en el primer y segundo paso de predicción, y alcanza un valor cercano a 0.7 en el último paso de predicción. En general, se puede observar de la gráfica que los valores de aptitud obtenidos con la configuración de referencia son superados por todas las configuraciones de sintonización seleccionadas.




Figura 6: **Caso B:** Resultados obtenidos con las cuatro mejores combinaciones de parámetros, y los valores de referencia (ref).




Figura 7: **Caso B:** Tiempos de ejecución (en segundos) obtenidos con las cuatro mejores combinaciones de parámetros, y los valores de referencia (ref).

Los gráficos de barra de la Figura 7 muestran los tiempos de ejecución obtenidos para el caso B con cada configuración. Se puede observar, al igual que en el caso A, que la configuración 2, la cual posee mayor cantidad de individuos en la población y mayor cota de iteraciones en el ciclo evolutivo, insume mayor tiempo de ejecución.

Es importante notar que, para los dos casos de experimentación considerados en este trabajo, no es posible determinar con exactitud una única configuración de parámetros óptima, ya que los mejores valores de cada paso de predicción se obtienen, en general, con diferentes experimentos (distintas combinaciones). Por lo tanto, la configuración de parámetros que brinda mejor desempeño en un paso de predicción puede no resultar efectiva para el paso siguiente. Para ejemplificar, es posible notar en la Tabla 3, para el caso A, que en cada paso de predicción se obtienen mejores resultados con poblaciones de diferente tamaño: en los pasos de predicción 2 y 8 la población de la mejor configuración está constituida por 438 individuos; en los pasos de predicción 6 y 10 la población posee 222 individuos; en el último paso de predicción la configuración con mejores resultados posee 382 individuos. Esto sugiere la alternativa de considerar que la población posea tamaño variable, en vez de mantener la misma cantidad de individuos durante toda la simulación. Para lograr dicho objetivo existen dos alternativas. Por un lado, se puede establecer que en cada paso de simulación la población de todas las islas adquiera un tamaño diferente al inicial. De esta manera, se puede tomar como referente el valor de la mejor configuración del proceso de sintonización, obtenido en cada paso de simulación. Por otro lado, gracias a que cada isla administra su propia población, esta característica también puede ser reflejada parametrizando las islas con poblaciones de diferente tamaño, al inicio de la simulación. En este caso, el valor que adquiere cada isla podría ser establecido en base al ranking de mejores configuraciones obtenidas en la sintonización. Finalmente, es posible profundizar el análisis con una experimentación que combine ambas alternativas. Desde el punto de vista evolutivo, estas configuraciones heterogéneas o mixtas podrían llegar a representar de manera más real el contexto de interacciones que se producen entre las especies.

6 CONCLUSIONES

En este trabajo se presentó un estudio de sintonización estática de un conjunto de parámetros utilizados en el esquema de migración para el método ESSIM-DE, tras ser aplicado a la predicción de incendios forestales. La migración tiene el objetivo de incorporar mayor diversidad en la población y disminuir la probabilidad de convergencia prematura o estancamiento en óptimos locales. Por ende, el proceso de migración afecta de manera directa la capacidad de búsqueda del método.

Para realizar la experimentación se utilizó muestreo estratificado por Hipercubo Latino, con 20 combinaciones diferentes de cuatro parámetros que influyen directamente en el proceso de migración. Los resultados obtenidos muestran que la calibración estática de estos parámetros logra incrementar la calidad de predicción del método, lo que enfatiza la importancia de realizar este tipo de ajuste o sintonización. Por otro lado, se pudo observar que no existe una única configuración de parámetros ideal, sino que la calibración es dependiente del problema y del paso de predicción considerado.

Como trabajo a futuro se propone realizar una nueva experimentación parametrizando cada paso de predicción con un tamaño de población diferente, de manera tal de considerar los

mejores valores de sintonización obtenidos. También resulta oportuno experimentar estableciendo tamaños de población diferente en cada isla, o considerar ambas estrategias, haciendo que cada isla posea dimensiones de población diferentes entre sí, y entre los distintos pasos de predicción.

AGRADECIMIENTOS

Este trabajo ha sido financiado por la Universidad Tecnológica Nacional mediante los proyectos EIUTIME0003939TC y EIUTNME0003952. Además, el primer autor agradece a CONICET por la beca doctoral otorgada.

REFERENCIAS

- Andrews, P.L., Bevins, C.D., Seli, R.C.: BehavePlus fire modeling system, version 2.0: User's Guide. Gen. Tech. Rep. RMRS-GTR-106WWW. Ogden, UT: Dept. of Agriculture, Forest Service, Rocky Mountain Research Station, 132, 2003.
- Ball, G.L., Guertin, D.P., FIREMAP, in Nodvin, S. C. and Waldrop, T. A., Fire and the Environment: Ecological and Cultural Perspectives, *Proceedings of an International Symposium*. Knoxville, TN. USDA Forest Service, Southeastern Forest Experiment Station, Asheville, NC. General Technical Report SE-69, 215-218, 1991.
- Bianchini, G., Caymes Scutari, P., Méndez Garabetti, M., Evolutionary-Statistical System: A parallel method for improving forest fire spread prediction. *Journal of Computational Science* 6:58-66, 2015.
- Bodrožić, L., Stipanicev, C., Šeric, M., Forest fires spread modeling using cellular automata approach. *Modern trends in control*. 23-33, 2006.
- Cantú Paz, E., A Survey of Parallel Genetic Algorithms, *CALCULATEURS PARALLELES*, vol 10, 1998.
- Darwin, C., On the Origin of Species by Means of Natural Selection, London, Murray, 1859.
- Finney M.A.: FARSITE: Fire Area Simulator-model development and evaluation. Res. Pap. RMRS-RP-4, Ogden, UT: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station, 47, 1998.
- Fons W., Analysis of fire spread in light forest fuels, *J. Agric. Res.*, 72:93-121, 1946.
- Jorba, J., Margalef, T., Luque, E., Campos da Silva, J., Viegas, D.X., Parallel Approach to the Simulation of Forest Fire Propagation. *Proc. 13 Inter. Symposium "Informatik fur den Umweltshutz" der Gesellschaft Fur Informatik (GI)*, 68-81, 1999.
- Lopes, A.M.G., Cruz, M.G., Viegas, D.X., FireStation - An integrated software system for the numerical simulation of wind field and fire spread on complex topography. *Environmental Modelling & Software*, 17 (3):269-285, 2002.
- Mandel, J., Beezley, J.D., Kochanski, A.K.: Coupled atmosphere-wildland fire modeling with WRF 3.3 and SFIRE 2011, *Geoscientific Model Development (GMD)* 4:591-610, 2011.
- Mattson T, Sanders B, Massingill B. Patterns for Parallel Programming. Addison-Wesley Professional, capítulo 5, 143-152, 2004.
- Mckay, M. D., Beckma, R. J., Conover, W.J.: A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output From a Computer Code, *Technometrics*, 21:239-246, 1979.
- Méndez Garabetti, M., Bianchini, G., Caymes Scutari, P., Tardivo, M.L., Increase in the quality of the prediction of a computational wildfire behavior method through the improvement of the internal metaheuristic, *Fire Safety Journal*, Elsevier, 82: 49-62.

- Price, K., Storn R., Lampinen J., *Differential Evolution: A Practical Approach to Global Optimization*, Springer, New York, 2005.
- Rothermel, R.C., A mathematical model for predicting fire spread in wildland fuels, Res. Pap. INT-115, US Dept. of Agric., Forest Service, Intermountain Forest and Range Experiment Station. (Ogden, UT.), 1972.
- Rothermel, R.C., How to predict the spread and intensity of forest fire and range fires. Gen. Tech. Rep. INT-143, US Dept. of Agric., Forest Service, Intermountain Forest and Range Experiment Station. (Ogden, UT.), 1983.
- Talbi, E.G., *Metaheuristics: from design to implementation*, John Wiley & Sons, Inc., 2009.
- Tardivo, M.L., Caymes Scutari, P., Méndez Garabetti, M., Bianchini, G., Sintonización Estática de Parámetros Operacionales para un Modelo Paralelo de Evolución Diferencial, *1er Congreso Nacional de Ingeniería Informática y Sistemas de Información*, 770-779, 2013.
- Tardivo, M.L., Caymes Scutari, P., Méndez Garabetti, M., Bianchini, G., Cortés, A., Three Evolutionary Statistical Parallel Methods for Uncertainty Reduction in Wildland Fire Prediction, *Proceedings of the 2016 International Conference on High Performance Computing & Simulation (IEEE HPCS 2016)*, Innsbruck, Austria, 721-728, 2016
- Viegas, D. X., Project Spread – Forest Fire Spread Prevention and Mitigation, <http://www.algosystems.gr/spread/>, 2004.